

東海大学大学院令和6年度博士論文

ECサイトにおける消費者の
セッション中の購買予測

指導 田畑智章教授

東海大学大学院総合理工学研究科
総合理工学専攻

福井 悠斗

目次

第 1 章	序論	3
1.1	研究背景	3
1.2	研究目的	7
1.3	論文の構成	8
第 2 章	本研究で用いる概念	10
2.1	EC の定義とその変遷	10
2.2	セッションの定義	12
第 3 章	先行研究	13
3.1	セッション中の購買予測モデルに関する研究	13
3.2	本研究で比較対象とするモデル	14
3.2.1	Vieira (2016) のモデル	14
3.2.2	Esmeli et al. (2020) のモデル	15
3.2.3	Vieira (2016) と Esmeli et al. (2020) のモデルで考慮されていない消費者の購買行動, その限界	17
第 4 章	本研究の提案	19
4.1	セッション中の購買予測モデル	19
4.2	モデル化の方針	19
第 5 章	瞬間的な多様さを考慮したモデル	22
5.1	セッション中における消費者の行動の多様さ	22
5.2	新美・星野 (2017) の研究	22
5.3	Fukui et al. (2022) のモデル	23
5.4	検証	23
5.4.1	使用するデータの概要・前処理	24
5.4.2	使用する手法	28
5.4.3	モデルの概要と結果	30
5.4.4	考察	31

第 6 章	訪問経験を考慮したモデル	35
6.1	消費者のサイト訪問経験	35
6.2	提案	35
6.3	検証	37
6.3.1	モデルの概要と結果	37
6.3.2	考察	37
第 7 章	累積的な多様さを考慮したモデル	40
7.1	購買過程における消費者の行動の多様さ	40
7.2	Fukui, Tabata (2024) のモデル	40
7.3	検証	41
7.3.1	モデルの概要と結果	41
7.3.2	考察	41
第 8 章	購買経験に対する忘却を考慮したモデル	44
8.1	消費者の忘却	44
8.2	Fukui, Tabata (2024) のモデル	44
8.3	検証	45
8.3.1	モデルの概要と結果	45
8.3.2	考察	46
第 9 章	本研究の意義	49
第 10 章	結論と今後の課題	52
	謝辞	55
	参考文献	56
	付録	60
	業績リスト	78

第 1 章 序論

1.1 研究背景

実店舗を運営する小売業者は、POS システムと呼ばれる「光学式の読み取り器によって、製品に印刷または添付されているバーコードを読み取って精算を行うシステム」[1] から得られる POS データを蓄積している。このデータは「商品別もしくはカテゴリー別、日別（時には週別、月別）の販売状況を記録したデータ」[2] であり、小売業者はそれらデータを活用することで、特定の時期によく売れる商品をその時期に店頭の見やすい位置に配置するなどのマーケティング施策を実施している。しかし、POS データはあくまでも販売実績を記録したものであり、そこからは消費者の動線を確認することができない。すなわち、POS データは消費者がどこから来て、何の商品を閲覧し、何分後にレジに進んだかなどの購買プロセスを示してはおらず、また、ただ店舗に立ち寄り、購買をせずに退店を行なった消費者の情報も含んでいない。

ここで、図 1.1 より、我が国における EC の市場規模は拡大を続けており、2023 年には BtoC-EC の市場規模が 24.8 兆円に達し、前年対比で 9.2 % の増加を示している [3]。なお、BtoC-EC は Business to Consumer-EC の略であり、消費者向けの電子商取引を指している。このような背景に伴い、消費者との接点を増やすべく Web サイトを構築して販売活動を行う企業は、構築したサイトから消費者が購買に至るまでの過程のデータを取得できるようになっている。例を挙げると、消費者が商品を探る際にどのようなキーワードを用いて検索したか、特定の商品を検索するのにどれくらいの時間を費やしたか、また、消費者がサイトに訪問したものの購買に至らなかった際のデータの取得も可能となっている。企業はそれらデータを活用することによって、自社サイトに訪れる消費者に対し従来よりも多種多様なマーケティング施策を実施でき、販売促進を図ることが可能となっている。

しかし、消費者による EC サイトへの訪問、これを“セッション”と呼ぶが、そのうち購買に至るものはごくわずかであることが知られている [4]。サイトへの訪問のうち消費者が購入に至る割合を“サイトの購入転換率”と呼ぶ [5] が、この指標は概ね 2% ~ 4% [6] であるため、ほとんどの消費者が購入意思を持たずにサイトに訪れていることがわかる。したがってそれを少し改善させるだけでも、サイト運営企業は大幅に収益を増加させることが可能となる [7] と言える。このような背景から、各企業は例えばサイトの購入転換率を上昇させるべく、当該サイトに訪れるすべての消費者に対して商品を購入する際に使用することができる割引クーポンを配布するなどの施策を打ち出している。

しかしながら、割引クーポンを配布しなくても購買に至る可能性が高い消費者に対してクーポンを配布することは、マーケティングコストの浪費を招き、費用対効果の観点から非効率であると考えられる [8]。この課題への対応策としては、サイトに訪問した消費者が当該訪問において購買に至るか否かを予測し、購買に至らな




図 1.1 “経済産業省令和 5 年度電子商取引に関する市場調査報告書” [3] を参考に著者作成（BtoC-EC 市場規模の経年推移（単位：億円））

いと予測される消費者に限定して割引クーポンを配布する手法が挙げられる。この方法を用いることで、クーポンを配布しなくても購買に至ると予測される消費者を配布対象から除外することが可能となり、結果としてマーケティングコストの削減が期待できる。また、Guan ら（2022）は潜在的な購入者をターゲットとすることで、オンラインショップがプロモーションコストを大幅に削減し、投資収益率を向上させる可能性があるとして述べている [10]。

ここで、そもそも上記のような施策を実施するためには、任意のセッションにおける消費者の行動をもとに、当該セッション中の消費者の購買意思を正確に特定することが求められる。しかし、サイト内の消費者の行動は多様かつ多面的であるため、どのような行動を取る消費者がそのような意思を持っているかを正確に見極めることは容易ではない。この問題に対する解決策として用いられるのがセッション中の消費者の行動を表現したモデルであり、当該モデルを用いることで、任意のセッションにおける特定のタイミングで消費者が購買を行うか否かを予測できる。具体的に、このモデルではセッション開始から観察できている地点までに取得されたデータをもとに、そのタイミングでの消費者の購買有無を予測する。注意が必要なのが、そのタイミングはモデルの使用者が任意に設定するため、例えば消費者がサイトにアクセスしてから商品を 3 つ閲覧した時点での予測や、閲覧数に関係なくアクセス後 1 分が経過した時点での予測などいくつか存在する。また、購買を行うと予測された消費者は購入意思を持っているものとして扱っている。このモデルを活用することで、任意のセッションに訪問した消費者が購入者か非購入者かを判定できるため、購入者をクーポンの配布対象から排除できる。したがって、非購入者のみを対象とした割引クーポンを配布することができることから、マーケティングコストの削減に繋げることができる。

セッション中における消費者の購買を予測するモデルを構築している従来研究は複数存在しており、例えば Mokryn et al. (2019) [5], Bogina et al. (2016) [9], Vieira (2017) [11], Esmeli et al. (2021) [4], Boroujerdi

表 1.1 従来のモデルに取り入れられている観点・特徴量

		セッション中の情報						消費者の特性				消費者属性		その他	
		滞在・閲覧時間	金額	PV数	ユニークに閲覧された商品数	閲覧した商品の人気度	カートの情報	時刻	月	曜日	年	デモグラフィック	OS	地理的情報	
Boroujerdi et al. [12]	2014	×	○	○	×	×	○	○	×	×	×	○	×	×	×
Bogina et al. [9]	2016	○	×	○	×	○	×	○	○	○	○	×	×	×	×
Vieira [11]	2016	○	○	○	×	×	×	○	×	×	×	×	×	×	×
CHEN et al. [13]	2017	○	×	○	○	○	×	○	○	○	○	×	×	×	×
Mokryn et al. [5]	2019	○	×	○	×	○	×	×	○	○	×	×	×	×	×
Esmeli et al. [4]	2020	○	×	○	○	○	×	○	○	○	○	×	×	×	×
Chaudhuri et al. [14]	2021	○	○	○	×	×	○	○	×	○	×	○	×	×	×
Tanvir et al. [15]	2023	○	×	○	×	×	×	×	○	×	×	×	○	○	○




図 1.2 従来のモデルで考慮されていない消費者の購買行動 1

et al. (2014) [12], CHEN et al. (2017) [13] や Chaudhuri et al. (2021) [14] に Tanvir et al. (2023) [15] などがある。これら研究で構築されているモデルに反映されている要素を簡易的にまとめたものが表 1.1 になり、赤色がモデルに反映されている要素で、青色はモデルに反映されていない要素を示している。たとえば Esmeli et al. (2021) [4] は、消費者のセッション中の購買意向を早期に予測するフレームワークを提案し、複数の機械学習モデルを用いた比較検証を通じて、それらの予測性能を明らかにしている。彼らは、消費者のセッション中における滞在時間やセッション中に閲覧した商品の人気率等を用いてモデルを構築している。

ここで、従来のセッション中の購買予測モデルには、サイト内の滞在時間や閲覧した商品などのセッション中の消費者行動を代表する変数が中心に扱われていることから、実験的な側面が強いことが見受けられる。しかし、そのようなモデルでは消費者のセッション中の購買意思に影響を与えるであろうと考えられる要因が十分に検討されておらず、詳細な消費者の購買行動をモデル上で表現することができていない。具体的に、以下では従来のモデルで考慮されていない消費者の購買行動、その限界を 3 つ挙げている。

1. 消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか
2. 消費者の過去のサイト訪問経験
3. 消費者は購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか

まず 1. は、“幅広く様々な商品に均等に閲覧時間を費やしていた消費者よりも、1 つの商品に重点的に閲覧時間を費やしていた消費者の方が購買意思がある”という仮説である。例としては図 1.2 が存在し、これは、任




図 1.3 従来のモデルで考慮されていない消費者の購買行動 2

意のセッションにおける商品閲覧時間が 15 分でかつ、商品 A, B, C を閲覧している消費者 X_1 と X_2 が同じ購買行動を有していると考えて良いのか、という問題提起である。消費者 X_2 は特定の商品 A を重点的に閲覧しているため、少なくとも消費者 X_1 よりも購買に至りやすいと考えられるが、従来のモデルではそのような消費者の購買行動を捉えることができていないという点で、正確な購買意思の判定に繋げることができていないと考えられる。このような消費者の購買行動を捉えることは、消費者の各商品に対する関心の深さをモデルに反映させる上で有用であり、購買に影響を与える要因を考慮する点で価値がある。例えば家電を購入する際に、値段など種々ある要素を気にして各商品に均等に閲覧時間を割り振っている消費者は、1 つの家電に興味を持ち、始終それを閲覧している消費者よりも購買に至りにくいであろう。

次に 2. は、“過去何度もサイトに訪問していた、もしくは既にそのサイトで商品を何度も購買していた消費者は、初めてそのサイトに訪れる消費者よりも購買意思がある”という仮説である。例としては図 1.3 が存在し、ここでは、初めてサイトに訪れる消費者 X_4 よりも、何度もそのサイトに訪れている消費者 X_3 の方が購買に至りやすいと考えられるため、消費者 X_3 と X_4 の購買行動を同じものとして扱って良いのか、という問題を挙げている。これは、従来のモデルでは 1/5 時点での消費者の購買を予測する際に、1/1 から 1/5 までの訪問経験がすべて無視されてしまうため、各時点のサイト訪問が全て独立して扱われていることに対する問題提起でもある。消費者が商品の比較検討を行う際には何度もサイトに訪問することが予想され、また、購買に応じてポイントが付与されるサイトにおいては、過去何度もそのサイトで購買を行った消費者は再び同じサイトでの購買に至りやすいと考えられる。このように、消費者は過去蓄積された経験を元に現在の購買行動を決定すると考えられるため、これを考慮しない従来のモデルでは、正確に消費者の購買意思を判定することは難しいであろう。なおこれに関して例を挙げると、日々多忙なサラリーマンは、通勤の合間に商品を閲覧し、休みが入った際に本格的な検討を行い購買に至るといったものがある。

そして 3. は、“任意のセッションで 1 つの商品を重点的に閲覧していたとしても、別のセッションで異なる商品に対して同様の行動を繰り返している消費者は、そうでない消費者と比べて購買意思がない”という仮説である。例としては図 1.4 が存在し、ここでは、各セッションにおいて特定の商品を重点的に閲覧していたかつ、セッション全体を通しての商品閲覧時間が 51 分である消費者 X_5 と X_6 が同じ購買行動を有していると考えて良いのか、という問題を提起している。あるセッションにおいて特定の商品を重点的に閲覧していたとしても、その行動を他の商品に対しても繰り返している消費者 X_5 は、単に情報収集のためにサイトに訪問していると考えられるため、セッション全体で見て最終的に商品 A と B のみを閲覧している消費者 X_6 と比べて購買に至りにくいのではないか、という疑問がある。この観点をモデルに取り入れない場合、例えば Moe



図 1.4 従来のモデルで考慮されていない消費者の購買行動 3

(2003) [16] で言及されているような、購買よりも知識を得ることに重点を置いている消費者や、単に決断力が欠如している、優柔不断さを持ち合わせているといった消費者の判別ができないため、消費者の購買意思を正確に見極めることが難しくなると考えられる。なお、1. (図 1.2) で述べた観点との違いは、1. は任意のセッションにおける消費者の各商品に対する関心の深さを評価していたが、3. はセッション全体での行動パターンを評価している点にある。

本研究では上記 3 つの視点が反映されていない従来のモデルの限界を克服するため、消費者のセッション中の購買意思を正確に捉えるべく、購買に影響を与える要因を吟味、変数として新たに作成し、より現実的な消費者の購買行動をモデル化する。なお、このように提案したモデルは従来の技術でも実現可能なものであるが、従来にはない視点を新たに導入し、それまでのモデルでは捉えることができていなかった消費者の購買行動を新たにモデルに取り入れ、検証まで行ったという点に新規性があると考えられる。また、従来の研究でそれら要素が十分に考慮されていなかった理由として、EC サイトの普及から現在に至るまで当該研究分野の研究期間が比較的短く、そして研究を開始するにあたって十分なデータ量を確保する必要があったということが挙げられる。このような背景から、従来のモデルでは消費者の購買に影響を与えられようとする要因が十分に熟慮されておらず、詳細な消費者の購買行動を捉えることができていなかった。これに対し本研究では、既存のデータを最大限活用し、消費者の購買行動を捉えた適切な変数を作成、モデルに取り入れることで予測精度の向上を実現している。

1.2 研究目的

本研究ではまず、“消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか”と、“消費者の過去のサイト訪問経験”，そして“消費者は購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか”の 3 つの観点を新たに考慮したセッション中の購買予測モデルを構築する。これらの観点はそれぞれ第 5 章、第 6 章、第 7 章で取り上げ、6 章および 7 章をモデル化する際の留意点については第 8 章に組み込んでいる。そして、消費者の購買有無を正確に予測し、その結果に基づいて非購買者を購買者に転換する施策に活用できるモデルを構築し、その精度向上を図ることを目的とする。ここで、本研究では購買を検討する際に一定の迷いや熟考を要する消費者の購買行動を捉えたモデルの構築を目指している。EC サイトで見られる消

表 1.2 EC サイトで見られる消費者の購買行動

商材	購買頻度	悩む時間	価格帯	例	対象企業
日用品	高	短い	低	トイレット ペーパー・青果	マツモトキヨ シ・オーケー
耐久消費財	低	中～長	高	家電・家具	ヨドバシカメ ラ・ニトリ
嗜好品	中	長	低～高	ワイン・化粧品	ENOTECA・ 資生堂
サービス	中	短～中	中～高	旅行・デリバ リー	じゃらん net・ Uber Eats

費者の購買行動は表 1.2 にあるように多様に存在するが、一般的に価格帯が高い商材は購買を検討するにあたって悩む時間が長くなると考えられるため、本研究では耐久消費財および嗜好品に焦点を当ててモデル化を行う。

1.3 論文の構成

本論文の構成は以下の通りである。

第 2 章では、本研究で用いる概念を整理する。具体的には、“EC” の定義やその変遷、本研究で対象とする EC のタイプをまとめ、“セッション” の定義を行う。EC サイトにおける消費者のセッション中の購買予測モデルを構築する上で、これらの定義を整理することは以降の議論を正確に展開するために不可欠である。

第 3 章では、セッション中の消費者の購買予測モデルを構築している従来研究、具体的には 1.1 節で述べた [5] から [15] までの概要を説明する。その後、本研究で予測精度の検証を行うために比較対象とする Vieira (2016) [11] と Esmeli et al. (2020) [4] のモデルが捉えている消費者の購買行動に言及し、それらのモデルで考慮されていない消費者行動と、それにより生じる問題について論じる。

第 4 章では、第 1 章から第 3 章までの内容を振り返り、改めてセッション中の購買予測モデルおよび従来研究の限界に触れる。その上で、本研究の提案として以降の 5 章から 8 章にかけてのモデル化の方針とその目的を説明する。

第 5 章では、“消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか”，すなわち，1.1 の 1. で述べた要素を考慮したモデル，ここではセッション中の消費者の行動の多様さを考慮したモデルを構築する。具体的には，新美・星野（2017）[17] が提唱する“多様性”の概念を拡張した特徴量を新たに作成し，モデルに用いている Fukui et al. (2022) [18] の研究を詳述する。

第 6 章では，1.1 の 2. で述べた，“消費者の過去のサイト訪問経験”を考慮したモデルを構築する。具体的には，“累積購買回数”と“購買に至るまでの平均訪問回数”の 2 つの特徴量で消費者のサイト訪問経験を表現し，それらを用いたモデルを構築する。

第 7 章では，“消費者は購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか”，すなわち，1.1 の 3. で述べた要素を考慮したモデル，消費者特性としての行動の多様さを考慮したモデルを構築する。再度，5 章で述べた新美・星野（2017）[17] が提唱する“多様性”の概念から，消費者行動の累積的な多様

さを示す特徴量を作成し、それを用いてモデルを構築している Fukui & Tabata (2024) [24] を詳述する。

第 8 章では、消費者のサイト訪問経験を考慮する上での留意点として、消費者の購買経験に対する忘却を考慮したモデルを構築する。ここでは、Fukui & Tabata (2024) [25] が提案する、消費者の過去の購買経験が忘却されていく様子を表現したモデルを詳述する。

第 9 章では、本研究の実務的な貢献を述べる。具体的には、本研究で構築したモデルを用いた施策の有効性、たとえば、“離脱する”と予測された消費者にのみ割引クーポンを配布するといった施策が、従来の全ての消費者に対しクーポンを配布していたものと比較して、費用対効果の面でどの程度効率的になったのかを推定する。

第 10 章では、本研究の主要な結論をまとめ、今後の研究課題や展望について議論する。本研究の限界においては、未だ捉えることができていない消費者のセッション中の購買行動に影響を与えと考えられる要素に言及する。

第 2 章 本研究で用いる概念

2.1 EC の定義とその変遷

経済産業省令和 4 年度電子商取引に関する市場調査報告書 [3] によると、OECD による EC の定義には、以下の広義 EC と狭義 EC が存在している。

広義 EC (BROAD definition)：物・サービスの売却あるいは購入であり、企業、世帯、個人、政府、その他公的あるいは私的機関の間で、コンピュータを介したネットワーク上で行われるもの。物・サービスの注文はこれらのネットワーク上で行われるが、支払い及び配送はオンラインで行われてもオフラインで行われても構わない。

狭義 EC (NARROW definition)：物・サービスの売却あるいは購入であり、企業、世帯、個人、政府、その他公的あるいは私的機関の間で、インターネット上で行われるもの。物・サービスの注文はインターネット上で行われるが、支払い及び配送はオンラインで行われてもオフラインで行われても構わない。

本研究では上記を踏まえて、狭義 EC の定義を採用し、以降の議論を進める。これは、広義 EC を採用した場合、例えば製造業者が原材料を仕入れるためにサプライヤーの専用ネットワークを通じて行う注文なども EC として扱われることになり、その取引形態の多様さから、議論の対象が曖昧になる可能性があるためである。

EC の発展は技術の進歩と密接に関連している [26]。1960 年代には「企業や行政機関などがコンピュータをネットワークで繋ぎ、伝票や文書を電子データで自動的に交換する」EDI (Electronic Data Interchange) と呼ばれる仕組み [27] が誕生した。約 20 年後の 1983 年には TCP/IP プロトコルの採用により、すべてのコンピュータが同等に情報を交換できるインターネットの基盤が確立され、続いて 1991 年には、全米科学財団ネットワークがインターネットの商業利用に対する制限を解除し、インターネットが商業的に活用される道が開かれる。そして 1995 年、Amazon.com の開設を機に、“e-commerce”という用語が広く使われるようになり、インターネットを介した商取引が急速に普及する。その後は、オンラインオークションサイトである eBay やパソコン販売を行う DELL などの多くの企業がインターネットを活用したビジネスモデルを展開し始め、米国における EC の収益は急成長を遂げた。さらに、2007 年に登場したスマートフォンは、携帯電話に比べてパソコンに近い性質を持つ情報機器として普及し、EC 市場の拡大を後押しすることになった。こうして、EC は現在に至るまで飛躍的な成長を続けている。

表 2.1 EC の 6 つの取引形態

取引形態	特徴	例
B2B (Business to Business)	企業が別の企業にサービスや商品を販売する	アスクル、モノタロウ
B2C (Business to Consumer)	企業が個人消費者に対して製品やサービスを小売販売する	楽天、ニトリ
C2C (Consumer to Consumer)	消費者が他の消費者に商品やサービスを販売する	メルカリ、Yahoo!フリマ
C2B (Consumer to Business)	消費者が自分の商品やサービスを企業や組織に販売する	クラウドワークス、ココナラ
B2A (Business to Administration)	企業が主要な Web ページを使用してデータを送受信し、政府機関と取引を行う	法的文書など
C2A (Consumer to Administration)	消費者から行政への取引または消費者から政府への電子取引	電気料金、健康保険料の支払いなど

EC にはいくつかの取引形態が存在し、Taher and Alnoor (2021) [28] はそれらを 6 つにまとめている（表 2.1）。まず、B2B（Business to Business）は、企業が他の企業に対してサービスや商品を販売する取引形態で、アスクルやモノタロウがその代表例となる。一方、B2C（Business to Customers）取引では、企業が個人消費者に対して製品やサービスを販売する形態であり、楽天やニトリがこのカテゴリーに該当する。消費者が他の消費者に商品やサービスを販売する C2C（Customer to Customer）取引も一般的で、メルカリや Yahoo!フリマが代表的なプラットフォームとしてこれに該当する。また、消費者が自分の商品やサービスを企業や組織に販売する C2B（Customer to Business）取引もあり、これにはクラウドワークスやココナラ等が当てはまる。さらに、B2A（Business to Administration）取引は、企業が主にウェブページを使用して政府機関とデータの送受信を行う形態で、これは法律文書のやり取りが典型的な例となる。そして、C2A（Customers to Administration）取引は、消費者が行政や政府への電子取引を行い、電気料金や健康保険料の支払いを行う形態を示す。このように、EC には多様な取引形態があり、それぞれが異なる特徴と用途を持っている。本研究ではこれら 6 つの取引形態の中で、B2C（Business to Customers）を対象とする。

なお、B2C には消費者との取引を行う場合に、“自社サイト”を通してそれを為す場合と、「インターネット上で多数の事業者と消費者を仲介し、商品を販売するために必要となるプラットフォーム」[29]である“オンラインモール”を利用する場合の 2 つが存在するが、そのどちらに対してもセッション中の購買予測モデルを適用することができると考えられるため、本研究では明確に区別しない。

2.2 セッションの定義

本研究で構築する“セッション中の購買予測モデル”を議論するにあたり，“セッション”の定義を明確にする。ここで，Chaudhuri et al. (2021) [14] はセッションを“オンラインプラットフォームへの1回の訪問”と定義し，Jansen et al. (2007) [30] はセッションを“1つの情報ニーズに対応するためのユーザーによる一連のインタラクション”，Wu et al. (2017) [31] は“e コマースサイトにおけるユーザー活動（例：クリック，購入）の中断されない一連のシーケンス”と定義している。このようにセッションの定義にはばらつきが見られ，画一的な定義は存在しないと考えられる。したがって，本研究ではセッションを“消費者がサイトにアクセスを行ってから離脱をするまでの期間”として概念的に定義する。この“概念的”という表現は，実務において各企業のサーバ上でのセッションの扱いが異なることに起因している。セッションを管理するサーバーには，ある消費者がサイトにアクセスした際の行動がリアルタイムに格納されており，たとえば消費者がホームページから特定の商品ページへ遷移し，商品をカートに追加した後，さらに別の商品ページを閲覧するなどの一連の行動が記録される。ゆえに，購買を行なった後でも何かの買い忘れに気づいて再度サイト内回遊を行うケースや，特定のページに長時間とどまり熟慮しているケースなどが存在するため，消費者が当該サイトから離脱したかどうかを即座に検知することは難しい。そのため，消費者が特定の時間，例えば2時間以上サイトでのアクションを取らなかった場合にそのセッションが自動的に終了されたものと見なすなどの基準が必要になり，その基準が企業ごとに異なっていることから，セッションの定義が企業ごとに異なっている。本研究では使用したデータ提供企業のセッションの定義を基に以降の議論を展開するが，対象企業では，消費者の長時間の非アクティブ状態が続いた場合に離脱したと判定しているため，その期間をセッションとして扱う。したがって，セッション中の消費者の購買行動には，消費者がサイトにアクセスしてから，特定の商品ページを閲覧する，クリックする，商品ページにはアクセスしないものの，単にスクロールを繰り返して長時間滞在するといった振る舞いなどが含まれる。

第 3 章 先行研究

3.1 セッション中の購買予測モデルに関する研究

“セッション中の購買予測モデル”を構築している研究は数多くあり、1 章で述べた通り例えば Mokryn et al. (2019) [5], Bogina et al. (2016) [9], Vieira (2017) [11], Esmeli et al. (2021) [4], Boroujerdi et al. (2014) [12], CHEN et al. (2017) [13] や Chaudhuri et al. (2021) [14] に Tanvir et al. (2023) [15] などがある。本節ではそれら先行研究の概要を述べ、その中でも、本研究で構築するモデルの予測精度を検証する上で、比較対象とするモデルに Vieira (2017) [11] と Esmeli et al. (2021) [4] を選択した理由も述べる。

まず Mokryn et al. (2019) [5] は、過去 n 日間の商品の人気度などを考慮した匿名訪問者のセッション中の購買予測モデルを構築しており、消費者の過去の行動等を考慮せず、当該セッションが購入で終わるかどうかのモデルを構築している。次に Bogina et al. (2016) [9] は、時間経過に伴う商品の人気度などのトレンド性を用いて予測モデルを構築しており、消費者が各セッションでセッションで購入に至るかを予測することで、レコメンドシステムへの応用を行うことを目的としている。そして Vieira (2017) [11] は、消費者のサイト上での滞在時間やクリック回数 (PV 数)、消費者が閲覧した商品の価格などを用いてモデルを構築している。彼が使用している手法はロジスティック回帰、ランダムフォレスト、Deep Learning の 3 つであり、それらモデルの AUC を比較している。Esmeli et al. (2021) [4] は、前述のように、消費者のセッション中の購買意向を早期に予測するフレームワークを提案し、複数の機械学習モデルを用いた比較検証を通じて、それらの予測性能を明らかにしている。彼らは消費者のセッション中における滞在時間やセッション中に閲覧した商品の人気率等を用いてモデルを構築しているが、その人気率は Mokryn et al. (2019) [5] で提案されているものである。そして Boroujerdi et al. (2014) [12] は、カゴに入れた全商品の価格の合計などの要約された特徴量に基づいて予測モデルを構築しており、主な研究の貢献を消費者の行動を表す特徴量のみに基づいて予測モデルを構築し、消費者の嗜好や過去に購入した商品の種類に関連するものは含まれていないこととしている。CHEN et al. (2017) [13] は、ユニークに閲覧された商品の数や、よく一緒にクリックされる商品同士の類似性などを用いて予測モデルを構築しており、また、各商品の時間的ダイナミクスに基づく人気度合い等も用いてモデル化を行っている。そして Chaudhuri et al. (2021) [14] は、セッション中の消費者の行動に加えて、それら消費者の性別や年齢などのデモグラフィック情報を用いて予測を行っており、大規模なデータにおける Deep Learning 手法の予測能力の高さを機械学習と比較して実証している (決定木, ランダムフォレスト, SVM 等)。最後に Tanvir et al. (2023) [15] は、顧客が商品を購入するかどうかを判定する分類器を提案し、訪問者の購買意思をリアルタイムで予測、その特徴量として顧客が閲覧したページ数や使用した OS, セッションを開始した際の顧客の地理的な場所等を使用している。また、SVM, RF, MLP, DT, XGBoost を比較し、

XGBoost が最も性能の良い分類器であると結論づけている。

各研究で使用されているモデルの特徴量を表 1.1 に示しており、これにより、各研究が主にセッション中の情報、消費者自身の特性、その属性の 3 つの観点に基づいてモデルを構築していると言える。本研究では、Mokryn et al. (2019) [5] から Tanvir et al. (2023) [15] までの研究において構築されたモデルが、消費者の購買行動に関するいくつかの要素を十分に考慮できていない点に限界があることを指摘し、その限界を克服するために新たな要素をモデルに導入することを提案する。そして、それら要素を取り入れたモデルと既存のモデルとの予測精度を比較し、前者が高い予測精度を示した場合に、その新たな要素が消費者の購買意思を正確に特定することに寄与しているとして、その有効性を示すものとする。このような形で提案内容の検証をするべく、本研究では Vieira (2017) [11] および Esmeli et al. (2021) [4] のモデルを比較対象として指定する。それらモデルを比較対象とした理由は、消費者のセッション中の滞在時間や閲覧した商品の金額やその人気度、そして消費者自身の特性がその購買行動を左右する重要な要因なりえと考えられたためである。具体的に、セッション内での滞在時間の長い消費者や金額が高い商品を閲覧している消費者は購買に対して迷いが生じている、熟慮していると考えられるため、購買に至りにくいと考えられる。そして、商品の人気度は、当該サイトで扱っている主流の商品に対して関心があるか否かを示していることから、そのような商品に関心がある場合には、少なくとも購買に至りやすいと考えられる。また、消費者自身の特性は、当該消費者のサイトへのアクセスパターンを示しているため、例えば特定の季節やイベントに関連する月に購買意思が高まる、経済状況等が反映される年次の変化などに影響を受け、購買を差し控えるなどが考えられるため、それら要素も消費者の購買意思を正確に特定する上で必須であると考えられる。したがって、それら消費者のセッション中の購買に影響を与えると考えられる要因をモデルに取り入れている Vieira (2017) [11] および Esmeli et al. (2021) [4] は、本研究で新たに構築するモデルの比較対象として妥当であると考えられる。なお、Boroujerdi et al. (2014) [12] や Chaudhuri et al. (2021) [14]、また、Tanvir et al. (2023) [15] で構築されているモデルは、昨今のデータ保護規制の観点からデモグラフィックの利用が難しく、また、OS や地理的情報もデータとして取得されることが多くないため、本研究では比較対象としていない。

3.2 本研究で比較対象とするモデル

本節では、本研究で新たに構築するモデルの比較対象として選定した、Vieira (2017) [11] および Esmeli et al. (2021) [4] の研究を詳述する。具体的には、それら研究で構築されたモデルがどのような特徴量を使用し、それら特徴量がどのような消費者の購買行動を映し出しているかを述べる。

3.2.1 Vieira (2016) のモデル

まず、Vieira の研究は、目的変数に購入で終わるセッションと購入で終わらないセッションを設定し、それらを予測するモデルをロジスティック回帰やランダムフォレスト、Deep Learning によって構築している。結果として Deep Learning が最も AUC が高い値を示したとしてモデルの有用性を評価しており、その際、以下の要素を特徴量として用いて消費者の購買行動をモデル上で表現している。

1. D_s : セッション開始から終了までの時間（滞在時間）；滞在時間の長さで熟慮している購買行動、短さ

で突発的, もしくは計画的な購買行動を表す

2. C/B : 特定の期間の各商品の CVR を各消費者がそれら商品をセッション中に閲覧した回数で割った値; 他の消費者が買っている商品をよく見て, よく買う消費者なのか, あるいはあまり購買されないニッチな商品を見て, それを買う消費者なのかの特性を示す
3. S_B : 各消費者の非購買セッション数の中央値; どれだけ商品の検討を行ったのかの購買行動を表す
4. $Desc$: word2vec を用いて出力した, 50 次元で表現された各商品の説明文; 特定のタイプの商品を重点的に閲覧したのか, 幅広く様々なタイプの商品を閲覧したのかの購買行動を表す
5. $Duration$: セッションにおける商品閲覧時間; 表現している購買行動は (1) と同様
6. $Hour$: セッションが開始した時刻; 朝, 昼, もしくは夜中のどの時間帯に商品を閲覧し, 購買するのかの消費者の特性を表す
7. N_c : セッションでのクリック回数 (PV 数); 対象とするサイトでどれだけ活発に購買行動をとっていたのかを示す
8. $Price$: 各セッションで閲覧, 購買された商品の平均金額; 高め, もしくは安めの商材を好んで閲覧, 購買していたのかの消費者の特性を表す
9. $Views_{24h}$: 過去 24 時間で全消費者が PV を行った回数; 他の消費者が集まるタイミングで同じく商品の閲覧, 購買を行っていたのか, あるいはセール期間外などの閑散期でそれら行動をとっていたのかを示す
10. $Views_{week}$: 先週に全消費者が PV を行った回数; 表現している購買行動は (9) と同様

ここで注意が必要は, 特徴量 $Price$ についてである. この特徴量は Vieira の研究において “average items price of purchase in a session” と説明されているが, これは購買有無を予測するのにセッション中の商品の平均購買金額を説明変数として用いていることになり, Leakage を起こしている. したがって本研究では, この特徴量は各セッションで消費者が閲覧, 購買された商品の平均金額として解釈し, 購買行動の指標とする.

3.2.2 Esmeli et al. (2020) のモデル

次に Esmeli et al. の研究は, 使用する特徴量の数を制限する, 閲覧された商品数が 10 未満のデータを除外したデータセットを用いる, オーバーサンプリングやアンダーサンプリングを適用する, またはそのどちらも行わない場合などで機械学習モデルの精度に差異が生じるかどうかを検証している. その際, 以下の特徴量を使用することで, 消費者の購買行動およびその特性をモデルで表現している.

1. $Total Viewed Item$: 消費者がセッション中に閲覧した商品の数; 商品に対する消費者の購買意図, サイト内でどれだけ活発に購買行動をとっていたのかを示す
2. $Total Unique Items$: 消費者がセッション中に閲覧したユニークな商品の数; 消費者の関心の幅を示す (同じ商品を何度も閲覧している場合, その商品に対する興味があると考えられる)
3. $Total Session Duration$: 消費者がセッションに費やす時間 (滞在時間); 滞在時間の長さで熟慮している購買行動, 短さで突発的, もしくは計画的な購買行動を表す. なお, 滞在時間と商品に対する消費者の興味には正の相関があることが Bogina and Kuflik (2017) [32] によって示されている.

4. *Click Count* : セッション中にクリックされた商品の数；セッション中の消費者の購買意図，特定の商品をどれだけ重点的に閲覧していたかを示す．短い期間に多くの商品をクリックした消費者は，そのセッションで商品を購入するのではなく，ブラウジングの意図を持っていると考えられる（Esmeli et al. の研究では “Click Rate” という変数名であったが，その詳細から名前を変更した）．
5. *Max Popularity* : セッション中に閲覧された商品の最高人気率；人気のある商品，流行とされる商品を閲覧していたかどうかを示す（以下に詳細を記載）
6. *Min Popularity* : セッション中に閲覧された商品の最低人気率；不人気な商品，ニッチな商品を閲覧していたかを示す（以下に詳細を記載）
7. *Duration Spent on a Product* : セッション中の商品閲覧時間；商品に費やす時間の長さで，当該商品に対する消費者の関心度合いを示す．Bogina and Kuflik（2017） [32] によって消費者が商品に費やす時間が長いほどその商品に対する商品の関心度が高いことが分かっているため，当該変数が用いられている．
8. *Unique Categories* : セッション中に消費者が閲覧した商品カテゴリーの数；消費者の興味の幅，購買意図の変化を示す
9. *Hour* : セッションが開始した時刻；朝，昼，もしくは夜中のどの時間帯にサイトにアクセスするのかの消費者の特性を示す
10. *Day of the week* : セッションが開始した曜日；特定のどの曜日にサイトにアクセスするのかの消費者の特性を示す
11. *Weekend* : セッションが開始したのが週末か否か；週末にサイトにアクセスをするのか否かといった消費者の特性を示す
12. *Day of the Year* : セッションが開始した日が年の初めから数えて何日目か；特定の季節にサイトにアクセスするかの消費者の特性を示す

上記で定義されている 5. と 6. の Popularity に関しては，3.1 で述べた通り，Mokryn et al.（2019） [5] における $TD_i^n(t)$ に該当するものである．すなわち，Max Popularity は消費者がセッション中に閲覧した商品の中で最も Popularity が高い値が記録され，Min Popularity はその逆である． $TD_i^n(t)$ は過去 n 日間の商品 i の t 時点におけるトレンド性を表しており，次の式で定義される．

$$\begin{aligned}
 TD_i^n(t) &= \frac{\sum_{j=t-n-1}^{t-1} PS(j, i)}{P_i^n(t)} \\
 &= \frac{\# \text{ of buying sessions product } i \text{ was viewed in during the preceding } n \text{ days}}{\# \text{ of overall sessions product } i \text{ was viewed in during the preceding } n \text{ days}} \quad (3.1)
 \end{aligned}$$

上式より，特定の時点 t 以前の n 日間において商品 i が購買されたセッション数を，その商品 i が閲覧されたセッション数で割った値が $TD_i^n(t)$ となる．なお，本研究で対象としているサイトは日用品等の購買周期が短いものを扱っているわけではないということと，使用するデータ期間の短さから， n は設定せずに，特定の消費者が対象とするセッションに至るまでの $TD_i(t)$ で Popularity を測定する．

3.2.3 Vieira (2016) と Esmeli et al. (2020) のモデルで考慮されていない消費者の購買行動、その限界

3.2.1 節および 3.2.2 節において、本研究で比較対象とするモデルが使用する特徴量と、それら特徴量がどのような消費者の購買行動を映し出しているのかを述べた。本節では、それらモデルで考慮されていない消費者の購買行動と、それによってどのような問題が生じるのかについて論じる。

まず、Vieira と Esmeli et al. のモデルで考慮されていない消費者の購買行動、その観点を以下に記載する。

1. 消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか
2. 消費者の過去のサイト訪問経験
3. 消費者が購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか

これら要素はいずれも消費者のセッション中での購買に影響を与えると考えられるため、購買意思を正確に特定する上で重要な要素である。その理由について以下で説明する。まず 1. は、図 1.2 における消費者 X_1 と X_2 の購買行動を同一視してよいのか、という問いが存在する。先行研究では、セッション中における消費者の商品閲覧時間や滞在時間をモデルに組み込むことによって、消費者の迷いや熟慮といった購買行動を捉えている。しかし、同じ商品閲覧時間を有している消費者であっても、商品 A, B, C にそれぞれ 5 分ずつ閲覧時間を費やしている X_1 と、商品 A に 11 分、商品 B と C に 2 分ずつ閲覧時間を費やしている X_2 の購買行動は異なると考えられる。具体的に、 X_1 は商品 A, B, C のどれを買うかに関して迷っている状態と推察されるが、 X_2 は既に商品 A を買うことを決めており、念のため商品 B と C も見ておくか、という心情のもとそのような購買行動を示していると考えられる。このような観点から、1 つの商品を重点的に閲覧している X_2 は、様々な商品を均等に閲覧していた X_1 よりも購買に至りやすいことが予想される。ゆえに、この要素は消費者の商品に対する関心の深さを表現しており、セッション中の購買に影響を与える要因となり得る。

次に 2. は、過去サイトに何度も訪問していた、もしくは既にそのサイトで商品を何度も購買していた消費者は、初めてそのサイトに訪れる消費者よりも購買に移りやすいのではないか、という問いを背景にしている。図 1.3 に示されるように、既存のモデルでは 1 月 1 日から 1 月 31 日にかけて行われたサイト訪問を無視し、2 月 4 日時点の情報のみを用いて購買を予測している。消費者が商品の比較検討を行う際には何度もサイトに訪問することが予想され、また、購入に応じてポイントが付与されるサイトにおいては、過去何度もそのサイトで購買を行った消費者は再度同じサイトでの購買に至りやすいと考えられる。すなわち、このような観点を考慮しないモデルは、消費者の購買意思を正確に特定する上で不十分であると考えられる。なお、佐藤・朝日 (2013) [33] が直近 1 週間のサイト訪問回数の合計が多いほど消費者は再度訪問する傾向にあり、また、Weisberg et al. (2011) [34] が消費者の過去の購買が将来の購買意向にプラスの影響を与えると述べていることから、このような消費者の過去のサイトへのアクセス経験・購買経験は消費者のセッション中の購買に影響を与える要因たりうると考えられる。

そして 3. は、図 1.4 における消費者 X_5 と X_6 の購買行動を同じものだと考えてよいのか、という問いになる。1. において、消費者がセッション中に各商品にどれだけ幅広く時間を割いているのかを捉えているが、任意のセッションにおいて特定の商品を重点的に閲覧していたとしても、別のセッションで異なる商品に同様の行動を繰り返していた場合には、購買に至りにくいと考えられる。図 1.4 において、消費者 X_5 と X_6 は

どちらも任意のセッションで商品閲覧時間に偏りがあるものの、セッション全体では、消費者 X_5 が商品 A から H を幅広く閲覧しているのに対し、消費者 X_6 は商品 A と B のみを閲覧している。すなわち、両者はセッション全体で 51 分の商品閲覧時間を費やしているものの、その購買行動には明確に異なる。ここで、例えば消費者 X_5 は Moe (2003) [16] で言及されている、購買よりも知識を得ることに重点を置いている消費者 (Knowledge building) や、商品の閲覧が特定の商品カテゴリーに集中しておらず、購買目標もない消費者 (Hedonic browsing) である可能性があるため、3. の観点をモデルに取り入れることは、そのような消費者自身の特性をモデル化するといった点で重要であると考えられる。

第 4 章 本研究の提案

本章では、本研究の提案として以降の 5 章から 8 章にかけてのモデル化の方針とその目的を述べる。それにあたり、再度本研究で構築するセッション中の購買予測モデルを詳述し、それを構築している従来研究とその限界を整理する。

4.1 セッション中の購買予測モデル

セッションは、データベース上で一意に識別される ID (SID) によって管理されているため、セッション中の購買予測モデルは、SID が記録されるタイミングから特定のタイミングまでの消費者の購買を予測するモデルとなる。なお、この特定のタイミングはモデルの使用者が任意に決定できることを 1 章で述べた。本モデルを活用するためには、まず一定数の消費者がサイトにアクセスした際に記録されたデータを SID ごとに整理し、モデルに学習させてパラメータを固定する必要がある。その後、新たにサイトを訪問した消費者に対してモデルを適用し、セッション中の特定のタイミングでの購買有無を予測することが可能となる。なお、このモデル出力は 0 または 1 の 2 値のみであるため、その出力を確認してどのようなマーケティング施策を実施するかを検討することが求められる。

セッション中の購買予測モデルに関する従来研究はいくつか存在するが、それらモデルで考慮されていない観点・消費者の購買行動としては、“消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか”と“消費者の過去のサイト訪問経験”，また，“消費者は購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか”の 3 つがある。1 章および 3 章で述べた通り、これらの観点を考慮したモデルを構築することは、消費者の購買意思を正確に特定するために不可欠である。

4.2 モデル化の方針

以降の 5 章から 8 章にかけてのモデル化の方針とその目的を述べるにあたり、その前提として、ここで言及する“モデル化”が何を示しているのかを説明する。「モデルとは、現実からの一つの抽象であり、仮定の集合がモデルを形成する」[35]とされているため、本研究における“モデル化”は、耐久消費財および嗜好品を扱う EC サイト上の消費者の購買行動という現実を、抽象化して表現するという営みそのものを意味している。

本研究では、Vieira (2017) [11] および Esmeli et al. (2021) [4] によって構築されたモデルで表現されていた消費者の購買行動およびそれを表す変数を基盤に、より詳細な消費者の購買行動をモデル反映すべく、新たな変数を加えたモデルを構築する。そして、そのモデルが従来のモデルよりも予測精度が高い場合に、追加した新たな変数が消費者の購買意思を正確に特定するために寄与していたと結論づける。

それにあたり、まず5章では、“消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか”という観点から、消費者の各商品に対する関心の深さを表す指標を作成し、これを加味したモデル化を行う。ここでは、新美・星野(2017) [17] が提唱する“多様性”の概念を“セッション中の多様性”という形で拡張し、モデル化を行なっている Fukui et al. (2022) [18] の研究を詳述する。具体的には、新美・星野が顧客行動の多様さを表すために使用する“*HHI* (ハフィンダール・ハーシュマン指数)”を *SHHI* (Session-HHI) として拡張して、“セッション中に消費者が閲覧した商品に対する時間の幅広さ”を表現する。なお、5章で定義するセッション中の多様性は、後の7章で定義する多様性と区別するため、“瞬間的な多様さ”と表現する。また、本章では予測精度を比較するためのデータの前処理や手法についても述べ、それを基に検証を行う。この際に採用した検証方法等は、以降の章でも一貫して使用する。

6章では、5章までのモデルでは考慮されていない消費者の購買行動である、“消費者の過去のサイト訪問経験”を示す指標を作成し、これを加味したモデル化を行う。具体的には、“累積購買回数”と“購買に至るまでの平均訪問回数”の2つの特徴量で消費者のサイト訪問経験を表現し、検証を行う。ここで注意すべき点は、消費者の訪問経験を変数化するにあたり、データセットの開始時点近くのセッションデータには消費者の過去の訪問や購買履歴を十分に反映されていない可能性があることである。そのため、以降の章でも一貫して適用する前処理として、消費者の平均購買周期を分析し、その周期に応じて初期時点のデータセットを除外する処理が必要となる。

7章では、5章までのモデルに未だ反映されていない消費者の購買行動である、“消費者は購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか”といった消費者自身の特性を示す指標を作成し、これを加味したモデル化を行う。ここでは5章と同様に、新美・星野(2017) [17] が提唱する“多様性”の概念から、消費者の累積的な多様さを示す特徴量を新たに作成する。具体的には、*HHI* を拡張して、*CHHI* (Cumulative-HHI) で“累積的な多様さ”を表現する。そして、それを用いてモデルを構築している Fukui & Tabata (2024) [24] を詳述する。留意点として、そのようにして作成された指標は、たとえば“いつもじっくり商品を見ていくが、購買に対する決断力が低い”消費者であったり、単に“情報収集をしているだけ”といった消費者の特性として表現されているため、消費者属性として機能する。

8章では、6章と7章のモデルで捉えている観点、すなわち、消費者のサイト訪問経験をモデルで捉える上での留意点として、消費者の購買経験に対する忘却を考慮したモデル化を行う。購買からの日数が経つにつれ、当時の消費者の感情や満足度の記憶は薄れていくため、当該サイトでの現在の購買行動への影響は減衰していくと推察される。したがってこのような観点をモデルに反映させない場合、過去の購買行動の重要性を一律に扱うことで現実に反したモデル構築となってしまうため、結果として消費者の購買意思を正確に判定することができないモデルが構築されることが考えられる。ゆえに、8章では“当該サイトに対する印象が薄れることによる購買意思の低減・忘却”という、より現実的な消費者の購買行動のモデル化を試みている Fukui & Tabata (2024) [25] の研究を詳述する。彼らは具体的に、正味現在価値の考え方を用いて忘却係数を定義し、それに6章で提案した“累積購買回数”を掛け合わせることで、消費者の過去の購買経験が徐々に減衰する様子を捉えている。

本研究では5章から8章にかけて段階的に消費者の購買行動を加味したモデルを構築しているが、最終的にすべての要素を考慮した8章のモデルのみ検証を行えば十分ではないか、という疑問が生じるのは当然であ

ろう。しかし、各章で段階的にモデルを構築・評価することで、各特徴量の役割とその限界についての議論が可能になり、また、現実の消費者の購買行動に基づかない特徴量を追加することによる過学習のリスクも避けることができるため、各章で個別にモデルを評価することは重要なステップであると考えられる。また、単にモデルに取り入れる変数の数を増やせば精度が上昇するとも考えられるが、現実の消費者の購買行動に基づかない変数の追加は、モデルが訓練データに過度に適応し、汎化性能が低下するため、かえって精度が下がる可能性もある。したがって、モデルに追加する変数の評価は慎重に行う必要がある。

実際のモデル構築においては、多層構造を通じて変数間の複雑な関係を抽出する能力を持つ Feed-Forward Neural Networks (FFNN) を使用する。3.2.1 節で述べたように、Vieira[11] の研究では、ロジスティック回帰およびランダムフォレストと比較して Deep Learning を用いた予測精度の比較が行われ、結果として Deep Learning が最も高い精度を示したことが確認されている。このような理由から本研究でも消費者の購買行動をより正確に捉えるために Deep Learning の代表的なモデルである FFNN を採用する。しかし、FFNN は大規模なデータにおいて効力を発揮するものの、本研究で使ったデータは小規模であるため、複雑なモデルを使用することで生じる過学習が危惧される。そこで、本研究では Lee et al. (2021) [37] によってオンラインにおける消費者行動を予測するのに適した機械学習手法とされている XGBoost (eXtreme Gradient Boosting) [36] を用いた精度比較も行うこととする。XGBoost は Tanvir et al. (2023) [15] でも他の機械学習手法と比較して高い分類性能が示されており、比較検証において有効な手法であると考えられる。

第 5 章 瞬間的な多様さを考慮したモデル

本章から 8 章にかけて、提案内容を検証していく。各章の流れとして、まず 3 章で挙げた既存の研究で考慮されていない消費者の購買行動および、それによってどのような問題が生じるかを論じる。次に、その購買行動を捉えるための新たな変数を作成し、モデルの説明変数として導入する。そして、新たな変数を取り入れたモデルと既存のモデルの予測精度を比較し、前者が高い精度を示す場合には、その新たな変数が消費者の購買意思の正確な特定に寄与しているとして、その有用性を評価する。

5.1 セッション中における消費者の行動の多様さ

本章のモデルで表現する消費者の購買行動は、“セッション中における消費者の行動の多様さ”であり、これは、図 1.2 における消費者 X_1 と X_2 の購買行動を同じものだと考えてよいのかという問いかけに基づいている。すなわち、消費者 X_2 は特定の商品 A を重点的に閲覧しているため、商品 A, B, C を均等に閲覧している消費者 X_1 よりも購買に至る可能性が高いと考えられる。この観点は、セッション中における消費者の関心の深さや興味の幅として考えることができるので、このような購買行動を捉えることができれば、セッション中の消費者の購買意思をより正確に特定できることが期待される。

5.2 新美・星野（2017）の研究

5.1 で述べている内容に類似した概念を提案している研究として、新美・星野（2017）[17] がある。彼らは、「顧客が閲覧／購買した商品ジャンルの幅広さや特定のジャンルへの依存度を見ることによる、ある行動の「多様さ」を定量化した変数」を顧客行動の多様性として定義し、これを用いて顧客の将来の購買回数を予測するモデルを構築した結果、予測精度が向上したことを示している。その際、多様性を数値化するために、市場の寡占状態の度合いを示す経済指標である以下 (5.1) の“ HHI （ハフィンダール・ハーシュマン指数）”を使用している。

$$HHI_k = \sum_{i=1}^{n_k} s_i^2 \quad (5.1)$$

この指標は、ある顧客 k が購買した n_k 個の商品カテゴリと当該顧客の購買全体に占めるそのカテゴリの割合 s_i を用いて、一定期間内に消費者が取った行動の幅を 0 から 1 の範囲で表現しており、値が 1 に近いほど特定の商品カテゴリを閲覧／購買していることを示している。例として表 5.1 では、顧客 A と顧客 B はアクセス総数が同じものの、どのような商品ジャンルにアクセスしているかが異なるため、 HHI にその違いが明確に表れている。たとえば顧客 B の HHI は $64^2 + 16^2 + 12^2 + 8^2 = 4560$ となり、この値を 10,000 で除する

表 5.1 新美・星野（2017）[17] の「表 1：顧客が閲覧した商品カテゴリの集計データ例」を抜粋

商品ジャンル	顧客 A	顧客 B
アクセス総数	100 回	100 回
食器	25.0%	64.0%
収納用品	25.0%	16.0%
旅行用品	25.0%	12.0%
寝具	25.0%	8.0%
HHI	2500.0	4560.0

ことで 0 から 1 の範囲に正規化される。

新美・星野が提唱する多様性変数（ HHI ）は、一定期間内での消費者行動の多様さを示している。一方、本研究ではセッション中の消費者の購買予測に合わせるため、新美・星野の研究で提示されている HHI を基に、“セッション中の消費者の多様性”を示す新たに変数を作成し、本章ではそれを“瞬間的な多様性”と呼ぶ。

5.3 Fukui et al.（2022）のモデル

前節で述べた変数をモデルに用いている研究として、Fukui et al.（2022）[18] がある。彼らは、“消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか”という、消費者の各商品に対する関心の深さを示す変数を、新美・星野（2017）[17] が提唱する“多様性”の概念を基に“セッション中の多様性”という形で拡張し、モデル化を行なっている。具体的には、新美・星野が顧客行動の多様さを変数化するにあたり使用している“ HHI （ハフィンダール・ハーシュマン指数）”を $SHHI$ （Session- HHI ）として拡張し、“セッション中に消費者が閲覧した商品に対する時間の幅広さ”を (5.2) によって表現している。

$$SHHI_{kj} = \sum_{i=1}^{n_{kj}} s_{ij}^2 \quad (5.2)$$

ここで、 n_{kj} はセッション j 中に消費者 k が閲覧した商品カテゴリの数を、 s_{ij} は当該セッションの商品閲覧時間全体に占める各商品カテゴリ i の閲覧時間の比率を示している。この変数は、図 1.2 における消費者 X_1 のようにセッション中における閲覧時間のばらつきが小さい購買行動には小さな値を、逆に消費者 X_2 のように閲覧時間のばらつきが大きい購買行動には大きな値を取る。なお、消費者がセッション中に 1 つの商品しか閲覧していない場合には、 $SHHI$ は 1 となる。

5.4 検証

新たに作成した変数となる $SHHI$ の有用性を検証するため、Vieira（2017）[11] および Esmeli et al.（2021）[4] のモデルとの予測精度の比較検証を行う。本検証における手法と方法は第 4 章でも述べた通り、以降の章においても一貫して適用するものとする。

5.4.1 使用するデータの概要・前処理

使用するデータの概要として、手元に存在するデータの項目を以下に記す。

- セッション ID：セッションごとに一意な ID
- セッション開始時間：セッションが開始した時間（yyyy/mm/dd hh:mm:ss 形式）
- セッション終了時間：セッションが終了した時間（yyyy/mm/dd hh:mm:ss 形式）
- 商品閲覧時間：セッション中に消費者が商品を閲覧した時間（秒）
- セッション PV：セッション中の PV 数
- 商品のジャンル：セッション中に消費者が閲覧した商品のジャンル（5 つ）
- 金額：セッション中に消費者が閲覧した商品の金額
- ユーザー ID：ユーザーごとに一意な ID
- CV：セッション中の購買（購買がなされた場合に 1，そうでない場合に 0 を取る）

データは嗜好品（耐久消費財）を扱う EC サイト A 店の 2010 年 7 月 1 日から 2011 年 6 月 28 日までのものであり、A 店は当該嗜好品に関する国内最大級のポータルサイトを運営し、関連商品の販売やサービスの提供を行っている。データはセッション ID ごとに整理され、各セッションにおけるユーザーの行動履歴が記録されているが、個人が特定できる情報は含まれていない。また、長時間の非アクティブ状態が続いた場合にセッションが終了したと見なされ、購買の定義はセッション中に実際に商品購入が完了した場合のみとする。すなわち、買い物かごに商品を入れただけでは購買とみなされず、決済が完了し特定の購入完了ページに遷移した場合にのみ購買が成立したとみなされる。

ここで、本研究で扱ったデータは、cookie ベースでの個人ごとのサイト内行動を把握したものと扱われているため、2018 年 5 月 25 日に施行された GDPR（General Data Protection Regulation：一般データ保護規則）の環境下では取得が困難となっている。したがって現行の Web マーケティング環境下では、このようなデータを基にしたモデルは構築は難しいと考えられるが、[38]によると、GDPR の適用範囲は以下のように定められており、本研究のデータ提供企業はそれにあたらない。また、これに関しては内閣府の“個人情報保護委員会における個人情報の保護に関する法律についてのガイドライン（通則編）”[19] および [23] に直接問い合わせも行ったところ、問題ないとの回答を拝受したため、以下にその内容を記す。

GDPR は、EU 域内でビジネスを行い、EU 域内にいる個人の個人データ^{*1}を取得する中小・零細企業を含む日本企業に対しても、幅広く適用されます。

GDPR の適用範囲

- ① EU 域内に子会社や支店等の拠点^{*2}を有している場合
- ① EU 域内に拠点を有しておらず、以下のいずれかに該当する場合
 - (1) EU 域内にいる個人に対して商品やサービスを提供している^{*3}場合

^{*1} 「個人データ」とは、「識別された又は識別され得る自然人に関するあらゆる情報」を意味します。（例：氏名、識別番号、位置データ、オンライン識別子（IP アドレス、クッキー識別子）等）

^{*2} EU に複数の拠点がある場合、その主たる拠がある EU 加盟国の監督当局の監督を受ける等、執行の一貫性も図っています。

^{*3} どのような言語や通貨が使用されているか、EU 域内の個人に関する言及があるか、商品やサービスの提供範囲等を考慮して判断

(2) EU 域内の個人の行動を監視する場合 (例：アプリやウェブサイトにおける個人の行動履歴や購買履歴の追跡等)

まず、研究で使用したデータが個人情報に当たるか否か、すなわち現在の Web マーケティング環境下でも同等のデータの取得が可能かどうかは、本研究で使用するデータである“消費者のサイト内での滞在時間”、“ページを遷移した回数 (PV)”、“閲覧した商品ジャンル”、“セッション ID”および“UserID”は、個人情報の保護に関する法律についてのガイドライン (通則編) [19] の“2-8 個人関連情報 (法第 2 条第 7 項関係)”に当たるものであり、サイトにアクセスする消費者の同意や、消費者への通知が必要かどうかの制限を受けることはないとの回答をいただいた。また、セッション ID や UserID も、これらを他の何らかのデータと結合することによって、その ID を保持する消費者を一意に識別することができる場合には個人情報にあたるが、これ単体では個人情報に当たらないものであるとの回答も拝受した。すなわち、いわゆる年齢や性別、名前などの個人を識別し得るデータにならない限り、個人情報にはならないとのことである。なお、各社が独自に cookie を導入していた際には、オプトインによりデータに多くの欠測が生じると考えられるが、これに関しては“2-8 個人関連情報 (法第 2 条第 7 項関係)”の事例 1 より、「Cookie 等の端末識別子を通じて収集された、ある個人のウェブサイトの閲覧履歴」は“個人情報”ではなく“個人関連情報”として扱われるため、特段制限を受けることはない。また、2022 年 6 月に公布され、2023 年 6 月に施行された電気通信事業法の改正で新たに新設された“外部送信規律”[20] も確認したが、これに関しても Cookie に特に制限を与えるものではなかった。“総務省の外部送信規律 FAQ”[21] における「問 1-1 : 外部送信規律の概要を教えてください。」を確認すると、Cookie に関するデータの取得に関してはデータ主体本人の同意取得又はオプトアウト措置の提供等の義務を課しているように見えるが、この“外部送信規律”に従わなければならない事業者は限定されている。これは、[21] における問 1-8 および問 1-9 にその内容が記載されているが、今回のデータ提供元はそれに該当しない。

問 1-8 : 外部送信規律に従わなければならない事業者はどのような事業者ですか。答 : 電気通信事業者又は第三号事業を営む者 (いずれも電気通信事業を営む者) で、「利用者の利益に及ぼす影響が少なくない電気通信役務」を提供している電気通信事業者です。「利用者の利益に及ぼす影響が少なくない電気通信役務」については、「1-9」に記載しているとおりです。なお、「電気通信事業 (電気通信事業法 (以下「法」という。) 第 2 条第 4 号)」を営んでいない場合は、法の適用を受けないので、仮に情報の外部送信が行われていたとしても、外部送信規律の対象にはなりません。

問 1-9 : 「利用者の利益に及ぼす影響が少なくない電気通信役務」とは、どのような電気通信役務を指していますか。(法第 27 条の 12 柱書) 答 : 利用者の利益に及ぼす影響が少なくない電気通信役務」は、以下のいずれかの電気通信役務のうち、ブラウザやアプリケーションを通じて提供されているものが該当します (電気通信事業法施行規則 (以下「規則」という。) 第 22 条の 2 の 27)。(1) 利用者間のメッセージ媒介等 (同条第 1 号) (2) SNS, 電子掲示板, 動画共有サービス, オンラインショッピングモール等 (同条第 2 号) (3) オンライン検索サービス (同条第 3 号) (4) ニュース配信, 気象情報配信, 動画配信, 地図等の各種情報のオンライン提供 (同条第 4 号)

され、単に英語のウェブサイトを載せているだけでは適用されません。

上記、問 1-9 の (2) にオンラインショッピングモールとの記載があるが、当該研究で使用しているデータはオンラインショッピングモールではなく独自サイトであるため、外部送信規律の規制対象とならない。これに関しては以下に記す [21] の問 1-12 ～ 問 1-14 にも記載がなされている。

問 1-12 : 当社は家電小売業者です。実店舗における商品販売が主ですが、自社ウェブサイト上でも商品販売を行っています。当社の業務に、外部送信規律は適用されますか。(法第 27 条の 12 柱書) 答 : 外部送信規律は、「電気通信事業者又は第三号事業を営む者」に適用されるため(法第 27 条の 12 柱書)、「電気通信事業」を営んでいない場合は、規律対象となりません。小売業者がウェブサイトを開設して商品販売を行う場合は、本来業務である小売業の遂行の手段として電気通信を用いているに過ぎず、自己の需要のために電気通信サービスを提供しているため、「電気通信事業」に該当せず、外部送信規律も適用されません。

問 1-13 : 当社は家電小売業者です。実店舗における商品販売は行っておらず、専ら自社ウェブサイト上で商品販売を行っています。当社の業務に、外部送信規律は適用されますか。(法第 27 条の 12 柱書) 答 : 実店舗における商品販売を行っていない場合であっても、本来業務である小売業の遂行の手段として電気通信を用いているに過ぎないことには変わりはないため、Q1-12 のケースと同様、外部送信規律は適用されません。

問 1-14 : 当社は家電小売業者ですが、家電小売業とともに、オンラインショッピングモールも運営しています。当社の業務に、外部送信規律は適用されますか。(法第 27 条の 12 柱書) 答 : オンラインショッピングモールのような、インターネット経由で複数の店舗でネットショッピングを行うことができる又は複数の出品者の商品等を購入できる「場」を提供するサービスは「電気通信事業」に該当し、さらに、「利用者の利益に及ぼす影響が少なくない電気通信役務」にも該当しますので(規則第 22 条の 2 の 27 第 2 号)、外部送信規律が適用されます。なお、ここでいう「複数の店舗」については、当該店舗がグループ企業等限定的なものであっても、同様です。

なお、総務省の電気通信事業参入マニュアル [22] も確認したところ、「オンラインニュースや映像配信など、自社の商品やサービス自体がインターネット経由で提供される場合に、その提供(販売等)のために HP を開設するもの」が電気通信事業に該当するとの記述がある。しかし、これは問 1-12 から問 1-14 がインターネット経由で「物」を営んでいることを想定して記載がなされているのに対し、上記はニュースや映像配信などの「情報」を営んでいることを想定した記載となっているため、これを踏まえても本研究で対象としたサイトのデータは外部送信規律に従わなければならない事業者ではないと言える、すなわち将来的に消費者の同意の取得やオプトアウト措置によって、本研究で使用了データが取得不可能になる可能性はあるものの、2024 年現在は問題ないと判断される。

次に一般データ保護規則(GDPR)に今回の研究が抵触するかに関して、[38] よりその適用範囲外であることを確認したが、[23] に関しても個人情報保護委員会に確認を行った。具体的に、第 4 条の定義(1)に記載がなされている“personal data”が個人情報保護委員会が言及している“個人情報”に当たるものなのかどうかを当該委員会に問い合わせた。結果として、GDPR の規制の対象となっている“personal data”は、[19]

の“個人データ”^{*4}にあたるものであり、個人関連情報に関する規制を対象としているものではなかったため、2024 年現在のマーケティング環境下でも個人関連情報であれば特に制限を受けることなく取得が可能とのことだった（GDPR 第 4 条の定義 (1) で言及されているのが“個人関連情報”であれば本研究で使用したデータは GDPR の影響を受けると考えられたが、そうではなかった）。

そして、データ取扱事業者が個人関連情報を第三者に提供する場合はいかなる制限を受けるのかどうかについての確認もしたところ、[19] の 3-6 個人データの第三者への提供の法第 27 条（第 1 項）に以下の記載がなされていた。

法第 27 条（第 1 項）

1 個人情報取扱事業者は、次に掲げる場合を除くほか、あらかじめ本人の同意を得ないで、個人データを第三者に提供してはならない。

- (1) 法令に基づく場合
- (2) 人の生命、身体又は財産の保護のために必要がある場合であって、本人の同意を得ることが困難であるとき。
- (3) 公衆衛生の向上又は児童の健全な育成の推進のために特に必要がある場合であって、本人の同意を得ることが困難であるとき。
- (4) 国の機関若しくは地方公共団体又はその委託を受けた者が法令の定める事務を遂行することに対して協力する必要がある場合であって、本人の同意を得ることにより当該事務の遂行に支障を及ぼすおそれがあるとき。
- (5) 当該個人情報取扱事業者が学術研究機関等である場合であって、当該個人データの提供が学術研究の成果の公表又は教授のためやむを得ないとき（個人の権利利益を不当に侵害するおそれがある場合を除く。）。
- (6) 当該個人情報取扱事業者が学術研究機関等である場合であって、当該個人データを学術研究目的で提供する必要があるとき（当該個人データを提供する目的の一部が学術研究目的である場合を含み、個人の権利利益を不当に侵害するおそれがある場合を除く。）（当該個人情報取扱事業者と当該第三者が共同して学術研究を行う場合に限る。）。
- (7) 当該第三者が学術研究機関等である場合であって、当該第三者が当該個人データを学術研究目的で取り扱う必要があるとき（当該個人データを取り扱う目的の一部が学術研究目的である場合を含み、個人の権利利益を不当に侵害するおそれがある場合を除く。）。

上記の (7) より、当該第三者が学術研究機関等である場合であって、当該第三者が当該個人データを学術研究目的で取り扱う必要があるときには、個人情報取扱事業者はあらかじめ本人の同意を得ないで第三者への提供が可能である。また、研究機関に限らず、データ提供元が第三者に個人関連情報を送付する際には、その第三者がなにがしかのデータと結合することで、その個人関連情報を個人情報へと変貌させない限り、こちらも制限を受けることはないとのこと確認した。なお、これは“個人データ（個人情報）”の本人同意に関する

^{*4} [19] の法第 16 条（第 3 項）より、「個人データ」とは、個人情報データベース等を構成する個人情報を指す

ものであるが、個人関連情報を第三者に提供する場合でも法第 27 条（第 1 項）は適用されるとのことだった。

以上より、データ提供企業が GDPR の適用対象および Cookie 規制と称される外部送信規律の対象となっていないことと、本研究で使用するデータが個人関連情報にあたるものであり、2024 年現在は特段の制限を受けないことから、本研究で扱ったデータは個人情報保護関連の規則に抵触する可能性は低いと考えられる。したがって以降、本研究ではデータの使用可否は考えずに、モデルの構築、議論を展開する。

上記データ項目を基に、本章で提案した *SHHI* および以降の章で定義する変数、さらに Vieira (2017) と Esmeli et al. (2021) のモデルに使用されている変数を作成する。ただし、上記データ項目にはセッション中に消費者が閲覧した商品の説明文が存在しないため、Vieira が用いていた変数の 1 つである “4. *Desc*” の変数を作成することができない。そこで本研究では、“商品のジャンル”で “4. *Desc*” を代替する。この変数は消費者がセッション中に閲覧した商品ジャンルに 1、閲覧しなかった商品ジャンルに 0 を取るものであり、消費者がどのタイプの商品を閲覧したかの購買行動を示すことができるという点で、“4. *Desc*” に代わる変数として機能すると考えられる。

データに対する前処理として、まず、セッション開始時間と終了時間の差から算出した各セッションの滞在時間が 1 秒以下のデータをすべて削除する。これは、誤クリックによるサイト訪問や、中継ページとして開かれたページ閲覧を除外するためである。この処理により、データの行数は 942,493 行となり、そこからさらにセッション ID で情報を集約したところ、 $n = 71,280$ 件のセッションが得られ、そのうち購買があったセッションは 2,634 件となった。

そして、ダミー変数である “商品のジャンル” とモデルの目的変数となる CV を除き、上記処理を施したデータに対し、平均 0、標準偏差が 1 となるよう標準化を行う。その後、それらデータをシャッフルし、訓練データとテストデータに 6 対 4 の比率で分割し、さらにその訓練データを 6 対 4 の比率で分けて検証データを用意する。なお、[41], p.124-126 より、ダミー変数等の 2 値変数に対しての標準化は行わず、分割されたデータに対し個別に標準化を行わないことで、過学習を避けている。

5.4.2 使用する手法

本研究では不均衡データに対処するための手法として、SMOTENC (Synthetic Minority Over-sampling Technique for Nominal and Continuous) [42] を適用する。SMOTENC は連続量と離散量が混合されたデータセットに対するオーバーサンプリング手法であり、少数クラスのサンプルを複製したり、バランスをとるために新しいサンプルを作成したりする方法である。なお、本 SMOTENC は Tanvir et al. (2023) [15] を参考に、過学習を避けるため訓練データにのみ適用する。

CV を目的変数とした 2 値分類を行うべく、本研究では FFNN と XGBoost を用いる。まず FFNN に関しては、ネットワークの最適化に Batch Normalization、中間層の活性化関数に Relu、勾配降下法に Adam を用いて、ハイパーパラメータの探索には Random Search を用いる。探索するハイパーパラメータは、隠れ層の各ユニット数、学習率、エポック、バッチサイズ、L2 正則化の 5 つであり、モデルの AUC が最も高くなる組み合わせを選定する。XGBoost に関しては、Tanvir et al.[15] を参考に、そのハイパーパラメータとなる max_depth を 2 から 15 の範囲で調整し、最も F1-Score が高くなる値を最終的なモデルとして選択する。

モデルの予測性能を評価する指標としては、Accuracy, Precision, Recall, F1-Score, AUC の 5 つを用い、

加えて Confusion Matrix を作成する．Confusion Matrix は表 5.2 のように示され，AUC 以外の各指標は式 (5.3) から (5.6) のに基づいて算出される．

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.3)$$

$$Precision = \frac{TP}{TP + FP} \quad (5.4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5.5)$$

$$F1-Score = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (5.6)$$

Confusion Matrix 上の値はそれぞれ以下のようにになっており，完全な予測を行ったモデルの Confusion Matrix では TP と TN にのみ値が入り，FN と FP には値が入らない ([41], p.67-p.68)．

- TP (True Positive；真陽性)：予測値を正例として，その予測が正しい場合
- TN (True Negative；真陰性)：予測値を負例として，その予測が正しい場合
- FP (False Positive；偽陽性)：予測値を正例として，その予測が誤りの場合
- FN (False Negative；偽陰性)：予測値を負例として，その予測が誤りの場合

Accuracy は予測が正しい割合 ([41], p.40-41)，Precision は正例と予測したもののうち真の値も正例の割合，Recall は真の値が正例のものうちどの程度を正例の予測として含めることができるかの割合を示す．すなわち，Precision はモデルが予測した購買セッションの中で，実際に購買がなされたセッションを正確に捉える能力であり，Recall は実際に購買がなされたセッションを見逃すことなくモデルが予測する能力を表している．また，Precision と Recall はトレードオフの関係にあり，F1-Score はそれを考慮した指標となっている ([41], p.70-71)．なお，それぞれ 0 から 1 の値をとり，1 に近づくほど予測性能が高いモデルであると言える．上記の評価指標は購買意思の高い消費者を正確に特定する精度に焦点を当てているが，これが可能であれば，その逆となる非購買者を正確に見極めることも可能である．補足として，Accuracy や AUC の値は高くとも，Precision や Recall が低い場合があり，これは正例より負例が多い今回のような不均衡データにおいて発生する．すなわち，Accuracy や AUC が高くなるのはデータ数が大きい負例を正しく予測できている数が多いためであり，肝心の少数の正例を適切に予測できていないがために，Precision や Recall が低くなる．

本研究ではモデルの予測精度の比較に加え，モデルに使用した特徴量の重要度も評価する．これにより，新たに作成した変数が目的変数に与える影響も把握することができる．具体的には，ゲーム理論における Shapley 値のコンセプトを機械学習に応用した特徴量の重要度を測定する手法である SHAP (SHapley

表 5.2 Confusion Matrix

		Predicted	
		Negative	Positive
Actual	Negative	TN	FP
	Positive	FN	TP




図 5.1 An introduction to explainable AI with Shapley values[45] より，抜粋

Additive exPlanations) [43] を用いる。SHAP は予測モデルが検出した目的変数と説明変数間の相関関係を透明化する手法であり，因果関係を説明することはない [44]。SHAP の適用対象となるモデルは，検証により F1-Score が最も高くなった max_depth を用いた XGBoost となり，特徴量となる“商品のジャンル”は，本研究で対象としたサイトに特有のものであるため，SHAP を計算する際には除外する。図 5.1 に SHAP の読み取り例を示す [45]。赤色は特徴量自身の値が大きいことを示し，青はその逆を示している。横軸の“SHAP value (impact on model output)”が正の方向に伸びている特徴量は目的変数にプラスの影響を与え，負の方向に伸びている特徴量はマイナスの影響を与えることを示している。本研究では正の方向に伸びている特徴量はセッション中の購買に与える影響が強く，負の方向に伸びている特徴量はセッション中の非購買に与える影響が強いとして解釈する。また，図 5.1 のプロットにおいては，各特徴量が目的変数に与える影響力の大きい順に上から下に並べられている。

5.4.3 モデルの概要と結果

検証する上で比較対象となるモデルの詳細を表 5.3 に記す。

ここで，Esmeli et al. (2021) [4] のモデルには“Total Viewed Items”と“Click Count”の変数がそれぞれ存在していたが，閲覧は多くの場合クリックを伴い，どちらも消費者のサイト内での活動量を示すと考えられたため，それらは 1 つの指標として統合した。また，探索によって決定された FFNN および XGBoost のハイパーパラメータは表 5.4 と表 5.5 に記している。

各モデルの評価指標の結果を表 5.6 から表 5.9 に記す。なお，以降の章でも同様に，購買確率が 0.5 以上の値を予測値 1 としている。

FFNN では従来のモデルと比較して Precision がわずかに上昇し，Recall は大幅に上昇した。そして XGBoost では，Recall にわずかな上昇が確認された。この結果から，少なくとも本章で提案した“SHHI”を

表 5.3 検証対象となるモデルの詳細 (5 章)

Model	Description (dimension)	Features
Vieira [6]	Vieira Features (10)	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week}
Esmeli et al. [7]	Esmeli et al. Features (11)	Total Viewed Items, Total Unique Items, Total Session Duration, Max Popularity, Min Popularity, Duration Spent on a Product, Unique Categories, Hour, Day of the week, Weekend, Day of the Year
5 章	Vieira Features (10) + SHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI

表 5.4 FFNN のハイパーパラメータ

Model	隠れ層のユニット数	学習率	エポック	バッチサイズ	L2 正則化
Vieira [6]	128, 128, 128 3 層	※ 0.001	40	32	0.0001
Esmeli et al. [7]	128, 128, 128 3 層	※ 0.001	100	128	0.001
5 章	128, 128, 128 3 層	※ 0.001	40	32	0.0001

表 5.5 XGBoost のハイパーパラメータ

	max_depth
Vieira [6]	14
Esmeli et al. [7]	7
5 章	11

モデルに組み込まない理由はないと考えられる．特徴量の重要度を測定するために，SHAP を用いた結果を図 5.2 に示す．

5.4.4 考察

前節の結果より，FFNN および XGBoost のどちらも従来のモデルと比較して Recall が上昇したことから，本章で構築したモデルは実際に購買がなされたセッションを見逃さ図に予測する能力が従来のモデルよりも高いと言える．SHAP の結果からは，まずセッション中のクリック回数を示す N_c が負の方向に青い線を，正の




図 5.2 SHAP による特徴量の重要度の確認

方向に赤い線を伸ばしているため、消費者はセッション中におけるクリック回数が少ないほど購買しにくく、多いほど購買しやすいと言える。次にセッション中の商品閲覧時間を示す *Duration* が負の方向に青い線を伸ばしているため、これは商品閲覧時間が短いほど購買に至りにくいと言える。すなわち、商品の情報収集のみを目的にサイト閲覧をするような消費者は初めから購買する気がないと考えられ、そのような消費者は購買に至りにくいという結果が得られている。また、特定の期間の各商品の CVR を各消費者がそれら商品をセッション中に閲覧した回数で割った値である *C/B* も、 N_c と同じく負の方向に青い線を、正の方向に赤い線を伸ばしている。これは、ニッチな商品を閲覧する消費者は購買に移りにくく、逆に他の消費者がよく買っている商品を閲覧する消費者は購買に至りやすいという傾向を示している。さらに、セッション中の滞在時間を示す *Ds* も、 N_c と同じく負の方向に青い線を、正の方向に赤い線を伸ばしているため、滞在時間が短い消費者は購買に至りにくく、その逆の消費者は購買に至りやすいことが確認された。

表 5.6 【FFNN】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章
Accuracy	0.939	0.890	0.932
Precision	0.265	0.145	0.284
Recall	0.374	0.395	0.547
F1-Score	0.310	0.212	0.374
AUC	0.863	0.780	0.906

表 5.7 【FFNN】各モデルの Confusion Matrix

Vieira		Predicted	
		Negative	Positive
Actual	Negative	26,365	1,093
	Positive	660	394

Esmeli et al.		Predicted	
		Negative	Positive
Actual	Negative	24,951	2,493
	Positive	646	422

5章		Predicted	
		Negative	Positive
Actual	Negative	26,001	1,454
	Positive	479	578

表 5.8 【XGBoost】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章
Accuracy	0.946	0.943	0.943
Precision	0.332	0.316	0.323
Recall	0.458	0.465	0.492
F1-Score	0.385	0.376	0.390
AUC	0.924	0.891	0.923

一方、セッション中の商品閲覧時間である *Duration* は正の方向に赤い線を伸ばしていないため、これは、消費者の商品閲覧時間が長くとも、購買に対して特に影響を与えないということが示唆される。しかし、上記において滞在時間 (*Ds*) が長いほど購買に至りやすいという傾向が確認されているため、ここに相違が発生している。商品を長時間閲覧しているにも関わらず購買に結びつかないケースとしては、商品の詳細を隅々まで閲覧することで、その商品の期待に満たない部分に気づいて購入を躊躇する場合や、他のサイトの別の選択肢と比較するために特定の商品を長時間見ている場合の2つが考えられる。このような観点から、滞在時間の長さはサイトでの購買プロセスを示唆するのに対し、商品の閲覧時間の長さは必ずしもその商品に対する購買意思を反映していないと考えられる。例として、商品閲覧以外に購買に影響を与えうると考えられる要素、サイト上でのプロモーションが購買意思に影響を与えている可能性がある。

提案した指標である *SHHI* に関しては、赤色の線が負の方向に伸びているため、セッション中に各商品にかかる閲覧時間のばらつきが大きい消費者ほど購買しにくい、すなわち、特定の商品を重点的に閲覧している消費者ほど購買しにくいことが確認された。これは直感と反した結果ではあるが、上記で述べたように、当該サイトに訪問して商品を閲覧する消費者は他のサイトの商品と比較検討を行い、最終的にその外部のサイトでの購買に至って自社サイトでの購買に至っていないということが、このような結果を生む要因となっていると考えられる。また、*SHHI* は他の特徴量と比較して消費者のセッション中の購買有無に与える影響が小さいことも確認された。

表 5.9 【XGBoost】各モデルの Confusion Matrix

Vieira		Predicted	
		Negative	Positive
Actual	Negative	26,484	974
	Positive	571	483

Esmeli et al.		Predicted	
		Negative	Positive
Actual	Negative	26,397	1,061
	Positive	564	490

5章		Predicted	
		Negative	Positive
Actual	Negative	26,372	1,086
	Positive	535	519

第 6 章 訪問経験を考慮したモデル

本章では、5 章で構築したモデルで未だ考慮されていない消費者の購買行動である、“消費者の過去のサイト訪問経験”を表現する指標を作成する。そして 5 章と同様、その特徴量を取り入れたモデルと既存のモデルとの予測精度を比較し、前者の予測精度が高い場合に、この新たな要素が消費者の購買意思の特定に寄与していることを示す。

6.1 消費者のサイト訪問経験

上記で挙げた“消費者の過去のサイト訪問経験”をモデルに取り入れるという発想は、過去サイトに何度も訪問していた、あるいは既にそのサイトで商品を何度も購買していた消費者は、初めてそのサイトに訪れる消費者よりも購買に移りやすいのではないか、という疑問が発端となっている。図 1.3 に示されているように、既存のモデルでは 1 月 1 日から 31 日までサイトを訪問し、2 月 4 日に再訪問した消費者の購買を予測する際には、2 月 4 日時点の情報しか考慮されず、それ以前の訪問履歴が無視されてしまう。消費者が商品の比較検討を行う際には何度もサイトに訪問することが予想され、また、購買時にポイントが付与されるサイトでは、過去に複数回購買した消費者は再度同じサイトでの購買に至る可能性が高いと考えられるため、このような観点を持たないモデルは、消費者の購買意思を正確に特定する上で不十分である。佐藤・朝日（2013）[33] は直近 1 週間のサイト訪問回数の合計が多いほど消費者は再度訪問する傾向にあると述べ、Weisberg et al.（2011）[34] も消費者の過去の購買が将来の購買意向にプラスの影響を与えると述べていることから、消費者の過去のサイト訪問および購買経験は消費者のセッション中の購買に影響を与える要因であることがうかがえる。

6.2 提案


ここでは、“消費者の過去のサイト訪問経験”を表す指標として、“累積購買回数”と“購買に至るまでの平均訪問回数”の 2 つの特徴量を用いて、消費者の過去のサイト訪問経験をモデルに反映する。

まず“累積購買回数”は、消費者が特定の時点のサイト訪問に至るまでに何回購買を行なったのかを示す変数であり、消費者 k が現在のセッション S に至るまでに何回購買を行なったのかを示す値として、以下の式 (6.1) で表現される。

$$\text{Cum.buy}_{kS} = \sum_{s=1}^S I_{ks} \quad (6.1)$$

$$\text{where } I_{ks} = \begin{cases} 0 : \text{if not purchased in session } s \\ 1 : \text{if purchased in session } s \end{cases}$$

“購買に至るまでの平均訪問回数”は、消費者 k が、購買が行われたセッション buy_S に至るまでに平均して



	1/1	1/2	1/9	1/14	1/16	2/14	2/15	3/2
Cum_buyが取りうる値	0	0	1	1	1	1	1	2
Ave_sessionが取りうる値	0	0	3	4	5	6	7	4

図 6.1 消費者の過去の経験を示す変数 2 つが取りうる値の例

何回のサイト訪問を行ったのかを示す指標となっており、以下の式 (6.2) で表現される。なお、この変数は Cum_buy が 0 を取る場合には 0 の値をとる。

$$\text{Ave_session}_{k\text{buys}} = \frac{\sum_s^{\text{buys}} 1_{[s \leq \text{buys}]}}{\text{Cum_buy}_{kS}} \quad (6.2)$$

$$\text{where } 1_{[s \leq \text{buys}]} = \begin{cases} 1 : \text{if } s \leq \text{buys} \\ 0 : \text{if } s > \text{buys} \end{cases}$$

それら消費者の過去の経験を示す変数 2 つが取りうる値の例を図 6.1 に記す。一般に購買はセッションの最後
に発生するため、例えば図 6.1 の 1 月 2 日時点のセッションでは、式 (6.1) が取りうる値は 0 となる。Vieira
も $Views_{24h}$ および $Views_{week}$ の変数で過去 24 時間や先週といった特徴量で過去を捉えてはいるものの、そ
れら変数は各消費者が経験を重ねるごとに更新がなされる変数ではないため、本研究との違いはそこにある。
また、彼は本研究で提案した (6.2) とほぼ同様の役割を果たすと考えられる“各消費者の非購買セッション数
の中央値 (S_B)”をモデル化しているが、表 6.1 のように、 S_B はその値の大小によって消費者の購買行動を正
確に捉えることが難しいため、本研究では式 (6.2) によって、より正確な消費者の購買行動を捉える。

なお、消費者の過去の訪問をデータとして保持するにあたり、2023 年の 4 月に Safari 16.4 アップデートに
よって ITP の Cookie 規制が強化され、1st Party Cookie であってもその保持期間が最大 7 日間となったこと
が障害になるように見える。すなわち本章の提案は、1 週間前の消費者の購買記録までしかトラッキングでき
ないという点で厳しいと考えられる。しかし、現状は Web サイトのサーバー（コンテンツサーバー）と計測
システムのサーバー（トラッキングサーバー）を同じ IP レンジ下に配置することで行動データの正確な追跡
が可能であることから、問題ないと考えられる（サーバ間連携（S2S）等の処理）。また、Chrome に関しては
Google が 2024 年の 7 月に 3rd Party Cookie を廃止する方針を撤回しているため、こちらも現時点では Web
サイトのトラッキングに大幅な制限がかかることはない考える。

表 6.1 Vieira が提案する S_B と本研究が提案する Ave_session の違い

	1 月 1 日	1 月 2 日	1 月 9 日	1 月 14 日	1 月 16 日	2 月 14 日	2 月 15 日	3 月 2 日
Cum_buy	0	0	1	1	1	1	1	2
Ave_session	0	0	3	4	5	6	7	4
S_B	1	1	1	1	1	1	2.5	2.5

6.3 検証

6.3.1 モデルの概要と結果

検証する上で比較対象となるモデルの詳細を表 6.2 に記す。

表 6.2 検証対象となるモデルの詳細 (6 章)

Model	Description (dimension)	Features
5 章	Vieira Features (10) + SHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI
6 章	Vieira Features (10) + SHHI + Cum_buy + Ave_session	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Cum_buy , Ave_session

以降の章では消費者の訪問経験を変数化した指標を用いるため、モデルに使用するデータの前処理として、データセットの開始時点付近におけるセッションデータの一部を削除する。これは、それらデータが消費者の過去の訪問および購買履歴を十分に反映できていないという理由で行われる。具体的には、消費者の平均購買周期である 53.9 日に基づいて、最初の 54 日間のデータを除外してから変数を作り上げ、その後に変数を作成してモデル化を行う。また、探索によって決定された FFNN および XGBoost のハイパーパラメータの詳細を表 6.3 と表 6.4 に記す。

各モデルの評価指標の結果を表 6.5 から表 6.8 に示す。5 章で構築したモデルと比較して、FFNN では Precision と Recall にわずかな上昇が見られ、XGBoost では 5 章のモデルと比較して Recall が低下しているものの、Precision の上昇が確認された。したがって、本章で提案した“累積購買回数”と“購買に至るまでの平均訪問回数”も 5 章と同様に、モデルに組み込まない理由はないと考えられる。特徴量の重要度を確認するため、SHAP を使用した結果を図 6.2 に示す。

6.3.2 考察

従来のモデルおよび 5 章のモデルよりも Precision が大きく上昇したことに関して、6 章で構築したモデルは購買すると予測したセッションだったものの実際には購買されていなかったセッションであったという誤りを小さくすることができていると言える。SHAP の結果からは、消費者の過去のサイト訪問経験を表すために作成した指標の 1 つである“累積購買回数 (Cum_buy)”は負の方向に青い線、正の方向に赤い線を伸ばしているため、当該セッションに至るまでに購買した回数が少ないほど購買に至りにくく、逆に多いほど購買に至りやすいことが確認された。この結果は、当該サイトでの購買経験が多い消費者ほど再びそのサイトでの購買に至りやすいという点で、直感に一致するものである。また、“購買に至るまでの平均訪問回数 (Ave_session)”は、負の方向に赤い線、正の方向に青い線を伸ばしているため、消費者は購買を伴わない訪問回数が多くなるほど購買に至りにくくなることが示唆された。なお、“累積購買回数 (Cum_buy)”は全ての特徴量の中で最もセッション中の購買に影響を与え、“購買に至るまでの平均訪問回数 (Ave_session)”も図 6.2 において上位に位置しているため、これら 2 つの指標は他の特徴量よりも目的変数に対して強い影響を与えていることがわか

表 6.3 FFNN のハイパーパラメータ

Model	隠れ層のユニット数	学習率	エポック	バッチサイズ	L2 正則化
6 章 層	256, 256, 256 ※ 3	0.0001	150	64	0.0001

表 6.4 XGBoost のハイパーパラメータ

max_depth	
6 章	15

表 6.5 【FFNN】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章	6章
Accuracy	0.939	0.890	0.932	0.942
Precision	0.265	0.145	0.284	0.333
Recall	0.374	0.395	0.547	0.570
F1-Score	0.310	0.212	0.374	0.421
AUC	0.863	0.780	0.906	0.836

表 6.6 【FFNN】各モデルの Confusion Matrix

5章		Predicted	
		Negative	Positive
Actual	Negative	26,001	1,454
	Positive	479	578

6章		Predicted	
		Negative	Positive
Actual	Negative	22,642	1,036
	Positive	392	518

る。これは、セッション中のクリック回数 (N_c) 除いて、消費者の過去のサイト訪問経験がセッション中の購買有無を予測するにあたり他の行動特性よりも大きく寄与することを示している。

表 6.7 【XGBoost】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章	6章
Accuracy	0.946	0.943	0.943	0.952
Precision	0.332	0.316	0.323	0.379
Recall	0.458	0.465	0.492	0.469
F1-Score	0.385	0.376	0.390	0.419
AUC	0.924	0.891	0.923	0.940

表 6.8 【XGBoost】各モデルの Confusion Matrix

5章		Predicted	
		Negative	Positive
Actual	Negative	26,372	1,086
	Positive	535	519

6章		Predicted	
		Negative	Positive
Actual	Negative	22,996	692
	Positive	478	422




図 6.2 SHAP による特徴量の重要度の確認

第 7 章 累積的な多様さを考慮したモデル

7.1 購買過程における消費者の行動の多様さ

本章で構築するモデルで考慮する消費者の購買行動は、“消費者の購買過程における行動の多様さ”であり、これは、図 1.4 に示した消費者 X_5 と X_6 の購買行動を同じものだと考えてよいのか、という疑問が発端となっている。消費者 X_5 と X_6 はどちらも各セッションで商品閲覧時間に偏りがあるものの、セッション全体では消費者 X_5 が商品 A から H まで幅広く閲覧しているのに対し、消費者 X_6 は商品 A と B のみを閲覧している。この違いから、購買に対する決断力が低く多くの商品を広範に閲覧している消費者 X_5 よりも、消費者 X_6 の方が購買に至りやすいと考えられる。この観点は、Moe (2003) [16] が指摘した購買よりも知識を得ることに重点を置いている消費者 (Knowledge building) や、商品の閲覧が特定の商品カテゴリーに集中しておらず、購買目標もない消費者 (Hedonic browsing) に加え、単に購買に対する決断力が低い消費者や、同じ種類の商品を他社のサイトで比較しながら検討する消費者といった、現実的な消費者特性をより正確に捉えられる点で、消費者の購買意思をより正確に特定できると考えられる。なお、本章で提案する上記の視点は、5 章で提案した“セッション中における消費者の行動の多様さ”を消費者属性として再解釈したものであるため、5 章と区別するために“累積的な多様さ”として定義される。

7.2 Fukui, Tabata (2024) のモデル

前節で述べた変数を定義し、モデルに用いている研究として Fukui & Tabata (2024) [24] がある。彼らは 5 章と同様、新美・星野 (2017) [17] が提唱している“多様性”の概念を“累積的な多様性”として拡張し、モデル化を行なっている。具体的には、 HHI (ハフィンダール・ハーシュマン指数) を $CHHI$ (Cumulative-HHI) として拡張し、“セッション全体で見た消費者の閲覧時間の幅広さ”という、消費者が購買を検討する過程においての各商品に対する関心の深さを示す変数を作成している。

$$CHHI_k = \sum_{i=1}^{n_k} s_i^2 \quad (7.1)$$

ここで、 n_k は消費者 k が閲覧した商品カテゴリーの数を、 s_i は消費者の商品閲覧時間全体に占める各商品カテゴリー i の閲覧時間の比率を表している。 $CHHI$ は図 1.4 において、セッション全体における商品閲覧時間のばらつきが大きい消費者 X_5 には値を小さくとり、その逆となる消費者 X_6 には値を大きくとる。なお、消費者がセッション全体のいて 1 つの商品しか閲覧していない場合、 $CHHI$ は 1 となる。

7.3 検証

7.3.1 モデルの概要と結果

検証する上で比較対象となるモデルの詳細を表 7.1 に、探索によって決定された FFNN および XGBoost のハイパーパラメータを表 7.2 および表 7.3 に記す。

表 7.1 検証対象となるモデルの詳細 (7 章)

Model	Description (dimension)	Features
6 章	Vieira Features (10) + SHHI + Cum_buy + Ave_session	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Cum_buy, Ave_session
7 章	Vieira Features (10) + SHHI + Cum_buy + Ave_session + CHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Cum_buy, Ave_session, CHHI

各モデルの評価指標の結果を表 7.4 から表 7.7 にまとめる。

6 章で構築したモデルと比較して、FFNN を使用した場合は Precision がわずかに低下し、Recall はほぼ変わらなかった。一方、XGBoost は Precision が大きく上昇し、Recall がわずかに上昇した。このことから、本章で提案した変数である“CHHI”をモデルに組み込まない理由はないと考えられる。特徴量の重要度を評価するべく、SHAP を本研究のモデルに適用した結果を図 7.1 に示す。

7.3.2 考察

XGBoost を用いた結果として、本章のモデルが従来のモデルおよび 5 章と 6 章のモデルと比較して Precision が大きく上昇しているため、本章では構築したモデルは、6 章で構築したモデルよりもさらに購買すると予測したセッションだったものの実際には購買していなかったセッションであったという誤りを小さくすることができると言える。SHAP の結果からは、提案した指標である CHHI は青色の線が負の方向に、赤色の線が正の方向に伸びているため、セッション全体で見ても様々な商品閲覧する“消費者”は購買しにくく、特定の商品を中心に閲覧する“消費者”は購買しやすいことが確認された。ここで、5 章の 5.4.4 で述べた SHHI の考察より、当該サイトに訪問して商品閲覧する消費者は、他のサイトで別の商品との比較を行い、最終的にその外部のサイトでの購買に至り自社サイトでの購買に至らないということが示唆されていた。しかし、CHHI の結果から、任意のセッションにおいて閲覧時間のばらつきが大きい消費者であっても、その行為を繰り返す消費者は自社サイトでの購買に至る可能性が高いと考えられる。したがって特定の商品を中心に閲覧していたとしても、そのような属性を持つ消費者はマーケティングの対象から除外すべきではないと考えられる。

表 7.2 FFNN のハイパーパラメータ

Model	隠れ層のユニット数	学習率	エポック	バッチサイズ	L2 正則化	
7 章	256, 256, 256	※ 3	0.0001	150	64	0.0001
	層					

表 7.3 XGBoost のハイパーパラメータ

max_depth	
7 章	13

表 7.4 【FFNN】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章	6章	7章
Accuracy	0.939	0.890	0.932	0.942	0.939
Precision	0.265	0.145	0.284	0.333	0.318
Recall	0.374	0.395	0.547	0.570	0.571
F1-Score	0.310	0.212	0.374	0.421	0.408
AUC	0.863	0.780	0.906	0.836	0.915

表 7.5 【FFNN】各モデルの Confusion Matrix

6章		Predicted	
		Negative	Positive
Actual	Negative	22,642	1,036
	Positive	392	518

7章		Predicted	
		Negative	Positive
Actual	Negative	22,558	1,117
	Positive	392	521

表 7.6 【XGBoost】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章	6章	7章
Accuracy	0.946	0.943	0.943	0.952	0.958
Precision	0.332	0.316	0.323	0.379	0.431
Recall	0.458	0.465	0.492	0.469	0.482
F1-Score	0.385	0.376	0.390	0.419	0.455
AUC	0.924	0.891	0.923	0.940	0.943

表 7.7 【XGBoost】各モデルの Confusion Matrix

6章		Predicted	
		Negative	Positive
Actual	Negative	22,996	692
	Positive	478	422

7章		Predicted	
		Negative	Positive
Actual	Negative	23,116	572
	Positive	466	434




図 7.1 SHAP による特徴量の重要度の確認

第 8 章 購買経験に対する忘却を考慮したモデル

本章では、消費者のサイト訪問経験をモデルで捉える上での留意点として、“当該サイトに対する印象が薄れることによる購買意思の低減・忘却”を考慮したモデルを構築する。これは、1 年前の 10 回の購買経験、半年前の 10 回の購買経験、直近 1 ヶ月の 10 回の購買経験の全てが等しく現在のセッションでの購買行動に影響を与えているとみなしてよいのか、という疑問を出発点としている。

8.1 消費者の忘却

消費者の購買経験は時間の経過とともに忘却されると考えられ、1 年前の経験よりも直近 1 ヶ月の経験の方が鮮明に記憶されているであろう。特に、消費者が最近購入した商品に対する満足度や購買後の感情が次の購買行動に強く作用することを考えると、現在の購買行動に影響を及ぼすのは直近の経験の方が大きいと考えられる。したがって、セッション中の消費者行動をより現実 に即した形で捉えるためには、購買経験の忘却という要素を考慮することは重要であると考えられる。

8.2 Fukui, Tabata (2024) のモデル

前節で述べた忘却の要素を取り入れたモデルを構築している研究として、Fukui & Tabata (2024) [25] がある。彼らはまず、消費者の何が忘却されるのか、そしてどのように忘却を表現するのかを定めてモデル化と検証を行なっている。具体的には、6 章で定義した消費者の累積購買回数 (Cum_buy) を忘却の対象とし、以下の (8.1) 式で示される忘却係数を導入して忘却を表現している。

$$(1 + r)^{-D_{ks}} \quad (8.1)$$

上記 (8.1) 式は“正味現在価値”の考え方を応用して作成されており、例えば 3 年後の 10 万円の割引現在価値を年利 10% で計算すると、 $100,000 \times (1 + 0.1)^{-3} = 75131.5$ 円となる。この割引率 $(1 + 0.1)^{-3}$ に該当する部分を忘却係数として導入することで、過去の購買の影響を指数関数的に減少させることができる。なお、 D_{ks} は消費者 k が最後に購入を行った日から当該セッション s までの日数、 r は消費者の忘却率であり、 r の違いによって忘却係数 $(1 + r)^{-D_{ks}}$ にどのような変化が生じるかを図 8.1 に記す。図 8.1 では、実線が $r = 0.1$ 、マーカー付きの線は $r = 0.05$ であり、点線は $r = 0.01$ であり、縦軸は忘却係数の値、横軸は消費者が最後に購入を行なった日から現在のセッションまでの日数を示している。したがって、右に行くほどその日数が長




図 8.1 忘却係数 $(1+r)^{-D_{ks}}$ のプロット

いことを意味している．本研究で扱っているデータ期間が 2010 年 7 月 1 日から 2011 年 6 月 28 日までであることを考えると，最右端の値である 1 年前に購買を行った消費者の購買経験に対する忘却係数はほぼ 0 に近い値をとることが確認される．本研究ではこの忘却係数を 6.2 節の式 (6.1) に掛け合わせて用いることで，以下 (8.2) のように消費者の過去の購買経験を忘却させる．

$$\text{Forgetting-Cum-buy}_{kS} = \sum_{s=1}^S I_{ks} \times (1+r)^{-D_{ks}} \quad (8.2)$$

$$\text{where } I_{ks} = \begin{cases} 0 : & \text{if not purchased in session } s \\ 1 : & \text{if purchased in session } s \end{cases}$$

図 8.1 と合わせて，最後に購買を行ってから現在まで半年経っていた場合， $r = 0.1$ であれば累積購買回数 (*Cum.buy*) を現在のセッション中の購買行動にある程度寄与させられるが， $r = 0.05$ や $r = 0.01$ であればほぼ寄与させないように表現できる．ここで，この r は当該モデルを使用するサイト運営者の価値観で設定されるハイパーパラメータであり，消費者の過去の購買経験をどれだけ忘却するか，その程度を決定するものである．

8.3 検証

8.3.1 モデルの概要と結果

検証する上で比較対象となるモデルの詳細を表 8.1 に記す．また，探索によって決定された FFNN および XGBoost のハイパーパラメータをそれぞれ表 8.2 および表 8.3 に記す．

各モデルの評価指標の結果を表 8.4 から表 8.7 にまとめる．

XGBoost の結果に関して，Recall は本章で構築したモデルが 7 章のモデルよりも上昇しているが，Precision は忘却率 $r = 0.1$ の際に小さくなり， $r = 0.01$ のときに他のモデルと同等の値となっている．この傾向は FFNN では Precision と Recall の両方に生じている．なお，本章では新たな特徴量を追加する形でのモデルの検証ではないため，特徴量の重要度を測定することは行わない．

表 8.1 検証対象となるモデルの詳細 (8 章)

Model	Description (dimension)	Features
7 章	Vieira Features (10) + SHHI + Cum_buy + Ave_session + CHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Cum_buy, Ave_session, CHHI
8 章	Vieira Features (10) + SHHI + Forgetting_Cum_buy + Ave_session + CHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Forgetting_Cum_buy ($r=0.1$) , Ave_session, CHHI
8 章	Vieira Features (10) + SHHI + Forgetting_Cum_buy + Ave_session + CHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Forgetting_Cum_buy ($r=0.05$) , Ave_session, CHHI
8 章	Vieira Features (10) + SHHI + Forgetting_Cum_buy + Ave_session + CHHI	D_S , C/B, S_B , Desc, Duration, Hour, N_c , Price, Views _{24h} , Views _{week} , SHHI, Forgetting_Cum_buy ($r=0.01$) , Ave_session, CHHI

表 8.2 FFNN のハイパーパラメータ

Model	隠れ層のユニット 数	学習率	エポック	バッチサイズ	L2 正則化
8 章 ($r = 0.1$)	128, 128, 128 3 層	※ 0.001	40	32	0.001
8 章 ($r = 0.05$)	256, 256, 256 3 層	※ 0.0001	150	64	0.0001
8 章 ($r = 0.01$)	128, 128, 128 3 層	※ 0.001	40	32	0.001

8.3.2 考察

Precision と忘却率 r との関係性を述べると、忘却率 r が高い場合と低い場合で以下のように言うことができる。

1. 忘却率 r が高い場合：消費者が過去の購買経験をより早く“忘れる”と仮定し、モデルが最新の購買データに対して強く反応するようになっている。この結果、最新の消費者の購買パターンを優先しすぎるため、予測の正確さ (Precision) が犠牲になる。
2. 忘却率 r が低い場合：消費者の過去の購買履歴がモデルに長期間影響を与えるため、Precision は他のモデルと同等か、それに近い値となる。これは、過去の購買行動が現在の予測に対し、依然として有用

表 8.3 XGBoost のハイパーパラメータ

	max_depth
8 章 ($r = 0.1$)	14
8 章 ($r = 0.05$)	7
8 章 ($r = 0.01$)	14

表 8.4 【FFNN】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章	6章	7章	8章 ($r = 0.1$)	8章 ($r = 0.05$)	8章 ($r = 0.01$)
Accuracy	0.939	0.890	0.932	0.942	0.939	0.933	0.932	0.938
Precision	0.265	0.145	0.284	0.333	0.318	0.284	0.292	0.315
Recall	0.374	0.395	0.547	0.570	0.571	0.549	0.577	0.588
F1-Score	0.310	0.212	0.374	0.421	0.408	0.375	0.388	0.410
AUC	0.863	0.780	0.906	0.836	0.915	0.906	0.921	0.914

表 8.5 【FFNN】各モデルの Confusion Matrix

7章		Predicted	
		Negative	Positive
Actual	Negative	22,558	1,117
	Positive	392	521

8章 ($r = 0.1$)		Predicted	
		Negative	Positive
Actual	Negative	22,432	1,250
	Positive	409	497

8章 ($r = 0.05$)		Predicted	
		Negative	Positive
Actual	Negative	22,401	1,275
	Positive	386	526

8章 ($r = 0.01$)		Predicted	
		Negative	Positive
Actual	Negative	22,523	1,159
	Positive	373	533

表 8.6 【XGBoost】各モデルの Precision, Recall, F1-Score, Accuracy, AUC

	Vieira	Esmeli et al.	5章	6章	7章	8章 ($r = 0.1$)	8章 ($r = 0.05$)	8章 ($r = 0.01$)
Accuracy	0.946	0.943	0.943	0.952	0.958	0.953	0.955	0.956
Precision	0.332	0.316	0.323	0.379	0.431	0.397	0.414	0.426
Recall	0.458	0.465	0.492	0.469	0.482	0.541	0.532	0.563
F1-Score	0.385	0.376	0.390	0.419	0.455	0.458	0.466	0.485
AUC	0.924	0.891	0.923	0.940	0.943	0.936	0.939	0.949

であることを示唆している。

表 8.7 【XGBoost】各モデルの Confusion Matrix

7章		Predicted	
		Negative	Positive
Actual	Negative	23,116	572
	Positive	466	434

8章 (r = 0.1)		Predicted	
		Negative	Positive
Actual	Negative	22,949	739
	Positive	413	487

8章 (r = 0.05)		Predicted	
		Negative	Positive
Actual	Negative	23,011	677
	Positive	421	479

8章 (r = 0.01)		Predicted	
		Negative	Positive
Actual	Negative	23,004	684
	Positive	393	507

第 9 章 本研究の意義

本章では、ここまでに予測精度を高めることに注力してきたセッション中の購買予測モデルの実務上の貢献に言及する。具体的には、従来はサイトに訪問した全ての消費者に対して割引クーポンを配布していたところ、具体的には、従来はサイト訪問者全員に一律で配布されていた割引クーポンを、特定のセッションにおいて離脱すると予測される消費者に限定して配布する場合のマーケティングコスト削減効果を評価する。また、モデルの予測精度によってその削減効果にどれくらい差異が生じるのかも試算する。なお、以下に示す応用例とその推定については、2024 年 9 月 30 日に株式会社エニキャリア代表取締役兼東海大学総合社会科学研究所客員教授である小嶋秀信氏からご意見をいただいている。当日の議事録の詳細は付録に記載している。

費用対効果の計算は 売上 - 費用 という基準に基づき、以下の条件のもと概算する。

1. 月商約 10 億円のサイト ※本研究で用いたデータ期間が 2010 年 7 月 1 日から 2011 年 6 月 28 日までのものであったため、データ提供元企業における 2010 年決算と 2011 年決算売上高を参照し、その値を 12 で割った
2. 1. には EC サイトの売上と実店舗の売上が混在しているため、“EC：実店舗 = 9：1” の比率で売上があると想定する。したがって、EC の月商は約 9 億 4 千万円 ※ 1. および 2. の計算を営業利益でも行ったら、月の営業利益は約 3400 万円となった。
3. 平均客単価：9,861 円 ※本研究において使用したデータを分析した結果
4. 月間ユーザー数：520 万人 ※本研究で用いたデータ提供元企業が報道関係者各位に向けた公式資料より、2010 年～2011 年の月間ユニークビジター数を参照
5. 割引率：10% と 15% で試算 ※割引率によるサイト購入転換率の増加分、これを“購入率予想増加分”と呼ぶが、これは割引率が 10% で 1%、15% で 1.5% 増加する想定とする

ここまでの情報から、月間ユーザー数と平均客単価を所与とし、月の購入転換率の値を変動させることで、以下の月間購入者数と購入転換率仮定後の月商を算出する。そして、月の購入転換率は条件にある EC の月商約 9 億 4 千万円に近づく値で確定させる。

$$\text{月間購入者数} = \text{月の購入転換率} \times \text{月間ユーザー数} \quad (9.1)$$

$$\text{購入転換率仮定後の月商} = \text{月間購入者数} \times \text{平均客単価} \quad (9.2)$$

結果として月の購入転換率は 1.85% になった。ここから、月間非購入者数の算出が可能となる。

$$\text{月間非購入者数} = (1 - \text{月の購入転換率}) \times \text{月間ユーザー数} \quad (9.3)$$

次に本研究で構築したモデルを用いた結果として、誤予測でクーポンが配布された非購入者数、すなわち、本

当は購入者として予測されるはずだが、誤って非購入者だと予測された消費者の数を算出する。

$$\text{誤予測でクーポンが配布された非購入者数} = \text{月間購入者数} \times \alpha\% \quad (9.4)$$

ここで、 α はモデルが誤予測をする確率であり、これによって費用対効果がどれだけ変化するかを確かめる。例えば 70% の確率で誤予測をする場合、30% しか正確に購入者か非購入者かをモデルから判別することができない。

次に、割引クーポン適用後の客単価を以下式にて算出する。

$$\text{割引クーポン適用後の客単価} = (1 - \text{割引率}) \times \text{平均客単価} \quad (9.5)$$

そしてその次に、その割引クーポンによる購入者増加数を算出する。この際、購入者は月間非購入者数と誤予測でクーポンが配布された非購入者数から生じるものとする。

$$\text{割引クーポンによる購入者増加数} = (\text{月間非購入者数} + \text{誤予測でクーポンが配布された非購入者数}) \times \text{購入率予想増加分} \quad (9.6)$$

その後、割引クーポンによって増加した分の売上と施策実施にかかった費用を算出する。なお、施策実施にかかった費用は、平均客単価から割引クーポン適用後の客単価に減った分の値を当該企業が負担するとして算出する。

$$\text{割引クーポンによって増加した分の売上} = \text{割引クーポン適用後の客単価} \times \text{割引クーポンによる購入者増加数} \quad (9.7)$$

$$\text{施策実施にかかった費用} = (\text{平均客単価} - \text{割引クーポン適用後の客単価}) \times \text{割引クーポンによる購入者増加数} \quad (9.8)$$

最後に、費用対効果を以下式にて算出する。

$$\text{費用対効果} = \text{割引クーポンによって増加した分の売上} - \text{施策実施にかかった費用} \quad (9.9)$$

ここで算出された費用対効果の比較対象として、全消費者を対象としてクーポンを配布した場合の値を算出する。これは単純に、割引クーポンによる購入者増加数を算出する方法を以下に変更すれば、以降の流れは (9.7) ~ (9.9) と同様である。

$$\text{割引クーポンによる購入者増加数 (全消費者対象)} = \text{月間ユーザー数} \times \text{購入率予想増加分} \quad (9.10)$$

比較には、全消費者に割引クーポンを配布した際の費用対効果から、離脱すると予測された消費者にのみ配布した場合の費用対効果を差し引くことで得られた値を用いる。この値は、月にどれだけコスト削減が可能であったかを示すものである。

上記手順に従い、モデルが誤予測する確率 α を変更した際の費用対効果とその比較結果を表 9.1 にまとめた。表 9.1 から、本研究で構築したモデルを使用することによる月当たりのマーケティングコスト削減効果は、モデルの精度にもよるが約 200 ~ 700 万円と確認できる。たとえ 70% の確率で誤予測する場合でも月 227 万円のコスト削減が見込まれるため、月の営業利益が約 3400 万円であることを考慮すると、そのインパクトは大きいと考えられる。また、例えば 60% の誤予測をしていたモデルの誤予測確率を 40% にするだけでも割引率 10% で約 150 万円、15% で約 200 万円の削減効果が見込めるため、本研究で構築したモデルの精度向上がもたらす効果の大きさが見て取れる。

表 9.1 モデルが誤予測をする確率 α を変更した際の費用対効果とその差分

	30%の確率で誤予測		
	離脱と予測された消費者にのみ配布	全消費者に配布	差分（月にどれだけコスト削減ができるか）
割引率10%	¥404,905,282	¥410,217,600	¥5,312,318
割引率15%	¥531,438,183	¥538,410,600	¥6,972,417

	40%の確率で誤予測		
	離脱と予測された消費者にのみ配布	全消費者に配布	差分（月にどれだけコスト削減ができるか）
割引率10%	¥405,664,185	¥410,217,600	¥4,553,415
割引率15%	¥532,434,242	¥538,410,600	¥5,976,358

	50%の確率で誤予測		
	離脱と予測された消費者にのみ配布	全消費者に配布	差分（月にどれだけコスト削減ができるか）
割引率10%	¥406,423,087	¥410,217,600	¥3,794,513
割引率15%	¥533,430,302	¥538,410,600	¥4,980,298

	60%の確率で誤予測		
	離脱と予測された消費者にのみ配布	全消費者に配布	差分（月にどれだけコスト削減ができるか）
割引率10%	¥407,181,990	¥410,217,600	¥3,035,610
割引率15%	¥534,426,362	¥538,410,600	¥3,984,238

	70%の確率で誤予測		
	離脱と予測された消費者にのみ配布	全消費者に配布	差分（月にどれだけコスト削減ができるか）
割引率10%	¥407,940,892	¥410,217,600	¥2,276,708
割引率15%	¥535,422,421	¥538,410,600	¥2,988,179

第 10 章 結論と今後の課題

本研究ではまず、現在広く普及している EC サイトにおいて、消費者によるサイトへの訪問のうち購入に至る割合がごくわずかであるため、企業はサイト購入転換率を少し改善するだけでも大幅な収益増につながるということを背景とした。そのため、EC サイトを運営する企業はサイト購入転換率を上げるべく、非購買者を購買者に転換させるマーケティングを日々実施している。例えば、サイトを訪れた消費者がセッション中に購買すると予測された場合はそのままに、購買しないと予測された場合には割引クーポンの配布などの施策を実施する等、非購買者を購買者に転換させるために日々奮闘している。

しかしながら、上記のような施策を実施するためには、そもそも任意のセッションにおける消費者の行動をもとに、当該セッション中の消費者の購買意思を正確に特定する必要がある。そこで使用されるのがセッション中の購買予測モデルであり、このモデルを用いることで、セッション開始から特定のタイミングまでに観察されたデータをもとに、そのタイミングでの消費者の購買有無を予測することができる。

セッション中の購買予測モデルを構築している研究はこれまでも複数行われてきたが、それら従来研究には以下の要素が反映されていないとして、本研究では各章でそれら限界を克服するモデルを構築した。

1. 消費者はセッション中に各商品にどれだけ幅広く時間を割いているのか
2. 消費者の過去のサイト訪問経験
3. 消費者は購買を検討する過程において各商品にどれだけ幅広く時間を割いているのか

まず、1. には 5 章が対応しており、ここでは任意のセッションにおいて特定の商品を重点的に閲覧している消費者は購買に至りやすく、そうでない消費者は購買しにくいという仮説を立証している。具体的には、新美・星野（2017）[17] の研究で提案されている“多様性”の概念を拡張した指標を提案し、“セッション中に消費者が閲覧した商品に対する時間の幅広さ”をモデル化している。結果として FFNN では従来のモデルと比較して Precision にわずかな上昇、Recall は大幅な上昇が見受けられ、XGBoost では Recall がわずかに上昇したことが確認された（図 10.1, 図 10.2）。この結果から、5 章で構築したモデルは実際に購買がなされたセッションを見逃すことなく予測する能力が従来のモデルよりも高いとすることができた。

次に 2. には 6 章が対応しており、ここでは商品の比較検討を行う際には何度もサイトに訪問する、過去何度も当該サイトで購買を行なった消費者は再度同じサイトで購買に至りやすいという仮説を立証している。具体的には、“累積購買回数”と“購買に至るまでの平均訪問回数”の 2 つによって消費者のサイト訪問経験を表現し、それら変数を用いてモデルを構築、従来のモデルとの予測精度を比較している。結果として、FFNN を使用した場合は Precision と Recall にわずかな上昇が見られ、XGBoost を使用した場合は 5 章のモデルよりも Recall が低下しているが、Precision は大きく上昇した（図 10.1, 図 10.2）。この結果から、6 章では購買する

と予測したセッションだったものの実際には購買されていなかったセッションであったという誤りを小さくすることができるモデルの構築に成功したとすることができた。

そして 3. には 7 章が対応しており、ここでは任意のセッションで特定の商品を重点的に閲覧しても、それを他の商品にも繰り返していれば購買に対する決断力がなく、購買に至りにくいという仮説を立証している。具体的には、5 章と同様、新美・星野（2017）の研究を参考に、新たな指標として“セッション全体で見た消費者の閲覧時間の幅広さ”を作成し、モデル化を行っている。結果として、6 章で構築したモデルと比較して FFNN では Precision がわずかに低下し、Recall はほぼ変わっていないものの、XGBoost を使用した場合は Precision が大きく上昇し、Recall がわずかに上昇していた（図 10.1, 図 10.2）。この結果から、7 章では 6 章で構築したモデルよりもさらに、購買すると予測したセッションだったものの実際には購買していなかったセッションであったという誤りを小さくすることができるモデルの構築に成功したとすることができた。

最後の 4. に対しては 8 章が対応しており、ここでは消費者のサイト訪問経験をモデルで捉える上での留意点として、1 年前の購買経験より直近 1 ヶ月の購買経験の方が、現在のセッション中の購買行動に大きな影響を与えるという仮説を立証している。具体的には、6 章で作成した“累積購買回数”に掛け合わせ、消費者の過去の購買経験が時間の経過とともに徐々に減衰していく様子をモデル化した。結果として、XGBoost の結果から Recall は 7 章のモデルよりも上昇しているものの、Precision は忘却率 $r = 0.1$ の際に低下し、 $r = 0.01$ の際には他のモデルと同等の値となった（表 10.1, 表 10.2）。また、この傾向は FFNN では Precision と Recall の両方に見られた。この結果より、忘却を考慮したモデルは、直近の購買経験をより重視することによって、過去の購買経験によって“非購入者”として誤分類されていた消費者を現状に即した購買行動として捉え直し、その誤分類を改善する効果があったと述べることもできた。

総じて、表 10.1 および表 10.2 から、先行研究のセッション中の購買予測モデルに反映されていない消費者の購買行動をモデル上で新たに表現することにより、比較対象としている Vieira (2016) [11] と Esmeli et al. (2020) [4] のモデルよりも予測精度を向上させたモデルの構築に成功した。このことから、本研究では消費者の購買有無を正確に予測し、その結果に基づいて非購買者を購買者に変える施策に役立つことが期待されるモデルの構築に成功したと言える。ここで、FFNN と XGBoost のどちらも最も精度が高いのは、8 章で構築した忘却率を $r = 0.01$ のモデルとなっており、XGBoost の方が Accuracy, F1-Score, AUC が FFNN よりも高いため、本研究で対象としたサイトおよびそのデータ規模を考慮すると、XGboost の使用が推奨される。

また、各章で構築したモデルの適用場面に関しては、たとえば 5 章のモデルは消費者の過去の経験を考慮していないため、消費者の過去のデータが少ない EC サイト開設直後での購買予測に有効であると言える。次に 6 章のモデルは、耐久消費財や嗜好品などを扱う、購買するまでに何度も訪問する消費者が存在する EC サイト、すなわち、即断即決で購買するような消費者がいない EC サイトでの購買予測に有効であると考えられる。そして 7 章のモデルは、消費者が複数の商品に興味を持つ傾向がある EC サイト、商品の種類が多い EC サイトでの購買予測に有効である。最後に 8 章のモデルは、一時期に大量購入をしていたが、最近ではその購買頻度が減少している消費者を抱える EC サイトにおける予測に有効であると考えられる。

今後の課題として、本研究において構築したモデルは 1.2 節で述べたように耐久消費財および嗜好品を扱う EC サイトにおける消費者の購買行動を捉えていたため、日用品など異なる商材を扱う EC サイトにおいて本モデルが適用可能であるか、あるいはそれらにより適合する形でのモデルの改良が必要であるかを検証する必

表 10.1 【FFNN】本研究で構築した各モデルの Precision, Recall, F1-Score, Accuracy, AUC

			5章	6章	7章	8章		
	Vieira	Esmeli et al.	瞬間的な多様さ	訪問経験	累積的な多様さ	購買経験に対する忘却 $r = 0.1$	購買経験に対する忘却 $r = 0.05$	購買経験に対する忘却 $r = 0.01$
Accuracy	0.939	0.890	0.932	0.942	0.939	0.933	0.932	0.938
Precision	0.265	0.145	0.284	0.333	0.318	0.284	0.292	0.315
Recall	0.374	0.395	0.547	0.570	0.571	0.549	0.577	0.588
F1-Score	0.310	0.212	0.374	0.421	0.408	0.375	0.388	0.410
AUC	0.863	0.780	0.906	0.836	0.915	0.906	0.921	0.914

表 10.2 【XGBoost】本研究で構築した各モデルの Precision, Recall, F1-Score, Accuracy, AUC

			5章	6章	7章	8章		
	Vieira	Esmeli et al.	瞬間的な多様さ	訪問経験	累積的な多様さ	購買経験に対する忘却 $r = 0.1$	購買経験に対する忘却 $r = 0.05$	購買経験に対する忘却 $r = 0.01$
Accuracy	0.946	0.943	0.943	0.952	0.958	0.953	0.955	0.956
Precision	0.332	0.316	0.323	0.379	0.431	0.397	0.414	0.426
Recall	0.458	0.465	0.492	0.469	0.482	0.541	0.532	0.563
F1-Score	0.385	0.376	0.390	0.419	0.455	0.458	0.466	0.485
AUC	0.924	0.891	0.923	0.940	0.943	0.936	0.939	0.949

要がある。また、耐久消費財の特性、特に季節性や耐用年数などを考慮したモデリングを行うことで、より精度の高いモデル構築が可能になると考えられる。したがって、今後の研究ではこれらの観点を取り入れたモデル化とその検証を進めることを目指す。

謝辞

本論文を作成するにあたり、審査委員として多大なるご協力を賜りました東海大学情報通信学部の高山佳久教授、森田直樹教授、西口宏美教授、金子雅明教授、経営学部の森山弘海教授、田畑智章教授に対し、心より深謝申し上げます。皆様から非常に貴重かつ有益なご指摘を賜りましたことで、研究の完成度をさらに高めることができました。予備審査を経る中で研究者としての視点や能力が向上したことを実感しており、この成長を自負するとともに、深く感謝しております。特に、普段から「モデルとは何か」を意識しながら研究に取り組んでいたつもりではありましたが、その理解にはまだ甘さが残っており、真の意味での理解には至っていなかったことを痛感いたしました。このような気づきを得られたのも、審査委員の皆様からの貴重なご指摘のおかげであり、この場をお借りして、改めて深く感謝申し上げます。

また、学部から博士課程にかけて8年間にわたりご指導いただきました田畑智章教授には、いかんせん物分りが悪く強情な部分がある（と自覚している）著者に対し、幾度も辛抱強く多角的なご指導を賜りましたことに、心より深く感謝申し上げます。未だ十分に恩返しができていないため、今後は研究活動を通じて少しでもそのご恩に報いるべく尽力してまいりたいと考えております。

さて、以降は当該研究を執筆するにあたっての紆余曲折を記載しようと考えておりましたが、それをこちらに記すには余白が狭すぎるため、ここで筆を置かせていただきます。最後に、温かく見守ってくれました両親および叔母に感謝申し上げます。

[18] に関しては、International Journal of Service and Knowledge Management (IJSKM)・IIAI Journal の許可を得て転載しています。[24] に関しては、Springer Nature の許可を得て転載しています。[25] に関しては、Industrial Engineering and Management Systems (Proceedings of the 24th Asia Pacific Industrial Engineering and Management Systems Conference (APIEMS, 2024) の HP にて、Proceeding of Papers として掲載されている。表 5.1 の引用に関しては、現名城大学経営学部経営学科新美潤一郎准教授に許諾をいただいています。

参考文献

- [1] マーケティング・サイエンス入門 市場対応の科学的マネジメント, 古川一郎, 守口剛, 阿部誠, 2011/4/25
- [2] マーケティング・リサーチ入門, 星野崇宏, 上田雅夫, 2018/12/25
- [3] 経済産業省 令和5年度電子商取引に関する市場調査報告書:
https://www.meti.go.jp/policy/it_policy/statistics/outlook/R5tyousahoukokusho.pdf (最終閲覧日: 2024/10/3)
- [4] Esmeli, R., Bader-El-Den, M. and Abdullahi, H.: Towards early purchase intention prediction in online session based retailing systems, *Electronic Markets*, Vol.31, pp.697-715 (2021)
<https://doi.org/10.1007/s12525-020-00448-x>
- [5] Mokryn, O., Bogina, V. and Kuflik, T.: Will this session end with a purchase? Inferring current purchase intent of anonymous visitors, *Electronic Commerce Research and Applications*, Vol.34, pp.1-25 (2019) <https://doi.org/10.1016/j.elerap.2019.100836>
- [6] Digital Commerce 360, Online conversion rates have dipped going into 2024. Here 's what we know.: <https://www.digitalcommerce360.com/article/how-to-increase-conversion-rates/> (最終閲覧日: 2024/10/3)
- [7] Sismeiro, C. and Bucklin, R. E.: Modeling Purchase Behavior at an E-Commerce Web Site: A Task-Completion Approach, *Journal of Marketing Research*, Volume 41, Issue 3 (2004)
<https://doi.org/10.1509/jmkr.41.3.306.35985>
- [8] 毎月の作業時間 15 分で CVR が 1.5 倍に! AI の活用で無駄の無いクーポン配布を実現:
https://ecnomikata.com/original_news/25213/ (最終閲覧日: 2024/10/3)
- [9] Bogina, V., Kuflik, T. and Mokryn, O.: Learning Item Temporal Dynamics for Predicting Buying Sessions, *Proceedings of the 21st International Conference on Intelligent User Interfaces*, pp.251-255 (2016) <https://doi.org/10.1145/2856767.2856781>
- [10] Guan, M., Cha, M., Wang, Y., Li, Y. and Sun, J.: From Anticipation to Action: Data Reveal Mobile Shopping Patterns During a Yearly Mega Sale Event in China, *IEEE Transactions on Knowledge and Data Engineering*, Vol. 34, No.4, pp.1775-1787 (2022) DOI: 10.1109/TKDE.2020.3001558
- [11] Vieira, A.: Predicting online user behaviour using deep learning algorithms, *The Computing Research Repository (CoRR)*, Vol. abs/1511.06247 (2016) <https://doi.org/10.48550/arXiv.1511.06247>
- [12] Boroujerdi, E. G., Mehri S., Garmaroudi, S. S. and Pezeshki, M.: A study on prediction of user's tendency toward purchases in websites based on behavior models, *Conference: 2014 6th Conference*

- on Information and Knowledge Technology (IKT), DOI: 10.1109/IKT.2014.7030334
- [13] CHEN, C., HOU, C., XIAO, J., WEN, Y. and YUAN, X.: Enhancing Purchase Behavior Prediction with Temporally Popular Items, IEICE TRANSACTIONS on Information and Systems, Vol.E100-D, No.9, pp.2237-2240 (2017) <https://doi.org/10.1587/transinf.2017EDL8057>
 - [14] Chaudhuri, N., Gupta, G., Vamsi, V. and Bose, I.: On the platform but will they buy? Predicting customers' purchase behavior using deep learning, Decision Support Systems, Vol.149, pp.113622 (2021), <https://doi.org/10.1016/j.dss.2021.113622>
 - [15] Tanvir, A.A., Khandokar, I.A., Islam, A.K.M.M, Islam, S., and Shatabda, S.: A Gradient Boosting Classifier for Purchase Intention Prediction of Online Shoppers, Heliyon, 9(4), e15163, 2023, <https://doi.org/10.1016/j.heliyon.2023.e15163>
 - [16] Moe, W. W.: Buying, Searching, or Browsing: Differentiating Between Online Shoppers Using In-Store Navigational Clickstream, Journal of Consumer Psychology Volume 13, Issues 1-2 , 2003, Pages 29-39, https://doi.org/10.1207/S15327663JCP13-1&2_03
 - [17] 新美潤一郎, 星野崇宏: 顧客行動の多様性変数を利用した購買行動の予測 -Deep Learning を応用した実店舗・Web・モバイルの多面的な分析-, 人工知能学会論文誌, Vol.32, No.2, p.B-G63 1-9, 2017, <https://doi.org/10.1527/tjsai.B-G63>
 - [18] Yuto, F., Tomoaki, T. and Takaaki, H.: A Purchasing Prediction Model Considering Pre-purchase Behaviors, International Journal of Service and Knowledge Management, Vol. 6 No.1, 2022, <https://doi.org/10.52731/ijskm.v6.i1.633>
 - [19] 個人情報保護委員会, 個人情報の保護に関する法律についてのガイドライン (通則編): https://www.ppc.go.jp/personalinfo/legal/guidelines_tsusoku/
 - [20] 総務省, 外部送信規律: https://www.soumu.go.jp/main_content/000862755.pdf
 - [21] 総務省, 外部送信規律 FAQ: https://www.soumu.go.jp/main_sosiki/joho_tsusin/d_syohi/gaibusoushin_kiritsu_00002.htm
 - [22] 総務省, 電気通信事業参入マニュアル [追補版], 主なオンラインサービスの考え方, p.17: https://www.soumu.go.jp/main_content/000799137.pdf
 - [23] 個人情報保護委員会, 一般データ保護規則 (GDPR) の条文: <https://www.ppc.go.jp/files/pdf/gdpr-provisions-ja.pdf>
 - [24] Yuto F. and Tomoaki T.: Prediction of Consumer Purchases in a Session on an EC Site Considering the Variety of Past Browsing, Social Computing and Social, Conference Paper, pp 247-261, 2024, https://link.springer.com/chapter/10.1007/978-3-031-61305-0_17
 - [25] Yuto F. and Tomoaki T.: A Prediction Model for Consumer Purchase in a Session on an EC site, Industrial Engineering and Management Systems (Proceedings of the 24th Asia Pacific Industrial Engineering and Management Systems Conference (APIEMS, 2024), pp 227-232, 2024
 - [26] Tian, Y. and Stewart, C.: History of E-Commerce, In book: Electronic Commerce, 2007, DOI:10.4018/9781599049434.ch001
 - [27] 一般財団法人 日本情報経済社会推進協会, EDI とは:

- <https://www.jipdec.or.jp/project/kcode/edi/about.html>
- [28] Taher, G. and Alnoor, A.: E-Commerce: Advantages and Limitations, International Journal of Academic Research in Accounting Finance and Management Sciences 11(1):153-165, <http://dx.doi.org/10.6007/IJARAFMS/v11-i1/8987>
 - [29] 公正取引委員会, 消費者向け e コマースの取引実態に関する調査報告書: https://www.jftc.go.jp/houdou/pressrelease/2019/jan/190129_4houkokusyo.pdf
 - [30] Jansen, B. J., Spink, A., Blakely, C. and Koshman, S.: Defining a session on Web search engines, Journal of the American Society for Information Science and Technology, 2007, <https://doi.org/10.1002/asi.20564>
 - [31] Wu, C., Yan, M. and Si, L.: Session-aware Information Embedding for E-commerce Product Recommendation, Proceedings of the ACM on Conference on Information and Knowledge Management, pp.2379-2382, 2017, <https://doi.org/10.1145/3132847.3133163>
 - [32] Bogina, V. and Kuflik, T.: Incorporating Dwell Time in SessionBased Recommendations with Recurrent Neural Networks, In CEUR Workshop proceedings, Vol.1922, pp. 57 UTF201359, 2017
 - [33] 佐藤翔太, 朝日弓未: 消費者向け電子商取引サイトにおける顧客の来店有無を考慮した購買モデル, オペレーションズ・リサーチ, Vol.58, No.2, pp.80-86, 2013
 - [34] Weisberg, J., Te'eni, Dov. and Arman, Limor.: Past purchase and intention to purchase in e-commerce: The mediation of social presence and trust, Internet Research, Vol.21, No.1, pp.82-96, 2011, <https://doi.org/10.1108/10662241111104893>
 - [35] 機関誌 経営の科学 オペレーションズ・リサーチ, Vol.23, No.2: ブラック・ボックスを透視する, 田畑吉雄, 1978
 - [36] Chen, T. and Guestrin, Carlos.: XGBoost: A Scalable Tree Boosting System, KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp.785-794, 2016, <https://doi.org/10.1145/2939672.293978>
 - [37] Lee, J., Jung, O., Lee, Y., Kim, O. and Park, C.: A Comparison and Interpretation of Machine Learning Algorithm for the Prediction of Online Purchase Conversion. Theoretical and Applied Electronic Commerce Research, 16(5), 1472-1492, 2021
 - [38] EU 域内にいる個人の個人データを取扱う企業の皆さまへ (平成 30 年 3 月 28 日, 個人情報保護委員会・経済産業省): <https://www.ryokan.or.jp/top/news/download/116?file=1>
 - [39] Xu, L., Duan, J.A., and Whinston, A.: Path to Purchase: A Mutually Exciting Point Process Model for Online Advertising and Conversion. Management Science 60(6), 1351-1616, 2014, <https://doi.org/10.1287/mnsc.2014.1952>
 - [40] University of waterloo, Campus Wellness, Curve of Forgetting, <https://uwaterloo.ca/campus-wellness/curve-forgetting> (最終閲覧日: 2024/8/25)
 - [41] Kaggle で勝つデータ分析の技術, 門脇大輔, 阪田隆司, 保坂桂佑, 平松雄司, 2019/10/9

- [42] Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P.: SMOTE: Synthetic Minority Over-sampling Technique, Journal of artificial intelligence research, Vol.16, pp.321-357, 2002, <https://doi.org/10.1613/jair.953>
- [43] Lundberg, S. M. and Lee, S.I.: A Unified Approach to Interpreting Model Predictions, Proceedings of the 31st International Conference on Neural Information Processing Systems, pp.4768-4777, 2017, <https://doi.org/10.48550/arXiv.1705.07874>
- [44] Be careful when interpreting predictive models in search of causal insights : https://shap.readthedocs.io/en/latest/example_notebooks/overviews/Be%20careful%20when%20interpreting%20predictive%20models%20in%20search%20of%20causal%20insights.html
- [45] An introduction to explainable AI with Shapley values: https://shap.readthedocs.io/en/latest/example_notebooks/overviews/An%20introduction%20to%20explainable%20AI%20with%20Shapley%20values.html
- [46] 【ZOZO・エアーローゼット事例】AIを活用する最前線ファッションテックの現状とは？ : <https://netshop.impress.co.jp/node/8150>（最終閲覧日：2024/8/24）
- [47] Wen, Z., Lin, W. and Liu, H.: Machine-Learning-Based Approach for Anonymous Online Customer Purchase Intentions Using Clickstream Data, Systems, Vol.15, No.5, pp.255, 2023
- [48] 株式会社 言語理解研究所（Institute of Language Understanding Inc. ; ILU） : <https://www.ilu.co.jp/>
- [49] imbalanced-learn/imblearn/over_sampling/_smote/base.py : https://github.com/scikit-learn-contrib/imbalanced-learn/blob/20ba698/imblearn/over_sampling/_smote/base.py
- [50] LightGBM 予測モデル実装ハンドブック, 毛利拓也, 2023/6/17
- [51] Introduction to Boosted Trees : <https://xgboost.readthedocs.io/en/stable/tutorials/model.html>
- [52] 機械学習を解釈する技術～予測力と説明力を両立する実践テクニック, 森下光之助, 2021/8/4
- [53] 機械学習工学, 石川冬樹, 丸山宏, 柿沼太一, 竹内広宜, 土橋昌, 中川裕志, 原聡, 堀内新吾, 鷺崎弘宜, 2022/7/20

付録

SMOTENC

SMOTENC (Synthetic Minority Over-sampling TEchnique-Nominal Continuou) は連続値の特徴量と質的な特徴量が混合されたデータセットを扱うように一般化された SMOTE のこと [42] であり, Python の SMOTENC クラスのプログラムコード ([49]) から, 大枠として以下のようなアルゴリズムとなっている.

1. 特徴量の種類を識別し, それぞれ取得 (連続特徴量と質的特特徴量)
2. 少数派クラスのサンプルを取得 ※行の取得
3. 質的特特徴量のワンホットエンコーディングを行う
4. 少数派クラスの連続特徴量の列ごとの標準偏差の中央値を出力
5. 3. のワンホットエンコードベクトルに 4. を掛け, 2 で割る (3. のベクトルは 0 or 1 の要素を持つものなので, それら 1 の値を連続特徴量のスケールに合わせた値に置き換えることで, 質的特特徴量と連続特徴量間での距離計算のバランスをとる)
6. 連続特徴量と 5. のベクトルを合わせたものを用いて最近傍を計算し, 新しい連続特徴量の合成サンプルを生成
7. 質的特特徴量の逆ワンホットエンコーディングを行う
8. 質的特特徴量に関して, 少数派クラスで最も頻繁に出現するカテゴリを選択する

本研究ではデータ不均衡の問題に対処するためにオーバーサンプリングを実施している. しかしながら, 質的データとして, Vieira (2017) [11] がモデルに用いていた変数の 1 つである “4. *Desc*” の変数 (3.2 節を参照) の代替となる, “商品のジャンル”が存在するため, SMOTE ではなく SMOTENC を使用している. なお, SHAP 値を計算する際に使用するモデルには上記 “商品のジャンル”を用いないため, SMOTE を使用している. また, python では `imblearn.over_sampling` を用いてそれらオーバーサンプリングを行っているが, 各パラメータはデフォルトの値を使用している (サンプルを生成するために使用する近傍の定義 `k_neighbors` など).

XGBoost (eXtreme Gradient Boosting)

XGBoost は, 勾配ブースティングのためのスケーラブルな機械学習システムである [36], [50]. 以降, 損失関数を最小化する重みとその際の目的関数を導出するが, 数式の展開は主に [50] と [51] を参考にしている. ま

ずは使用する記号を整理する.

- K : 木の数
- $\mathbf{x}_i^T = (x_{i1}, x_{i2}, \dots, x_{im})$: 1 レコード ($i = 1, 2, \dots, n$, m 個の特徴量)
- t : ブースティングの回数 (ステップ)
- $\hat{y}_i^{(t)}$: ステップ t の予測値
- f_k : 関数空間 $\mathcal{F}$ に属する関数 ($f_k \in \mathcal{F}$)
- $\mathcal{F}$: 決定木の集合
- θ : パラメータ
- $l(y_i, \hat{y}_i)$: 損失関数

各木における予測スコアを合計して最終スコアを得ることを考えて (1), このモデルがパラメータ θ に依存する目的関数 $obj(\theta)$ で最適化できると仮定する.

$$\hat{y}_i = \sum_{k=1}^K f_k(\mathbf{x}_i) \quad (1)$$

正則項 $\sum_{k=1}^K \omega(f_k)$ も同時に考えて, 以下 (2) のように表現する.

$$obj(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \omega(f_k) \quad (2)$$

勾配ブースティングにおける予測は, K 本の決定木に予測したい特徴量 $\mathbf{x}$ を入力し, ステップの初期値 $\hat{y}^{(0)}$ に, 決定木 k において特徴量の条件に該当した葉の重み $w_k(\mathbf{x})$ を順番に K 本ぶん加算したものとなる (以下 (3)). ※ $w_k(\mathbf{x}_i) = f_k(\mathbf{x}_i)$ となることに注意.

$$\hat{y}_i = \hat{y}^{(0)} + w_1(\mathbf{x}_i) + w_2(\mathbf{x}_i) + \dots + w_K(\mathbf{x}_i) = \hat{y}^{(0)} + \sum_{k=1}^K w_k(\mathbf{x}_i) \quad (3)$$

すなわち, 全ての木を一度に学習することは不可能なので, Additive Training を行う. これは, すでに学習したものを固定し, 新しい木を一つずつ各ステップで追加して以下 (4) のようにまとめることができる.

$$\begin{aligned} \hat{y}_i^{(0)} &= 0 \\ \hat{y}_i^{(1)} &= f_1(\mathbf{x}_i) = \hat{y}_i^{(0)} + f_1(\mathbf{x}_i) \\ \hat{y}_i^{(2)} &= f_1(\mathbf{x}_i) + f_2(\mathbf{x}_i) = \hat{y}_i^{(1)} + f_2(\mathbf{x}_i) \\ &\vdots \\ \hat{y}_i^{(t)} &= \sum_{k=1}^t f_k(\mathbf{x}_i) = \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i) \end{aligned} \quad (4)$$

また, 目的関数 $obj^{(t)}$ も t 回ぶんのブースティングしたステップ t に合わせて, 以下の (5) の形で整理される

(正則化項はステップごとに最適化するので、ステップ t だけを残す).

$$\begin{aligned}
obj^{(t)} &= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t \omega(f_k) \\
&= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \sum_{k=1}^t \omega(f_k) \\
&= \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \omega(f_t) + \text{constant}
\end{aligned} \tag{5}$$

損失関数として平均二乗誤差 (MSE) を使うことを考えると、目的関数は (6) のようになる.

$$obj^{(t)} = \sum_{i=1}^n \left[2 \left(\hat{y}_i^{(t-1)} - y_i \right) f_t(x_i) + f_t(x_i)^2 \right] + \omega(f_t) + \text{constant} \tag{6}$$

上記の損失関数を 2 次までテイラー展開すると、(7) のようになる.

$$obj^{(t)} = \sum_{i=1}^n \left[l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \omega(f_t) + \text{constant} \tag{7}$$

g_i は損失関数の 1 次微分, h_i は 2 次微分である.

$$\begin{aligned}
g_i &= \frac{\partial l(y_i, \hat{y}_i^{(t-1)})}{\partial \hat{y}_i^{(t-1)}} \\
h_i &= \frac{\partial^2 l(y_i, \hat{y}_i^{(t-1)})}{(\partial \hat{y}_i^{(t-1)})^2}
\end{aligned}$$

上記の中で $f_t(x_i)$ に依存しない項は定数項とみなし、それを除いた損失関数を定義すると、(8) のようになる.

$$\tilde{obj}^{(t)} = \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \omega(f_t) \tag{8}$$

木の複雑さ (正則化項) $\omega(f)$ を定義するにあたり、木の定義 $f(x)$ を考えると、以下 (9) のようになる.

$$f_t(x) = w_{q(x)}, \quad w \in R^T, \quad q: R^d \rightarrow \{1, 2, \dots, T\}. \tag{9}$$

ここで、 q は特徴量 x_i を葉に割り振る関数で、木の葉数が T 、葉数に応じて発生する正則化の強さを γ 、重みの L2 正則化の強さが λ であるとする、正則化項 $\omega(f_k)$ は以下 (10) のようになる.

$$\omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \tag{10}$$

これによって、損失関数 (8) を以下 (11) のように書き換える.

$$\tilde{obj}^{(t)} = \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \tag{11}$$

ここで、 j 番目の葉に割り当てられたデータポイントのインデックスの集合 $I_j = \{i | q(x_i) = j\}$ を考え (実際に出力されたノードのみ考え)、その総和 $\sum_{i \in I_j}$ をとるとすると、損失関数 (11) は以下 (12) のように書き換えることができる (q の定義と、 $w_k(x_i) = f_k(x_i)$ であることも使用).

$$\begin{aligned}
\tilde{obj}^{(t)} &= \sum_{i=1}^n \left[g_i w_{q(x_i)} + \frac{1}{2} h_i w_{q(x_i)}^2 \right] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \\
&= \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T
\end{aligned} \tag{12}$$

上式を w_j で微分して 0 とすると、損失関数を最小化する重み w_j は (13) 式のようになる。

$$\begin{aligned}\frac{\partial \tilde{obj}^{(t)}}{\partial w_j} &= \left(\sum_{i \in I_j} g_i \right) + \left(\sum_{i \in I_j} h_i + \lambda \right) w_j = 0 \\ w_j &= - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}\end{aligned}\tag{13}$$

(13) 式を (12) 式に代入して整理すると、以下 (14) 式となる。

$$\tilde{obj}^{(t)} = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T\tag{14}$$

AUC (Area Under the Curve)

以下, [41], p.75-77 を要約したものを記載する。

AUC は ROC 曲線 (Receiver Operating Characteristic Curve) が描く曲線をもとに計算される二値分類における代表的な評価指標である。ROC 曲線の下部の面積が AUC であり、これは予測値を正例とする閾値を 1 から 0 に動かし、そのときの偽陽性率／真陽性率を (x, y) としてプロットすることで描くことができる。なお、偽陽性率と真陽性率の定義は Confusion Matrix 上の値を用いて、以下となっている。

- 偽陽性率：FP / (FP + TN)
- 真陽性率：TP / (TP + FN)

全体の正例の個数を n_p 、全体の負例の個数を n_n として、最初の点を左下の (0.0, 0.0) の点とした際の ROC 曲線を描く。正例と予測する閾値を徐々に低くしていくと、正例と予測されるデータ増えていき、それらのデータに真の値が正例のものが 1 つ入ると $1/n_p$ だけ上に進め、負例のものが 1 つ入ると $1/n_n$ だけ右に進む。最終的には右上の (1.0, 1.0) の点にたどり着き、例えば予測値が大きい順番にデータを並べ替えたとき、正例を 1、負例を 0 として [1, 1, 0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0] となった際には、正例が 5 個、負例が 10 個のため、正例と予測されたデータに正例が入ると上に 0.2 進み、負例が入ると右に 0.1 進むため、以下図 2.15 のようになる。AUC の性質に関しては以下となる。

- 完全な予測を行った場合には $AUC = 1.0$ となり、ランダムな予測を行った場合には $AUC = 0.5$ となる。
- AUC は “正例と負例をそれぞれランダムに選んだときに、正例の予測値が負例の予測値より大きい確率” としても定義できる (以下式)

$$AUC = \frac{(\text{ } y_i = 1, y_j = 0, \hat{y}_i > \hat{y}_j \text{) である (i, j) の組の個数}}{(\text{ } y_i = 1, y_j = 0 \text{) である (i, j) の組の個数}}$$

- AUC は各レコードの予測値の大小関係のみに値に影響する。

SHAP (SHapley Additive exPlanations)

協力ゲーム理論における Shapley 値のコンセプトを機械学習に応用し、特徴量の重要度を計算する方法を SHAP (SHapley Additive exPlanation) と呼ぶ ([52])。以下、Shapley 値の説明から入り、その後に SHAP




図1 “[41], p.76, 図 2.15”を抜粋

表3 参加者と報酬の関係（[52] の表 6.1 を引用）

参加者	報酬
Aさん	6
Bさん	4
Cさん	2
Aさん・Bさん	20
Aさん・Cさん	15
Bさん・Cさん	10
Aさん・Bさん・Cさん	24

の説明を行う（主に [52] の例などを引用）。

A さん、B さん、C さんの 3 人（プレイヤー）がアルバイトゲームに参加する。このゲームは単独で行うこともできるが、他の人とチームを組んで行ってもよい。ここで、アルバイトの報酬は誰が参加するかで決まるとし、特定の参加者が参加した場合の報酬をまとめたものを表 1.1 に示す（報酬の単位は万円で、これはゲーム理論で言うところの“利得”である）。

ここで、アルバイトゲームに A さんと B さんと C さんの 3 人全員が参加した場合、合計の報酬 24 万円をどのように 3 人に分配するのがもっともらしいかを考える。直感的には、ゲームに対する貢献度の高い人により多くの報酬を割り当てることがフェアな配分方法の 1 つになる。そのような方法を考える上で問題になるのが、各人の貢献度をどうやって計るのかである。これを計算するために、“限界貢献度”という概念、すなわち

表 4 参加順を考慮した限界貢献度 ([52] の表 6.2 を引用)

参加順	Aさんの限界貢献度	Bさんの限界貢献度	Cさんの限界貢献度
Aさん → Bさん → Cさん	6	14	4
Aさん → Cさん → Bさん	6	9	9
Bさん → Aさん → Cさん	16	4	4
Bさん → Cさん → Aさん	14	4	6
Cさん → Aさん → Bさん	13	9	2
Cさん → Bさん → Aさん	14	8	2

各人がアルバイトに参加したとき、参加しなかったときと比べて、追加的にどのくらい報酬が増えるかを計算する．具体的には、特定のプレイヤーがゲームに参加することによって追加的に増える利得を計算する．例えば、誰も参加していない状況で A さんのみ参加した場合の A さんの利得 6 万円であり、B さんのみ参加している状況で A さんが参加した場合の A さんの利得は $20 - 4 = 16$ 万円、C さんのみ参加している状況で A さんが参加した場合の A さんの利得は $15 - 2 = 13$ 万円、そして B さんと C さんの両方が参加している状況で A さんが参加した場合の A さんの利得は $24 - 10 = 14$ 万円となる．このようにして計算される利得が A さんの参加によって追加的に増える利得となり、限界貢献度になる．しかし注意が必要なのが、A さんの限界貢献度は A さんがゲームに参加する順番に依存する．したがって、この影響を打ち消すために、考えられる全ての参加順を用いて限界貢献度を計算し、その平均を求める．発生し得る参加順とその場合の各人の限界貢献度を表 6.2 にまとめる．参加順は $3! = 6$ なので、平均的な限界貢献度を計算すると以下のようになり、この平均的な限界貢献度のことを “Shapley 値” と呼ぶ．

- A さんの平均的な限界貢献度： $(6 + 6 + 16 + 14 + 13 + 14)/6 = 11.5$ 万円
- B さんの平均的な限界貢献度： $(14 + 9 + 4 + 4 + 9 + 8)/6 = 8$ 万円
- C さんの平均的な限界貢献度： $(4 + 9 + 4 + 6 + 2 + 2)/6 = 4.5$ 万円

Shapley 値を用いて利得を割り当てることで、より貢献度が高い人に多くの報酬が渡るという意味でフェアに配分を行うことができる．上記例ではプレイヤーが 3 人のケースであったが、一般化して、 J 人のプレイヤーが存在するケースを考えると、プレイヤー j の Shapley 値 ϕ_j は以下のように計算できる．

$$\phi_j = \frac{1}{|J|!} \sum_{S \subseteq J \setminus \{j\}} (|S|!(|J| - |S| - 1)!(v(S \cup \{j\}) - v(S))) \quad (15)$$

各記号が表すものをまとめると以下になる．

- $J = \{1, 2, \dots, J\}$ ：プレイヤーの集合（上記例の場合、 $J = \{A, B, C\}$ ）
- $|J|$ ：集合 J の要素の数、つまり全プレイヤーの人数を示す．したがって、 $|J|!$ は組み合わせの総数を示す（上記例の場合、 $|J| = 3$ で、 $|J|! = 6$ ）
- S ： J からプレイヤー j を除いたプレイヤー群から作られる、空集合 $\emptyset$ を含めた全ての組み合わせ（上記例の場合で A さんの Shapley 値を考える場合には、 $\emptyset, \{B\}, \{C\}, \{B, C\}$ が該当する）
- $|S|$ ：集合 S の要素の数（前述の S の場合、 $\emptyset, \{B\}, \{C\}, \{B, C\}$ で、それぞれ $0, 1, 1, 2$ となる）※ $(|S|!(|J| - |S| - 1)!)$ は組み合わせの出現回数を示す．

- $v(\cdot)$: 利得を表す関数で、参加プレイヤーに依存して決まる（上記例で、AさんとBさんがアルバイトに参加した場合の利得は $v(\{A, B\})$ となる）
- $v(S \cup \{j\}) - v(S)$: S にプレイヤー j が参加したときの限界貢献度、すなわちプレイヤー j が参加しているときと参加していないときでの報酬の差を示す。さらに言い換えれば、元々の参加者の集合が S だったときに、プレイヤー j が参加したときの限界貢献度となる。

つまり、プレイヤー j が参加することの限界貢献度 $v(S \cup \{j\}) - v(S)$ を出現する全ての組み合わせで求めて平均している。(1)を用いた計算は記載しないが、上記例におけるAさん、Bさん、Cさんのそれぞれの平均的な限界貢献度（Shapley 値）に一致する。

ここまでに解説した Shapley 値を機械学習に応用し、特徴量の貢献度を計算する方法が SHAP である。具体的には、モデルに投入した特徴量 $\mathbf{X} = (X_1, X_2, \dots, X_J)$ をゲームのプレイヤーと見立て、特徴量 j の貢献度 ϕ_j を Shapley の考え方を援用して測定する。SHAP と Shapley 値の違いは、限界貢献度の計算方法にある。Shapley 値を算出する際のプレイヤー j が参加することの限界貢献度 $v(S \cup \{j\}) - v(S)$ は、SHAP を計算する際には特徴量 j の値が“分かっている場合”と“分かっている場合”の予測値の差分を用いる。すなわち、 $v(S \cup \{j\})$ が特徴量 S が分かっている場合の予測値、 $v(S)$ が特徴量 S に加えてさらに別の特徴量 j の値が分かった場合の予測値を指す。したがって、 $v(S \cup \{j\}) - v(S)$ は特徴量 j が分かっている場合と分かっている場合での予測値の差分と解釈できる。

詳細な計算は省くが、[52] の p.178-181 に特徴量が 2 つの場合の SHAP 値の計算方法が記載されている。ここから、SHAP 値は各レコードの予測値に対して、特徴量 j が与える平均的な影響を表している。また、SHAP は各レコードの予測値を特徴量 j を入力したときの平均的な予測値（ベースライン）と各特徴量の貢献度の足し算の形に分解することができ（Additive Feature Attribution Method の 1 種）、その計算には線形性の仮定をおいていないので、任意のブラックボックスモデルに適用できる。

なお、SHAP はモデルの出力 $f(x)$ を d 個の特徴量の貢献度 $\phi_1, \phi_2, \dots, \phi_d$ および切片項 ϕ_0 （ベースライン）の和として、以下のようにも表現できる（[53], p.184）。

$$f(x) = f \circ h(z) \approx g(z) = \sum_{i: z_i=1} \phi_i + \phi_0 \quad (16)$$

すなわち、SHAP は z_i は 0 か 1 の 2 値を取るバイナリベクトルで、 $z_i = 1$ で特徴量の値が“分かっている場合”に着目してその寄与度の和でもってモデルの出力を近似する（説明する）ものであるとも言える。ここで、理想的な近似 $g(z)$ として、以下の 3 つの SHAP の公理が存在する（元論文である [43] にも記載があるが、[53], p.185 に則る）。ただし、モデル f および別のモデル f' について、それぞれ対応する 1 次近似 g, g' の係数を a_i, b_i とし、 z の i 番目の特徴量 z_i を 0 にしたベクトルを z_{-j} としており、元論文である [43] の Local accuracy が 1. に、Missingness が 2. に、Consistency が 3. に対応している。

SHAP の公理（[53], p.185, 定義 6.2 より引用）

1. $f(x) = g(z)$ 説明対象のデータ（機械学習表現 x , 可読表現 z ）について、モデル f の値と g の値が一致する。
2. $z_i = 0 \Rightarrow a_i = 0$ 可読表現 z_i が 0 ならば、その特徴量の寄与 a_i は 0 となる。
3. $f \circ h(z) - f \circ h(z_i) \leq f' \circ h(z) - f' \circ h(z_i) \Rightarrow a_i \leq b_i$ 可読表現 z_i の有無によるモデル f の予

測の変化（左辺）が別のモデル f' の予測の変化（右辺）よりも大きいならば、モデル f における z_i の寄与 a_i はモデル f' における寄与 b_i よりも大きい。

2024/9/30 における福井悠斗，小寄秀信，田畑智章の三者による会議議事録

会議の開催概要

2024/9/30 20:00 – 21:45 にて、「セッション中の購買予測モデルの応用」という論題で Zoom によるオンライン会議が開催されました。参加者は以下の通りです。

- 福井悠斗：東海大学 総合理工学研究科 総合理工学専攻 博士課程 2 年
- 小寄秀信：株式会社エニキャリア代表取締役 / 東海大学総合社会科学研究所客員教授
- 田畑智章：経営学部（湘南、品川キャンパス） / 情報通信学部 / 総合理工学研究科 / 情報通信学研究科教授

論題

福井悠斗の博士論文の成果（セッション中の購買予測モデルの構築）に対する実務的な価値の検討※福井悠斗の博士論文において対象としているモデル（セッション中の消費者の購買を予測するモデル；以降、単に“モデル”）が、実務の面でどのような活用がなされるのか、具体的なマーケティングへの応用事例を議論

導入

従来の学術論文を対象に、福井悠斗が調査したモデルの応用事例を列挙した（以下の 3 つ）。

1. セッション中に購入しないと予測された顧客にレコメンドを行う
2. セッション中に購入しないと予測された顧客に価格割引を行う
3. セッション中に購入しないと予測された顧客に Web サイトのパーソナライズを行う

福井悠斗はこれら 3 つの応用事例を基に、当該モデルは“非購入者を購入者に変える施策に対して適用することが有用である”との見解から、その価値を述べた。

その後、上記件に対し小寄氏より同意をいただいた。

小寄氏より提案

セッション中の購買予測モデルの応用に関して、小寄氏から以下の提案がなされました。例として当該サイトにおける購入率が 3% という状況を考えると、買わないと予測される 97% の顧客に対してクーポンや割引を提供することが効果的であるとのこと指摘をいただきました。すなわち、それら 97% の顧客に対する施策の結果、購入率が 0.5% 増加した際には、数百万円のコスト削減が見込めるため、その推定を行う必要があること。また、そのような場合には顧客獲得単価（CPA）の点からもその改善効果を示すことができるため、同様に CPA の推定も行う必要があること。まとめて、これら 2 つの定量化によって、当該モデルのマーケティングに対する有用性を示すことができることのご提案をいただきました。

以降の実施事項（福井悠斗の課題）

1. EC サイトにおける購入率（CVR）の調査
2. 購買を行わないと予測される消費者に限定したマーケティング施策の適用が及ぼすコスト削減効果の見積もり
3. 顧客獲得単価に対する改善がなされた場合のコスト削減，利益の増分に対する見積もり

※上記②と③を定量的に推定する

本研究で使⽤したプログラムコード（平均購買間隔の算出）

モデル構築・検証

```
import pandas as pd
import numpy as np

df = pd.read_csv("path/file_name")

need_df = df[['セッション ID', 'イベント発⽣日時', "セッション開始年月日", 'セッション開始時刻', 'セッション終了時刻', 'セッション時間 (秒)', '前回セッション ID', 'セッション PV 数', 'イベント滞在時間 (秒)', '大ジャンル', '中ジャンル', '小ジャンル', '商品 ID', 'UserID', '購買 CV フラグ', '受注 ID']]

#セッション時間 0 秒と 1 秒の削除
# "セッション時間 (秒)"が 0 または 1 である⾏を除外するが、"購買 CV フラグ"が 1 である⾏は保持する
need_df2 = need_df[((need_df["セッション時間 (秒)"] != 0) & (need_df["セッション時間 (秒)"] != 1)) | (need_df["購買 CV フラグ"] == 1)]

purchase_sessions = need_df2[["セッション ID", "UserID", "セッション開始年月日", "購買 CV フラグ"]][need_df2["購買 CV フラグ"] == 1].reset_index(drop=True)

# セッション開始年月日を⽇付型に変換
purchase_sessions['セッション開始年月日'] = pd.to_datetime(\
purchase_sessions['セッション開始年月日'])

# ユーザーごとに購買⽇を集計
user_purchases = purchase_sessions.groupby('UserID')['セッション開始年月日'].apply(list)

# 購買間隔を計算
```

```

def calculate_intervals(purchase_dates):
    if len(purchase_dates) < 2:
        return None

    purchase_dates = sorted(purchase_dates)

    intervals = [(purchase_dates[i] - purchase_dates[i-1]).days \
for i in range(1, len(purchase_dates))]

    return intervals

intervals_by_user = user_purchases.apply(calculate_intervals)

# None を削除
all_intervals = [interval for sublist in intervals_by_user.dropna() \
for interval in sublist]

# 平均購買間隔を算出
average_purchase_interval = sum(all_intervals) / len(all_intervals)

```

本研究で使⽤したプログラムコード（モデル構築）

モデル構築・検証

```

# import

import datetime as dt
import matplotlib.pyplot as plt
import pandas as pd
import shap
import xgboost as xgb

from imblearn.over_sampling import SMOTE, SMOTENC
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import precision_score, recall_score, \
f1_score, accuracy_score, confusion_matrix, roc_curve, auc
from sklearn.model_selection import train_test_split

# 読み込み
cv = pd.read_excel("path/file_name")

```

```

vieira = pd.read_excel("path/file_name")
esmeli = pd.read_excel("path/file_name")
fukui = pd.read_excel("path/file_name")
forgetting = pd.read_excel("path/file_name")

# 結合
tmp1 = pd.merge(cv, vieira, how="left", on="セッション ID")
tmp2 = pd.merge(tmp1, esmeli, how="left", on="セッション ID")
tmp3 = pd.merge(tmp2, fukui, how="left", on="セッション ID")
df = pd.merge(tmp3, forgetting, how="left", on="セッション ID")

# Vieira と Esmeli et al. と Chapter5 のモデリング -----

need_df = df.drop(['セッション ID', 'UserID', 'セッション開始時刻'], axis=1)

x = need_df[need_df.columns[need_df.columns != '購買 CV フラグ']]
y = need_df.loc[:, '購買 CV フラグ']

# 正規化の対象でないダミー変数を別に取り出す
genre_columns = ['Genre1', 'Genre2', 'Genre3', 'Genre4', 'Genre5']
x_genres = x[genre_columns]

# 正規化の準備（ダミー変数以外を正規化対象とする）
numeric_columns = [col for col in x.columns if col not in \
genre_columns]
std_scaler = StandardScaler()

# 正規化
x_numeric_sc = pd.DataFrame(std_scaler.fit_transform(\
x[numeric_columns]), columns=numeric_columns)

# ダミー変数を正規化後のデータと結合
x_sc = pd.concat([x_numeric_sc, x_genres.reset_index(drop=True)], \
axis=1)

# データ分割

```

```

x_train_val, x_test, y_train_val, y_test = train_test_split(x_sc, \
y, test_size=0.4, stratify=y, random_state=42)

x_train, x_eval, y_train, y_eval = train_test_split(x_train_val, \
y_train_val, test_size=0.4, stratify=y_train_val, random_state=42)

# 訓練データに SMOTENC を適用 1
sm_nc = SMOTENC(categorical_features=[\
'Genre1', 'Genre2', 'Genre3', 'Genre4', 'Genre5'], random_state=42)
x_train_resampled, y_train_resampled = sm_nc.fit_resample(x_train, \
y_train)

# 特徴量のリストを整理して変数に分ける
vieira_features = ['Ds', 'C/B', 'Genre1', 'Genre2', 'Genre3', \
'Genre4', 'Genre5', 'Duration', 'Hour(vieira)', 'Nc', 'Price', \
'Views24h', 'Viewsweek', 'SB']

esmeli_features = ['Hour(esmeli)', 'Day of the week', 'Weekend', \
'Day of the Year', 'Total Viewed Items', 'Total Unique Items', \
'Total Session Duration', 'Max_Popularity', 'Min_Popularity', \
'Duration Spent on a Product', 'Unique Categories']

chap5_features = vieira_features + ['SHHI']

# 特徴量のセットを辞書にまとめる
feature_sets = {
    'vieira': vieira_features,
    'esmeli': esmeli_features,
    'chap5': chap5_features,
}

# 特徴量の正規化とデータ分割
data = {}

for name, features in feature_sets.items():
    x_train_resampled_subset = x_train_resampled[features]
    x_eval_subset = x_eval[features]

```

```

x_test_subset = x_test[features]

data[name] = {
    'x_train': x_train_resampled_subset,
    'y_train': y_train_resampled,
    'x_eval': x_eval_subset,
    'y_eval': y_eval,
    'x_test': x_test_subset,
    'y_test': y_test
}

def size_checking(data, keys):
    for key in keys:
        print(f"{key}・x_train の形状: {data[key]['x_train'].shape}")
        print(f"{key}・y_train の形状: {data[key]['y_train'].shape}")
        print(f"{key}・x_val の形状: {data[key]['x_eval'].shape}")
        print(f"{key}・y_val の形状: {data[key]['y_eval'].shape}")
        print(f"{key}・x_test の形状: {data[key]['x_test'].shape}")
        print(f"{key}・y_test の形状: {data[key]['y_test'].shape}")
        print("-----")

keys = ['vieira', 'esmeli', 'chap5']
size_checking(data, keys)

def train_and_evaluate_model(var_name, data, num_boost_round=100):
    # 準備
    model_train = xgb.DMatrix(data[f'{var_name}']['x_train'], \
label=data[f'{var_name}']['y_train'])
    model_eval = xgb.DMatrix(data[f'{var_name}']['x_eval'], \
label=data[f'{var_name}']['y_eval'])

    # 結果保存用
    results = []

    # max_depth を 2 から 15 まで変更しながらモデルをトレーニング
    for depth in range(2, 16):

```

```

# ハイパーパラメータ
param = {'max_depth': depth, \
'objective': 'binary:logistic', 'random_state': 42, \
'eval_metric': 'auc'}

# モデルの学習と評価データセットの使用、アーリーストッピングを 10 ラウンドに設定
evals_result = {}

bst = xgb.train(
    param,
    model_train,
    num_boost_round,
    evals=[(model_train, 'train'), (model_eval, 'eval')],
    early_stopping_rounds=10,
    evals_result=evals_result
)

# 予測
model_test = xgb.DMatrix(data[f'{var_name}']['x_test'])
pred = bst.predict(model_test)

# ラベル予測（二値分類）
y_test = data[f'{var_name}']['y_test']
y_pred_binary = (pred >= 0.5).astype(int)

# パフォーマンスメトリクスの計算
fpr, tpr, thresholds = roc_curve(y_test, pred)
auc_score = auc(fpr, tpr)

# 結果の保存
results.append({
    'max_depth': depth,
    'Accuracy': accuracy_score(y_test, y_pred_binary),
    'Precision': precision_score(y_test, y_pred_binary),
    'Recall': recall_score(y_test, y_pred_binary),
    'F1-Score': f1_score(y_test, y_pred_binary),
    'AUC': auc_score,

```

```

        'y_pred_binary': y_pred_binary # 混同行列用に予測ラベルを保存
    })

    return results

# モデルを訓練・評価 (Esmeli et al. の場合)
var_name = "esmeli"
results = train_and_evaluate_model(var_name, data)

# 結果を DataFrame に変換
results_df = pd.DataFrame(results)

# 最も F1 スコアが高い結果を取得
best_result = max(results, key=lambda x: x['F1-Score'])

# 混同行列
conf_matrix = confusion_matrix(y_test, best_result['y_pred_binary'])

# SHAP 用に商品ジャンルを消した場合のモデルを構築
genre_nothing_x_sc = x_sc.drop(['Genre1', 'Genre2', 'Genre3', \
                                'Genre4', 'Genre5'], axis=1)

# データ分割
x_train_val, x_test, y_train_val, y_test = train_test_split(\
    genre_nothing_x_sc, y, test_size=0.4, stratify=y, random_state=42)
x_train, x_eval, y_train, y_eval = train_test_split(x_train_val, \
    y_train_val, test_size=0.4, stratify=y_train_val, random_state=42)

sm_nc = SMOTE(random_state=42)
x_train_resampled, y_train_resampled = sm_nc.fit_resample(x_train, \
    y_train)

# 特徴量の選択
feature_sets = {
    'vieira': ['Ds', 'C/B', 'Duration', 'Hour(vieira)', 'Nc', \

```

```

    'Price', 'Views24h', 'Viewsweek', 'SB'],
    'esmeli': ['Hour(esmeli)', 'Day of the week', 'Weekend', \
    'Day of the Year', 'Total Viewed Items', 'Total Unique Items', \
    'Total Session Duration', 'Max_Popularity', 'Min_Popularity', \
    'Duration Spent on a Product', 'Unique Categories'],
    'chap5': ['Ds', 'C/B', 'Duration', 'Hour(vieira)', 'Nc', \
    'Price', 'Views24h', 'Viewsweek', 'SB', 'SHHI'],
}

```

特徴量の正規化とデータ分割

```
data = {}
```

```

for name, features in feature_sets.items():
    x_train_resampled_subset = x_train_resampled[features]
    x_eval_subset = x_eval[features]
    x_test_subset = x_test[features]

    data[name] = {
        'x_train': x_train_resampled_subset,
        'y_train': y_train_resampled,
        'x_eval': x_eval_subset,
        'y_eval': y_eval,
        'x_test': x_test_subset,
        'y_test': y_test
    }

```

モデルを訓練・評価 (Esmeli et al. の場合)

```
results = train_and_evaluate_model(var_name, data)
```

SHAP に使用する用の特徴量の精査

```

class CustomDataFrame:
    def __init__(self, df, feature_sets):
        self.df = df
        self.feature_sets = feature_sets

    def __getitem__(self, key):

```

```

        if key in self.feature_sets:
            return self.df[self.feature_sets[key]]
        else:
            raise KeyError(f"'{key}' not found in feature_sets")

custom_x = CustomDataFrame(genre_nothing_x_sc, feature_sets)

x_df = custom_x[f"{var_name}"]

# 最も F1 スコアが高い結果を取得
best_result = max(results, key=lambda x: x['F1-Score'])

# 上記の結果の max_depth を用いたモデルを構築・訓練
param = {'max_depth': best_result['max_depth'], \
'objective': 'binary:logistic', 'random_state': 42, \
'eval_metric': 'auc'}

bst = xgb.train(
    param,
    model_train,
    num_boost_round,
    evals=[(model_train, 'train'), (model_eval, 'eval')],
    early_stopping_rounds=10, # 10 ラウンド連続で改善が見られない場合、学習を停止
    evals_result=evals_result
)

# SHAP
explainer = shap.TreeExplainer(model=bst, \
feature_perturbation='tree_path_dependent')
shap_values = explainer.shap_values(x_df)
shap.summary_plot(shap_values, x_df, show=False)

plt.savefig("file_name.png") # 画像を保存
plt.show() # グラフを描画

```

```
# 6章以降ははじめの54日を除外する(2010/8/24以降を抽出) -----
df_copy = df.copy()
df_copy["セッション開始時刻"] = pd.to_datetime(df_copy["セッション開始時刻"])
need_df = df_copy[df_copy["セッション開始時刻"] > dt.datetime(2010,8,23)]
need_df2 = need_df.drop(['セッションID', 'UserID', 'セッション開始時刻'], axis=1)

x = need_df2[need_df2.columns[need_df2.columns != '購買CVフラグ']]
y = need_df2.loc[:, '購買CVフラグ']
```

~~~~以降の処理は上記と同様~~~~

# 業績リスト

## 筆頭

## 論文

1. Yuto Fukui, Tomoaki Tabata and Takaaki Hosoda, “A Purchasing Prediction Model Considering Pre-purchase Behaviors”, International Journal of Service and Knowledge Management (IJSKM), Vol.6 No.1, 2022

## 国際会議

1. Yuto Fukui, Tomoaki Tabata and Takaaki Hosoda, “A Purchasing Prediction Model Considering the Time Consumers Spend On a Site and Consumers Characteristics”, 2020 9th International Congress on Advanced Applied Informatics (IIAI-AAI), Publisher: IEEE (Institute of Electrical and Electronics Engineers), page754-759, 2020（査読あり proceedings）
2. Yuto Fukui, Tomoaki Tabata and Takaaki Hosoda, “A Purchasing Prediction Model Considering the Time Consumers Spend on a Site and Consumers Characteristics(Second Report)”, 2021 10th International Congress on Advanced Applied Informatics (IIAI-AAI), Publisher: IEEE (Institute of Electrical and Electronics Engineers), page885-890, 2021（査読あり proceedings）
3. Yuto Fukui, Tomoaki Tabata, “Prediction of Consumer Purchases in a Session on an EC Site Considering the Variety of Past Browsing”, 26TH INTERNATIONAL CONFERENCE ON HUMAN-COMPUTER INTERACTION (HCI), Social Computing and Social Media, Publisher : Springer, pp247-261, 2024（査読あり proceedings）
4. Yuto Fukui, Tomoaki Tabata, “A Prediction Model for Consumer Purchase in a Session on an EC site”, the 24th Asia Pacific Industrial Engineering and Management Society (APIEMS), pp226-231, 2024（査読あり proceedings）

## 国内発表

1. 福井悠斗, 田畑智章, “消費者の購買行動の多様性がセッション中の購買予測に与える影響”, 日本心理学会第 88 回大会, 2024
2. 福井悠斗, 田畑智章, “EC サイト上におけるセッション中の購買予測モデルの応用”, 日本経営工学会

(2024 年春季)

3. 福井悠斗, 田畑智章, “吸収マルコフ連鎖を用いた顧客の離脱に関する研究”, 日本経営工学会 (2024 年春季)
4. 福井悠斗, 田畑智章, “インフルエンサーとしての YouTuber 総合評価モデル”, 日本経営システム学会 (第 72 回 (2024 年春季) 全国研究発表大会)
5. 福井悠斗, 田畑智章, “EC サイト上における消費者の購買経験に対する忘却を考慮したセッション中の購買予測”, 日本経営システム学会 (第 72 回 (2024 年春季) 全国研究発表大会)
6. 福井悠斗, 田畑智章, “EC サイト上における消費者の過去の閲覧行動の多様性を考慮したセッション中の購買予測”, 日本経営システム学会 (第 71 回 (2023 年春季) 全国研究発表大会)
7. 福井悠斗, 田畑智章, “消費者の過去の商品閲覧経験が現在の購買意思決定に及ぼす影響”, 日本心理学会第 87 回大会, 2023
8. 福井悠斗, 田畑智章, “EC サイトにおける消費者の行動の多様さと訪問経験を考慮したセッション中の購買予測”, 第 4 回 D-DATa プログラム主催, オンライン研究発表会「Flipped Conference」
9. 福井悠斗, 田畑智章, “EC サイト上における消費者の来店経験を考慮した購買行動の予測”, 日本経営工学会 (2023 年春季)
10. 福井悠斗, 田畑智章, “オンラインショップにおける商品レビューを利用したポジショニングマップ作成”, 日本経営システム学会 (第 70 回 (2023 年春季) 全国研究発表大会)
11. 福井悠斗, 田畑智章, “EC サイト上における消費者の閲覧経験を考慮した購買予測モデル”, 日本経営システム学会 (第 67 回 (2021 年秋季) 全国研究発表大会)
12. 福井悠斗, 田畑智章, “発展傾向にある幼年期企業における需要予測”, 日本イーコマース学会第 3 回学術大会, 2021 年秋
13. 福井悠斗, 田畑智章, “RFM 分析の限界に関する研究”, 日本経営システム学会 (第 66 回 (2021 年春季) 全国研究発表大会)
14. 福井悠斗, 田畑智章, “TAR モデルを用いた新型コロナウイルスによる株価への影響分析”, 日本経営工学会 (2021 年春季)
15. 福井悠斗, 田畑智章, “サイト閲覧時間と嗜好多様性を考慮した消費者行動モデル”, 日本経営工学会 (2021 年春季全国研究発表大会)
16. 福井悠斗, 田畑智章, “サイト閲覧時間と嗜好多様性を考慮した EC サイトにおける消費者行動モデル”, 日本イーコマース学会第 2 回学術大会, 2020 年秋
17. 福井悠斗, 田畑智章, “チェリーピッカーに対する経済性分析”, 日本経営システム学会 (第 65 回 (2020 年秋季) 全国研究発表大会)
18. 福井悠斗, 田畑智章, “サイト閲覧時間と消費者嗜好の多様性の観点から見た購買行動に対する要因分析”, 日本経営システム学会 (第 64 回 (2020 年春季) 全国研究発表大会)
19. 福井悠斗, 田畑智章, “オムニチャネルにおける消費者購買行動に関する研究”, 日本経営システム学会 (第 64 回 (2020 年春季) 全国研究発表大会)
20. 福井悠斗, 田畑智章, “顧客の購買過程を考慮した EC サイト上における購買予測モデル”, 日本経営工

学会（2020 年春季）全国研究発表大会

21. 福井悠斗，田畑智章，“EC サイト上における顧客の購買に至るまでの行動を考慮した購買予測モデル”，日本経営システム学会（第 63 回（2019 年秋季）全国研究発表大会）
22. 福井悠斗，田畑智章，“深層学習を用いた EC サイト上における顧客の購買予測”，日本経営システム学会（第 62 回（2019 年春季）全国研究発表大会）

## 受賞

1. 日本経営システム学会（第 71 回（2023 年秋季）全国研究発表大会），学生研究発表優秀賞
2. 東海大学情報通信学研究科情報通信学専攻，修士論文・優秀研究賞
3. 2021 10th International Congress on Advanced Applied Informatics (IIAI-AAI), Honorable Mention Award
4. 東海大学情報通信学部経営システム工学科，卒業論文・優秀研究賞

## 紀要

福井悠斗，田畑智章，小嵯秀信，キャンペーン情報がない中でのチェリーピッカーの特定に関する研究，東海大学総合社会科学研究所，2021

## 共著

### 国内発表

1. 安財玲央，福井悠斗，田畑智章，“インフルエンサーマーケティングを視野に入れた YouTuber 評価モデル”，日本イーコマース学会第 6 回学術大会，2024 年秋
2. YAN HAOTONG，福井悠斗，田畑智章，“アニメの放映期間がアニメグッズの売上に与える影響”，日本イーコマース学会第 6 回学術大会，2024 年秋
3. 江澤美花，福井悠斗，田畑智章，“TAR モデルによる売上変化のタイミング分析”，日本経営工学会（2024 年秋季）
4. 田畑智章，福井悠斗，田畑智章，西口宏美，荒井真哉，室井伸昭，佐久間一樹，吉田正廣，“ChatGPT による電話相談サービス支援システム，日本オペレーションズ・リサーチ学会 2024 年春季研究発表会，2024
5. 久島尚貴，福井悠斗，田畑智章，小嵯秀信，“自転車配送による CO2 削減量の算出”，日本イーコマース学会第 5 回学術大会，2023 年秋
6. 峯島海瑠，福井悠斗，田畑智章，“感情分析を用いた野球選手の採点システムの構築”，日本イーコマース学会第 5 回学術大会，2023 年秋
7. 坂田陸飛，福井悠斗，田畑智章，小嵯秀信，“球場内デリバリーの業務効率に関する研究”，日本イーコマース学会第 5 回学術大会，2023 年秋
8. 松尾凌汰，福井悠斗，田畑智章，東弘樹，“Google Map の店舗レビューに対するタイプ分類”，日本イー

コマース学会第 5 回学術大会, 2023 年秋

9. 吉田涼一, 福井悠斗, 田畑智章, “E-SPORTS サイトのアクセスログ解析”, 日本イーコマース学会第 5 回学術大会, 2023 年秋
10. 赤石玲子, 福井悠斗, 田畑智章, “デリバリースタッフの効率性評価”, 日本イーコマース学会第 5 回学術大会, 2023 年秋
11. 大澤圭介, 福井悠斗, 田畑智章, “循環変動を考慮した売上予測モデル”, 日本経営工学会 (2021 年春季)