

小売業における心理会計の消費者行動に対する  
影響メカニズムの研究

筑波大学審査学位論文（博士）

2019

宮津 和弘

筑波大学大学院  
ビジネス科学研究科 企業科学専攻

# 目次

<b>第1章</b>	<b>序論</b>	<b>1</b>
1.1	研究背景と問題意識	1
1.2	研究の目的	7
1.3	本研究の構成	9
<b>第2章</b>	<b>先行研究のレビュー</b>	<b>11</b>
2.1	先行研究のレビュー領域	11
2.2	消費者の心理会計に関する研究	13
2.3	レジームスイッチングに関する研究	15
2.4	消費者世帯の消費者購買行動の研究	22
2.5	サーベイ研究まとめと本研究の関連	30
<b>第3章</b>	<b>心理会計と購買点数モデリング</b>	<b>35</b>
3.1	はじめに	35
3.2	先行研究	35
3.3	モデル	36
3.4	アルゴリズム	44
3.5	実証分析	46
3.6	まとめ	58
<b>第4章</b>	<b>心理会計と来店間隔モデリング</b>	<b>60</b>
4.1	はじめに	60
4.2	先行研究	60
4.3	モデル	61
4.4	アルゴリズム	65
4.5	実証分析	67

4.6	まとめ	82
<b>第 5 章</b>	<b>心理会計モデルの二次元化拡張と来店間隔モデリング</b>	<b>83</b>
5.1	はじめに	83
5.2	先行研究	83
5.3	モデル	84
5.4	アルゴリズム	90
5.5	実証分析	92
5.6	まとめ	116
<b>第 6 章</b>	<b>結論</b>	<b>119</b>
6.1	本研究の結論	119
6.2	本研究の学術的貢献	122
6.3	本研究で残された課題	124
	参考文献	<b>126</b>
<b>付録 A</b>	<b>第 3 章の付録</b>	<b>135</b>
A.1	分布パラメータの構造化	135
A.2	推定アルゴリズム	135
A.3	推定用 R プログラム	138
<b>付録 B</b>	<b>第 4 章の付録</b>	<b>147</b>
B.1	分布パラメータの構造化	147
B.2	推定アルゴリズム	147
B.3	推定用 R プログラム	150
<b>付録 C</b>	<b>第 5 章の付録</b>	<b>159</b>
C.1	分布パラメータの構造化	159
C.2	推定アルゴリズム	161
C.3	推定用 R プログラム	163
C.4	対数周辺尤度および DIC によるモデル評価	174

# 第1章 序論

## 1.1 研究背景と問題意識

### 1.1.1 消費者ライフスタイルの変化

日本の世帯構造は、単身世帯と夫婦のみ二世帯が増加傾向にあり、これに伴う単身化、晩婚化、共働き化、少子高齢化などが消費者ライフスタイルに大きな影響を与えている。さらに、労働人口不足、長時間労働、非正規と正社員の雇用格差などが引き起こされ、大きな社会問題となっている。この問題に対して、政府は働き方改革実行計画を立案し、一億総活躍社会の実現を図る。働き方改革では、ライフステージに合った就労形態、高齢者の積極雇用、多様なキャリアパス、テレワーク等による柔軟な就労環境の整備、同一労働同一賃金の実現などにより、賃金の上昇と需要拡大を促進させ、人々の豊かな生活を目指している。また、Gratton and Scott (2011) は、「長寿化の恩恵に最大限浴するためにはどのような選択をすべきかを、いまずぐに考えはじめたほうがいい」と、人生100年時代に対応するライフスタイルの変化に備えるよう警鐘を鳴らしている。100年人生の計画を立てるには、自身は何を欲して、それをどのように達成したいか、明確な考えを有する必要がある。2008年のリーマンショック以降、日本の経済成長は鈍化し、個人消費も冷え込む中、2014年4月に消費税率が8%に引き上げられ、2019年10月には更なる引き上げが予定されている。これにより、耐久消費財の買い替えが促される一方で、カーシェアリングや民泊などのシェアリングエコノミーが消費者ライフスタイルに浸透し始めている。豊かさの象徴である高価な車や宝飾品の所有を目指すライフスタイルから、自分は本当に何を欲しているのかが現代の消費者には問われている。2011年の震災以降、人々は家族や仕事に対する価値観と向き合う機会が多くなり、高度経済成長以降の仕事を中心としたライフスタイルから、家族との時間を重視したライフスタイルへ変化しつつある。消費面においては、スマートストックという概念で、水や食料を家庭内在庫としてある程度備蓄し、より賢く消費する考え方が広まり始めている。これらの財を複数の消費者でストックすることは、シェア

リングエコノミーの考え方であり、無形資産も含めた資産の活用形態にも変化をもたらす。また、現代の消費者ライフスタイルに欠かせないものにスマートフォンがある。総務省の通信利用動向調査によれば、この5年間で消費者のスマートフォン所有率は、およそ4倍の56.8%まで上昇した。さらに、スマートフォン利用者1日あたりの利用時間も増加し、10～20代では2時間以上と長く、SNS、動画、オンラインゲームが主な用途である。30～50代でも、1時間程度がSNS、ネット検索、メールなどに費やされている。このように、急速にスマートフォンが普及されたことによって、消費者ライフスタイルにも影響を与えている。2015年に野村総合研究所が1万人を対象に行った調査によると、スマートフォンの普及により、価格にこだわらず、便利な手段を利用して欲しいものを買う利便性消費が増加しているという。いつでも、どこでもインターネットにアクセスできる環境が整うことで、自分が本当に欲しいものを、欲しい時に入手できるようになり、購買の意思決定が多様化した。さらに、スマートフォンの普及により、消費者の一人行動がしやすくなったという。スマートフォンによるSNSの普及により、一人でいても他人とつながる機会は多く、一人でいることに対する抵抗感も軽減している。さらに、社会的にも一人行動が容認され、一人によるアウトドア系レジャーのソロキャンプや海外の一人旅などは年々増加している。

バブル経済崩壊、リーマンショック、東日本大震災を経験して、消費者ライフスタイルは単一の量的豊かさを求める趣向から、多様な質的豊かさにプライオリティーをおくスタイルに変容している。消費者は、各ライフステージにおいて、いまの自分に何が必要かを意識し、多くの選択肢の中からその時点で最良のものを選択する。各時点で意思決定するための判断基準は、消費者の置かれた心理的状况にも大きく影響されるため、小売業者も消費者ライフスタイルの変化に対応して、商業形態を変化させていくことが求められている。

### 1.1.2 小売業態構造の変容

日本のGDPのうち家計最終支出は全体の約60%を占め、日本経済の支えとなっている。高度経済成長期以降、同様の傾向を示す一方、消費支出の内訳は、家具・家事用品と衣料品の支出割合は減少し、代わりに交通通信費が増加している（総務省統計局, 2014）。日本の小売業態は、高度経済成長期以降、単一の量的豊かさを求めた消費者ライフスタイルに対応した百貨店が席卷し、1980年頃は郊外型の総合スーパーが小売業売上高ではトップを占めていた。バブル経済崩壊の1990年代に入ると、日本経済はデフレ状態に陥り、価

格を重視した家電製品や衣料品などを扱う専門量販店が台頭する。消費者ニーズも多様化し、専門性の高い品揃えを求める消費者に対応できない業態は淘汰されることになる。熊倉（2016）によれば、消費者の購買行動は、周囲が買うから自分も買うという消費から、消費者にとって価値あるものを厳選して、本当に必要なものだけを買うという消費に価値観が変化したという。2000年代に入ると、少子高齢化、小世帯化、共働き化により、中食化と少量需要からコンビニエンスストアの店舗数が急増する。そもそも大型店舗の進出により、劣勢を強いられていた地域商店がフランチャイズ方式のコンビニエンスストアとして出店形態を変化するケースが増加したためである。

世帯ごとの項目別平均消費支出で見ると、食料費の占める割合が20%以上と最も高い（総務省統計局, 2014）。また、流通経済研究所の集計によれば、2015年度の食品小売市場に占める業態別シェアの50%はスーパーマーケットで、それに続くコンビニエンスストアのシェア17%との差は圧倒的である。加藤・木島（2017）は、食品小売販売額のシェアは10年後の2025年までにはスーパーマーケットで54%、コンビニエンスストアで21%まで上昇すると予測している。一方で、一般EC市場が拡大するなか、食品に対するEC化は2%程度とあまり進んでおらず、実店舗での売上が大半を占める（全国スーパーマーケット協会, 2018）。日本におけるEC市場規模は317兆円にまで拡大し、その大半が物販である。EC化率の高い分野は、文房具、電子機器、生活家電、書籍などで30%前後（経済産業省商務情報政策局, 2017）である。EC化率は低い市場規模が大きな分野はアパレル、旅行、食品、酒類などであり、今後EC化が進むことで市場拡大が期待される。逆に、アマゾンなどのようなEC専門業態が、実店舗での販売に進出するケースもある。同社は、ECで取り扱いのあるワインや日本酒をグラスで販売するアマゾンバーが銀座にオープンし、米国ではオーガニック食品を扱う無人化店舗のAmazon Goがオープンしている。

消費者ライフスタイルの変化とスマートフォンやSNSの普及により、小売業態は消費者ニーズに応えながら変容し、小売業態の主流であるスーパーマーケット、コンビニエンスストア、ドラッグストアの垣根もなくなりつつある。2009年の改正薬事法（現在、薬機法）により、一定の条件を満たせば、コンビニエンスストアやECでも薬を販売することは可能であり、ドラッグストアが食料品を扱うのも現在では一般化している。そして、小売業態はネットとリアルを融合したオムニチャネル業態へ変化している。ECと実店舗のサービスがシームレスにつながることで、消費者とのコンタクトポイントが増加し、消費者に対する状況に応じたマーケティング活動が可能となる。小売業態をオムニチャネル化するこ

とで、ネットで検討した選択肢に対して店頭で意思決定させたり、店頭で興味を引いたものを後日 EC で購入を促すといったマーケティング戦略が可能となる。このように、消費者ライフスタイルの変化に合わせて小売業態も変容し、消費者はさまざまなシーンにおいて購買の意思決定が可能である。それにともない、同じ商品でも消費者反応は状況によって変化し、消費者の意思決定プロセスは複雑となる。そのため、今後は消費者の心理的な状況を含めた、潜在的な情報も積極的に活用したマーケティング活動が求められる。

### 1.1.3 マーケティングの多様化

日本の広告費市場は、2017 年は 6.4 兆円と前年比 101.6 の微増である。その内訳を見ると、マスコミ 4 媒体広告とプロモーションメディア広告で対前年比割れ、インターネット広告は 6 年連続で前年実績を上回り、日本の広告市場を牽引している（「2017 年日本の広告費」電通）。広告費が最も多い業種は、情報・通信の分野であり、世帯ごと消費支出で通信・交通費が年々増加しているのと整合的である。本論文テーマの小売・流通分野では、広告費は前年比-9.7%と減少している。その背景には、もともと小売業態ではチラシなどの紙媒体を中心にメディア投資をしてきたが、消費者ライフスタイルの変化にともない新聞購読者が減少し、効率的な広告投資が実施できないことがある。小売業態の EC 化率は低く、マーケティング領域においても、ネットチラシなどと限定的で、デジタル化が進んでいない。

インターネット広告のうち、モバイル広告の割合は、2014 年にデスクトップ広告を抜くほど急激に増加し、2017 年には全体の 72%を占める（「2016 年インターネット広告市場規模推計調査」電通グループ）。消費者ライフスタイルがモバイル化したことで、広告出稿もモバイルをターゲットとするデジタル広告が増加した。一般的なデスクトップ向けのバナー広告とは異なり、プッシュ型配信が可能なモバイル広告は、消費者の状況に応じたコンテンツ配信が可能となる。スマートフォンに搭載された GPS 機能とワイヤレス LAN による位置検出機能を駆使したジオマーケティングでは、消費者の位置を正確に把握することで、きめ細やかな広告配信が可能であり、オムニチャネル業態をサポートしていくための重要なマーケティング手法として期待される。

デジタルマーケティングの領域では、消費者に関する様々な属性データを活用した DMP (Digital Management Platform) を採用する広告主も増えている。デジタルマーケティング先進国であるアメリカなどでは、性別や年齢など基本的な消費者属性情報だけでなく、家

族構成や年収などの個人情報も第三者データとして入手可能であり、DMPに統合されている。また、人工知能やIoT技術を駆使しながらデータを収集して、DMPに消費者の行動データとして蓄積しているケースも少なくない。さらに、消費者のおかれた状況をルール化し、消費者の蓄積された属性データと逐次更新される行動データを照合しながら、自動的にマーケティング施策を実施するMA（Marketing Automation）技術の開発がデジタルマーケティングでは進んでいる。

最近では、マーケティング領域に脳科学を取り入れたニューロマーケティングが、TVCM制作や新商品開発に活用されている。実際に消費者の頭部に電極を取り付けて、素材や新商品を試す際の反応を脳波から読み取り、マーケティングに利用する。消費者ごとの感性情報として蓄積するまでには至っていないが、消費者の置かれた状況の深層心理に応じたマーケティング施策を実施することも可能となる。心理的な面を取り入れた領域として、行動経済学がある。2002年にKahneman and Smithが、行動経済学と実験経済学の功績でノーベル経済学賞を受賞し、2017年にはThalerが行動経済学の功績でノーベル経済学賞を受賞した。これら受賞を機に、行動経済学のマーケティングへの応用が注目され、一見すると非合理的な消費者行動を考慮したマーケティングが実践されている。

消費者ライフスタイルの変化に合わせて、小売り業態構造も変容し、マーケティング手法も従来のマスマーケティングからデジタルマーケティングへシフトしている状況において、消費者ごとの属性情報を活用したマイクロマーケティングが実践されている。消費者ごとの購買データだけでなく、購買とは直接関係のない行動データもマーケティングに活用されている。今後は、消費者の心理的な側面も考慮したマーケティングの必要性が増すと考えられる。しかしながら、消費者の心理的要因を測定することは、現時点ではほとんど不可能であり、いかにして消費者の心理的状況を把握し、マーケティングに生かしていくかが求められている。

#### 1.1.4 問題意識

現代では、消費者ごとの購買データが入手可能となり、過去の購買履歴にもとづいたマイクロマーケティングが実践されている。特に、デジタルマーケティングの領域では、消費者の属性情報、位置や行動データを用いて、消費者がおかれている状況に最も合致したアクションを起こすことが求められる。一方で、消費者の心理的状況が購買行動に与える影響についての理解は不十分である。これを克服すべく、本研究の主要な問題意識は、消

費者の購買行動に与える心理的影響要因の構造の解明にある。心理的影響要因を構造化して、どのように消費者モデルへ取り込むべきかを論じた研究はほとんどなく、十分な検証はなされていない。そこで、本研究における問題意識として、以下に掲げる6点に着目し、小売業における心理的要因が購買行動に及ぼす影響を解明する。

■ 1. 心理的影響要因の構造 消費者がスーパーマーケットやコンビニエンスストアなどの小売店舗で日常的に購買するのは、食品および日用雑貨品であり、消費支出の点で最も割合が高い品目である。このような頻繁に購買を繰り返す状況において、消費者は収支バランスに配慮し、家庭内在庫量の多少を調整しながら購買意思決定を行う。本研究の問題意識の主眼である心理的影響要因は、消費者の収支バランスによる圧力と家庭内在庫バランスによる圧力に分けて考える。いずれの影響要因に関して、いかにしてそれらを推定するかを扱う研究はあるが、購買行動に対する影響を詳しく検討したものは見当たらない。

◆ 1-1. 収支バランスによる圧力 消費者収支の心理的影響は、行動経済学の領域で議論されている。Thaler (1985) は、心理会計という概念で消費者の心理的状況が購買行動に影響を与えることを説明した。伝統的経済学では、消費者の購買行動は効用が最大化するよう合理的に意思決定されると論じるが、心理会計では一見非合理的と思える消費者行動を議論する。しかしながら、これまでの心理会計に関する研究では、新たな消費者行動のアノマリーに関するマクロ的な発見にとどまり、消費者レベルで心理会計の影響をモデルに取り込んだ先例は見当たらない。心理会計の概念を定量化してモデルに採用した先例はなく、心理的影響因子のモデル構造を明らかにする意義は大きい。

◆ 1-2. 家庭内在庫バランスによる圧力 時間あたりの消費量は一定であるという仮定の下、Bucklin and Lattin (1991) は、漸化式で家庭内在庫量を推定した。また、時間あたりの消費量は一定ではなく、在庫量に応じて動的に変動すると仮定し、佐藤・樋口 (2007) は状態空間モデルを用いて、家庭内在庫量を推定している。しかし、推定された家庭内在庫量は、直接効果としてモデル変数に取り込み、消費者反応を分析するにとどまり、潜在的な効果として消費者の心理的状況を表すレジームスイッチングの情報として用いられた例はない。このことから、家庭内在庫を心理的影響要因として、定量的に把握することは、今後のマーケティング活動にとっても大変意義のあることである。

■ 2. 消費者異質性 趣味や嗜好と同様に、消費者の心理的な異質性は高い。収支バランスは、消費者の世帯年収や世帯構成にも関連している。消費者の金銭感覚やライフスタイル

にも直接関係し、世帯の収支バランスから受ける心理的な圧力はばらつく。さらに、常備する家庭内在庫量は、消費者の世帯構成や備蓄環境に依存し、その在庫バランスが及ぼす心理的圧力も消費者ごとに異質である。このように、心理的影響を検討する際に、消費者レベルの異質性を仮定することは必須の要件である。

■ 3. 確率分布の異質性 発生点数をモデリングする際、ポアソン分布を仮定するのが一般的だが、時間間隔の場合には、ワイブル分布、対数正規分布、対数ロジスティック分布など複数の確率分布が選択肢として存在する。特に、ハザード関数を導出する際は、元の確率分布に特性が依存する。また、これまでの時点間隔の研究では、特定の外部要因が時点間隔に影響を及ぼすか否かに問題意識をおいており、比例ハザードの枠組みでの検証が多数を占める。共変量の直接的影響を分析するには、これでも充分ではあるが、心理的状況によって確率分布が変化するか否かについては、これまで詳細に検討されてきた例はない。

■ 4. 購買点数 購買点数は、小売店舗で消費者が下す購買意思決定の回数を表し、小売業者にとって重要な経営指標の一つである。小売店舗における非計画購買率は70～80%と言われており、店舗内での購買意思決定には、値引きや特別陳列などのプロモーションによる影響が大きい。これまでの購買点数に関する研究では、プロモーション効果を検証することが多く、同一の消費者でも状況によって異なる消費者反応を示すことに関しては、充分に検討がなされていない。

■ 5. 来店間隔 来店間隔は、小売店舗と消費者の接点（コンタクト）頻度を表し、小売業者にとって重要な経営指標の一つである。時点間隔の問題では、共変量の効果を比例ハザードの枠組みで評価することが多い。共変量が同一でも、心理的な状況に応じて、消費者反応が異質となることについて詳細には検討はされていない。また、そもそも尤度を与える確率分布が、消費者の状況によって異なる場合には、比例ハザードの枠組みだけで議論することは難しい。

## 1.2 研究の目的

本研究は、1.1節に示した問題意識にもとづき、小売業における心理会計の消費者購買行動に対する影響メカニズムを明らかにすることを目的とする。その解明にあたっては、購買機会ごとに消費者が感じるであろう収支バランスおよび家庭内在庫バランスからの圧力をモデル化し、購買点数および来店間隔を説明する消費者行動モデルをID-POSデータを

用いて推定する。実際には、消費者が感じる心理的圧力は観測することはできないため、収支バランスからの圧力には給料日からの累積購買金額を、家庭内在庫バランスからの圧力には在庫量を金額換算した在庫金額を用いた閾値型レジームスイッチングモデルで検証する。これらバランスと収入、購買、消費の関係を図 1.1 に示す。通常、消費者世帯は月給として給料収入を得て、小売店舗での購買活動を通して支出する。その度に、消費者世帯の収支バランスは変動し、家庭内在庫バランスも購買と消費の活動を通して変動する。消費者世帯が生活を継続する限り、収支バランスに変動が生じなければ、家庭内在庫バランスは、いずれゼロとなる。また、支出バランスの変動は月次で発生し、家庭内在庫バランスは、これに依存した消費活動とともに変動する。よって、消費者世帯に対する心理的影響要因は、収支バランスの圧力が支配的となり、本研究の影響メカニズムでは、これを主要要因として捉えて研究テーマを構成する。

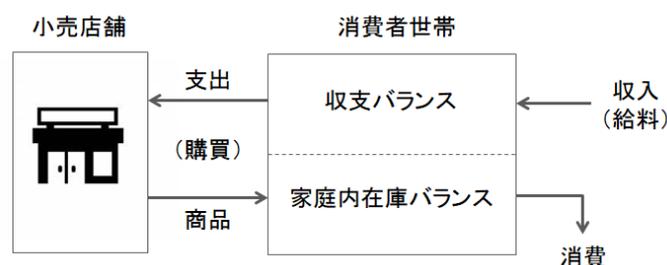


図 1.1: 心理的影響要因の構成

購買点数と来店間隔の関係は、Bucklin and Lattin (1991) に従うと、(1.1) 式の通りに表せる。これは、図 1.1 の家庭内在庫バランスを数式で表したものに等しい。

$$INV_t = INV_{t-1} + Q_{t-1} - CR \cdot I_{t-1,t} \quad (1.1)$$

購買機会  $t$  における家庭内在庫量  $INV_t$  は、購買機会  $t-1$  における家庭内在庫量  $INV_{t-1}$  に、購買機会  $t-1$  における購買量（購買点数） $Q_{t-1}$  を加えたものから、一日あたりの平均消費量（ $CR$ ：定数）と購買機会  $t-1$  から購買機会  $t$  の間の経過時間（来店間隔） $I_{t-1,t}$  の積を差し引いたものとして表す。ここで、家庭内在庫量が毎回の購買機会ですべて常に一定量を維持するような購買行動をとるならば、家庭内在庫量の初期値  $INV_0$  で決まる購買行動となる。しかしながら、実際には、消費分だけを正確に補充し続けるような購買行動を仮定するのは現実的ではなく、購買点数と来店間隔は最大家庭内在庫量を超えない範囲で、それぞれ変動する。本研究では、購買点数と来店間隔を別々に扱い、これらを同時にモデル化しな

い。その理由は、本研究の目的が、心理的要因が購買行動に与える影響の解明であり、購買点数と来店間隔の同時モデルに心理的要因を含めることで、結果の解釈が複雑になるのを避けるためである。これに基づき、図 1.2 には、本研究の3つのテーマと、冒頭の6つの着眼点の関係を模式化した。

第一のテーマでは、本研究の主要概念である心理会計の効果として、収支バランスの圧力による影響を閾値モデルの枠組みで構築し、購買点数モデルに対して、スーパーマーケットの ID-POS データを用いて実証する。第二のテーマでは、収支バランスの圧力による影響を来店間隔モデルに対して組み込み、来店間隔と心理会計の影響をスーパーマーケットの ID-POS データで実証する。第三のテーマでは、購買点数と来店間隔を (1.1) 式の家内在庫バランスを考慮することで融合させ、収支バランスと家内在庫バランスという二つの指標を用いて、閾値モデルの二次元拡張を試みる。この二次元化された枠組みで、消費者の来店間隔をモデル化し、ID-POS データで実証する。

それぞれの研究テーマの実証分析に使用するデータは、都内で営業するスーパーマーケットの1店舗で記録された ID-POS データで、学術利用目的で業者から購入されたものであり、消費者の匿名性は担保されたものである。テーマ1、テーマ2および3では、小売業系列および店舗は異なるが、いずれも大手小売業社の一つであり、信頼性の高いデータである。そのため、本実証分析から得られた知見の汎用性は高いと考えられる。

### 1.3 本研究の構成

本研究の構成は次の通りである。第2章では、本研究に関する先行研究を整理し、心理会計と消費者購買行動の関係性とその周辺について、先行研究をレビューする。その上で、研究課題を抽出し、本研究の学術的貢献に関しての位置づけを明確にする。第3章では、テーマ1の研究結果を示す。収支バランスの圧力からの心理的影響と購買点数の関係性を、閾値型レジームモデルの枠組みと階層ベイズを組合せて実証する。モデルの推定結果から、消費者ごとに異質な収支バランスの圧力からの心理的影響による購買レジームの切替点とそれぞれの消費者反応特性を考察する。第4章では、テーマ2の研究結果を示す。収支バランスの圧力からの心理的影響と消費者の来店間隔の関係性を、閾値型レジームモデルの枠組みと階層ベイズを組合せて実証する。モデルの推定結果から、レジームの切替点と消費者反応特性を考察する。第5章では、テーマ3の研究結果を示す。収支バランスおよび購買点数と来店間隔を関連させた家内在庫バランスの二つの圧力による心理的影響と来

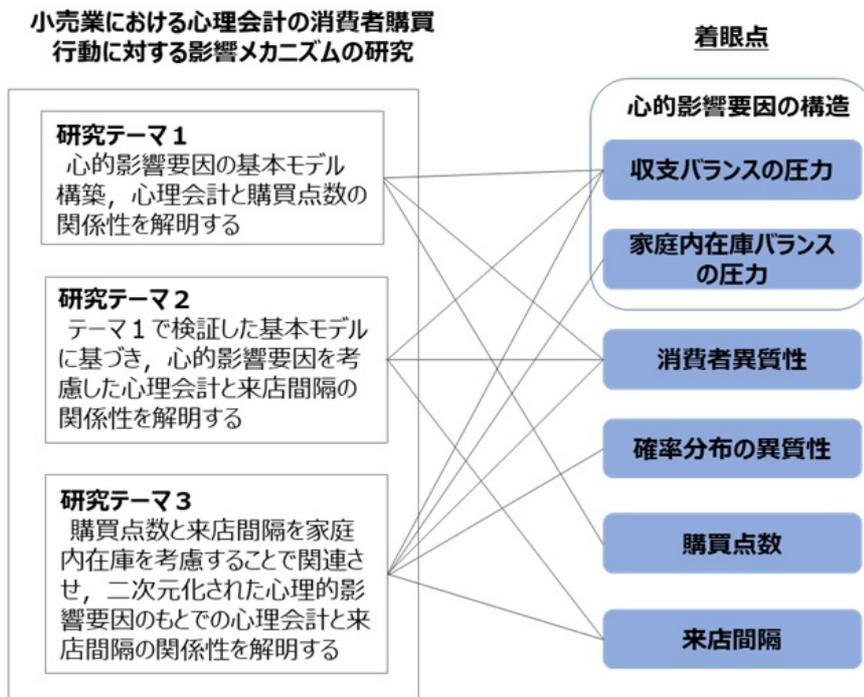


図 1.2: 本研究の3つのテーマと対応する着眼点

来店間隔の関係性を閾値型レジームモデルの枠組みと階層ベイズを組合せて実証する。各来店レジームの確率分布は異質であると仮定し、レジームの切換点とそれぞれの消費者反応特性を考察する。第6章では、本研究のまとめを示す。第3章、第4章、第5章の各テーマから得られた研究結果を総括して、学術的貢献と実務におけるマーケティング領域への応用に対する示唆を与える。また、本研究を通して発見された新たな課題および今後の研究の方向性についてまとめる。

## 第2章 先行研究のレビュー

### 2.1 先行研究のレビュー領域

本研究の目的は、小売業における心理会計の消費者行動に対する影響メカニズムを明らかにし、消費者の心的状況を考慮した効果的なマーケティングを実施するための示唆を与えることにある。そのため、第一のレビュー領域は消費者の心理会計に関する先行研究である。心理会計は、Thaler (1985) によって提唱された概念で、消費者の心的状況が消費者行動に影響を与えるというものであり、行動経済学以外にもファイナンスやマーケティングなど多岐にわたる領域で議論されている。消費者は常に合理的行動を取る経済主体であるとする伝統的経済学に対して、行動経済学では、消費者は常に合理的であるとは限らず、一見して非合理的である行動も選択することを前提とする。心理会計の研究は、消費者行動アノマリーを見つけ出して事例報告することが多く、それをマーケティングモデリングに組み込んだ実証例はほとんどない。心理会計を定量的に理解するために、第一のレビュー領域では、心理会計を引き起こす消費者の心的状況の影響因子に関連する先行研究を整理する。

本研究では、同一消費者でも、心理的状況によって異なる消費者行動を示すことを前提とし、消費者の心理的な負荷に応じて異なる購買および来店レジームを設定する。したがって、第二のレビュー領域はレジームスイッチングに関する先行研究である。レジームスイッチングに関する研究は、金融や経済学分野で、ある時期の金融や経済の局面が通常とは異なる状況だと事後的に分析するデータドリブン型のアプローチの研究が多い。背後に存在する直接観測できない潜在的な状態が時間進展にともない切り替わるという仮定でモデル化される。一方、本研究で採用するアプローチは閾値型モデリングアプローチで、閾値パラメータと閾値変数を用いて、消費者購買行動に対する影響メカニズムの切り替えを明示的に取り込む。レジームスイッチングのレビュー領域では、これら異なるアプローチとともに、異質性の組み込み方も含めて整理する。

本研究が対象とする心理会計の消費者行動への影響は、小売業における消費者の購買点

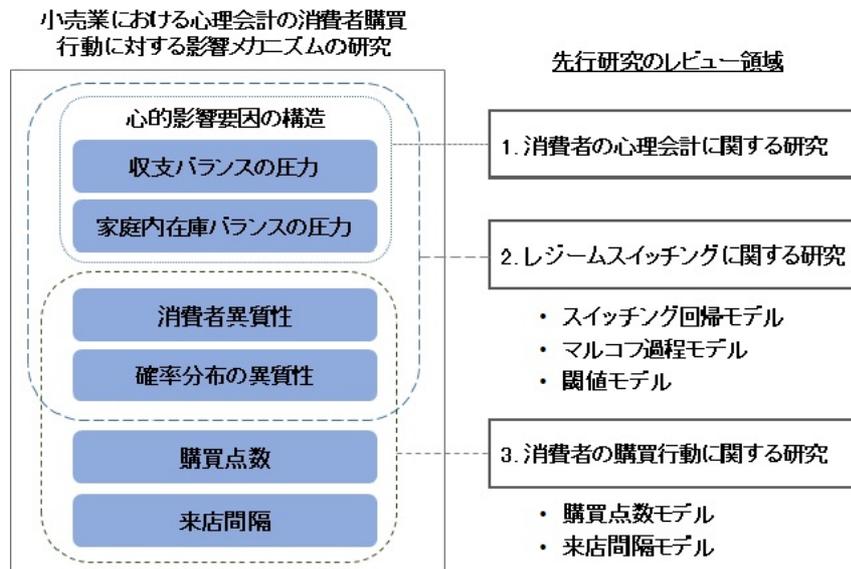


図 2.1: 本研究の着眼点と先行研究のレビュー領域

数および来店間隔である。特定のカテゴリーや商品を対象としたブランド選択問題とは異なり、小売業者の視点では、高頻度で多くの商品を購入する消費者に最大の関心がある。よって、第三のレビュー領域は、小売業における消費者の購買点数と来店間隔である。消費者の購買機会あたりの単価を購買点数と捉えるのは、商品単価に依存せず、消費者が小売店舗で購買意思決定を下す数に相当するためである。また、来店間隔は、購買の多少に関わらず、小売業者との接点（コンタクト）頻度を表し、消費者を理解するために重要な経営指標であり、購買点数と併せて先行研究を整理する。

以上の内容に沿って、先行研究を次の構成でレビューする。2.2 節で消費者の心理会計に関する先行研究、2.3 節ではレジームスイッチングに関する先行研究を、2.4 節では消費者行動（購買点数および来店間隔）に関する先行研究のレビュー結果を示す。2.5 節にサーベイ研究のまとめ、それを踏まえた本研究の狙いを示す。

## 2.2 消費者の心理会計に関する研究

心理会計 (Mental Accounting) は、認知心理学とミクロ経済学の合成概念として、Thaler (1985) が提唱したものであるが、当初 Thaler (1980) は *Mental Illusion*<sup>1</sup> と呼んでいた。そもそも、消費者は合理的であり、自身の効用が最大化されるよう意思決定するという前提の伝統的経済学へのアンチテーゼとして提案された概念で、Kahneman and Tversky (1979) のプロスペクト理論に端を発している。プロスペクト理論によれば、不確実な状況において、消費者は客観的確率を前提とした期待効用に主観的なバイアスをかけることで、期待効用最大化原理から逸脱した意思決定がなされる。伝統的経済学原理から逸脱した行為は、本来ならばランダムエラーとして観測されるものであるが、相関のあるシステムチックエラーとして認識される。つまり、これら逸脱した消費者行動を例外的な行動ではなく、一つのルールとして捉えることで、消費者行動の予測率を高めることが可能となる。心理会計とは、消費者の購買意思決定は、消費者がおかれた購買時の心理的状況、支払われる金銭の入手方法、対象カテゴリーによって異なり、必ずしも効用最大化原理に従う合理的な行為とは限らないと説明する。このことは、状況によっては、経済学原理である一物一価の原理は成立せず、財の代替可能性はもはや通用しないことを示している。このように、心理会計は消費者行動を説明する規範的なルールではなく、消費者をより深く理解するためのフレームワークとして、さまざまな事例をもとに議論されている。Thaler (1999) は、心理会計を議論するにあたり、重要となる3つの視点を挙げている。第一に、消費者は財の獲得から得られる取引効用を、どのように評価して意思決定するかということである。消費者は、本来の目的に完全には沿わなくとも、それを上回るような取引効用が得られるならば、購買意思決定を下すことがある。第二に、消費者は対象となる財ごとに異なる会計口座を設定し、それぞれ異なる取引効用を個別に管理していることである。これは、小嶋 (1986) も言及する心理的財布という概念と同一で、消費者は物理的な財布とは別に、仮想的な財布を複数有しており、取引効用もそれぞれ異質である。第三に、これら仮想的な会計口座を評価する頻度が、対象する財または消費者の心理的状況によっても異なり、日次から年単位まで、取引効用を評価する時間軸を伸縮させるというものである。このように、心理会計は、経済学の新たな領域である行動経済学または行動ファイナンス、さらに消費者行動やマーケティングにおいても活発に議論されている。以下には、心理会計に関連す

<sup>1</sup>定着した日本語訳はないが、心理錯覚や心理幻想などと訳される。Thaler (2008) によれば、Psychological Accounting とも考えていたが、最終的には Kahneman and Tversky などの薦めにより Mental Accounting としたいう。

る先行研究を整理する。

心理会計を議論する領域として、マーケティングとマネジメントサイエンス系、ファイナンスと経済学系、心理学と消費者行動系という、大別して3つの領域が挙げられる。マーケティングとマネジメントサイエンスの領域は、そもそも Thaler (1985) が心理会計を発表したのが *Marketing Science*<sup>2</sup> であり、数理的な側面から心理会計を議論する研究が多い。Prelec and Loewenstein (1998) は、従来の心理会計では、財の獲得から得られる取引効用と金銭的対価が同時に交換されることを前提するが、実際に借金が伴う場合、これらには時間的ラグが生じる。この場合、支払いは損失ではなく機会費用として捉えられ、損失に換算すると過小評価されるため、実際より少額の損失として知覚されるという。Langer and Weber (2001) は、将来の不確実性に対して、プロスペクト理論で消費者は損失回避的であると説明するのは、近視眼的な損失についてであり、長期的な利益を示すことで、損失回避は緩和されると主張する。Benartzi and Thaler (1999) は、このような消費者行動を近視眼的損失回避 (myopic loss aversion) と呼び、老後資金を株式投資で運用することに関する調査によると、長期運用利益を示すことで、株式運用意向率が90%を上回ると報告している。Erat and Bhaskaran (2012) は、ある商品に対して、付加価値を与える付属製品も販売されている場合、本体製品の価値を引き上げて付属製品を購入する確率が高くなるという。消費者は、付属商品による付加価値を本体製品に見出すことで、獲得時の取引効用も増加し、付属製品の販売確率も高くなる。この効果を心理会計効果 (Mental Accounting Effect) と呼び、製品の価格戦略に利用することが提案された。

ファイナンスと経済学の領域では、特に投資家行動を理解する際に、アノマリー (anomaly) という表現で、合理的でない投資家行動を記述する。Grinblatt and Han (2005) は、株価が下落し続けているにもかかわらず保有し続けている現象を、プロスペクト理論と心理会計の概念を用いて実証した。投資家は、銘柄ごとに取引効用の異なる仮想の口座を設定し、利益と損失を個別に評価する。損益分岐点となる参照価格も購入金額との兼ね合いで決定され、参照価格よりも高値になると売られやすく、安値になると損失の確定を先延ばしにするという。株式投資において、個別銘柄の株価変動による損失とポートフォリオとしての全体価値変動による損失を比較した場合、投資家は近視眼的な損失回避行動を取りやすいが、Barberis and Huang (2001) は、この消費者行動を数理モデルを用いて検証した。また、Koch and Nafziger (2016) によれば、消費者は自己目標の設定において、考慮する選択肢を広げる

<sup>2</sup>Thaler (2008) によれば、心理会計 (Mental Accounting) の投稿先を *Marketing Science* としたのは、マーケティング領域には既に心理学者も参画しており、伝統的な経済学領域よりも受け入れられやすいと考えたことによる。

ことで、外生的リスクから自己を隔離した状況での目標設定が可能になると主張する。このことは、タクシー運転手の例で上手く説明される。目標設定を広い選択肢において設定すると、需要の多いときに労働時間が集中し、そうでないときには働かなくなる。そのため、売上の目標金額を日次で設定し、斑のない労働となるようにすることが必要であるというものだ。これは、行動経済学のセルフコントロール (self-control) と呼ばれる概念と関連するが、心理会計の観点から説明している。

心理学と消費者行動の領域では、サーベイに基づく仮説検証型アプローチによる研究が多い。Soman (2001) は、埋没費用が現在の意思決定に影響を与えることは心理会計の観点から説明できるが、費用が金額換算されていることが前提で、過去に費やした時間を費用とした場合には影響を与えないという。例えば、従業員の残業を考えた場合、費やした時間ではなく、それを残業代に変換することで、現在の意思決定に影響を与えるようになる。つまり、時間的投資は心理会計には含まれない。同様に、Soster et al. (2010) も、心理会計に対する時間的投資の効果について検証している。パネル調査の結果、利益と費用が同一期間内で生じる場合、時間的投資は心理会計の費用として含まれるが、これらが異なる期間で生じる場合には、時間的投資は心理会計の費用としては考慮されないことを示した。異時点間の心理会計については、Shafir and Thaler (2006) も、通常の心理会計と異なり、消費が費用発生時から遅れるほど、無償もしくは費用の節約を抱くようになるという。Helion and Gilovich (2014) は、心理会計における費用に関して、現金および同一価値を有するギフトカードで比較したところ、ギフトカードは娯楽用途の費用に使われることが多く、現金は生活用品の購入費用に充てられるという。このように、消費と費用が異時点間に分散され、費用媒体も現金だけでなく、プリペイドカードやクレジットカードなども併用される状況では、心理会計の枠組みも拡張が求められる。

### 2.3 レジームスイッチングに関する研究

レジームスイッチングに関する研究は、Chen and Gupta (2010) などが示すように、変換点 (Change Point) 問題としても、経済学およびマーケティングの領域で議論されている。いずれの場合も、直接的には観測できない、背後に存在する潜在的状態が時間経過とともに切換るという仮定の下、潜在状態の変換点およびその前後のレジーム特性を推定することが、当該研究での目的である。レジームスイッチングは、推定アプローチから、3つの手法に大別することができる。第一は、Quandt (1972) から派生するスイッチング回帰によるアプ

ローチであり、変換点前後で異なる確率分布を仮定し、変換点と同時に各レジームのパラメトリック推定を行うアプローチである。第二は、マルコフ過程によるアプローチであり、古くは Neftçi (1984) による米国失業率時系列データに対してレジーム推定した例があり、マルコフ過程の遷移確率を推定することで、遷移状態を判別するアプローチである。第三は、Geweke and Terui (1993), Terui and Dahana (2006a,2006b) および Terui and Ban (2008) による閾値と閾値関数にもとづくアプローチである。閾値関数には、仮説にもとづく構造化を導入することが可能で、柔軟性の高いモデルである。以下には、それぞれのアプローチに関する先行研究についてまとめる。

### 2.3.1 スイッチング回帰モデル

レジームスイッチングの問題は、最も簡素化して考えると、状態が遷移するであろうと帰無仮説を立て、それに対応する回帰式の推定値を検定し、レジームスイッチングの有無を検証する。一般化線形モデルに相当するアプローチであり、計量経済学の最も基本的な手法として、さまざまな領域で活用されている。例えば、Gupta and Cooper (1992) は、値引きに関する消費者反応に対して、メーカーブランドの商品の方がストアによるプライベートブランド商品よりも値引きに反応する閾値が低いという帰無仮説を立て、消費者調査データを用いて実施した分析などはマーケティング領域の研究では典型的なアプローチである。しかしながら、割引率がどのレベルに達すると、その前後度でどれだけの反応の差があるのかを定量的に扱うことには限界がある。閾値と反応率に消費者異質性を前提とした推定となれば、なおさら困難である。

Quandt (1972) は、観測期間中に状態変化が生じているという前提のもと、その変換点と前後の回帰特性を推定する手法を提案した。変換点の推定には、外生変数を与えて、それと閾値の大小関係でレジームが遷移すると仮定し、未知の変換点も同時に推定する。外生変数の分布に関しては、1 または 0 の離散分布、もしくは正規分布を用いた連続分布が提案され、後者の場合はスイッチング回帰は混合分布のモデルとなる。この手法では、2 レジームであることを前提としており、3 以上のレジームを想定したレジームスイッチング問題には対応しておらず、かつ消費者異質性を包含できないことで限界がある。Ferreira (1975) と Chin Choy and Broemeling (1980) は、2 レジームのレジーム回帰モデルに対して、ベイズ推定を提案した。いずれのモデルでも、分散が同一で平均値の異なる正規分布を仮定し、変換点の分布には一様分布を事前分布として与えて推定している。

レジームスイッチング研究の適用分野として、経済学では、Neftçi (1984) による米国失業率を対象にした実証分析、Hamilton (1989) による米国実質 GNP による経済局面の判定などがある。一方、マーケティングでの適用領域の一つとして、新製品の売上予測が挙げられる。通常、新製品が市場投入されると、消費者のトライアル増加と、嗜好に合致するかを判断するために比較的高頻度でのリピートが発生する。そのため、新製品発売初期段階での売上増加は急峻で、ある時点を境に減速していくのが一般的である。このように、売上局面における変換点を見極めなければ、新製品の売上予測は過剰評価されるリスクがある。Fader et al. (2004) は、新製品の売上局面の変化を捉えるモデルを提案した。新製品の市場投入直後は、トライアルとリピートにより売上は通常よりも多く、各消費者の購買間隔が短くなることを、指数分布のレートが非線形で時間変動する構造を取り込んでモデル化した。新たに発売されるジュースとビスケットの各製品に対して、パネルデータを用いた実証分析した結果によると、市場投入直後に非定常性を考慮したモデル化の有位性が示された。Schweidel and Fader (2009) は、Fader et al. (2004) の非定常モデルの発展形として、購買レジームに試行レジームと定常レジームの異なる 2 つのレジームを仮定し、変換点を境に各指数分布のレートが切替わるモデルを構築した。Fader et al. (2004) で分析した同一の実証データを用いてモデル評価したところ、レジームスイッチングを仮定したモデルの有位性が確認された。

Bucklin and Lattin (1991) は、消費者の購買行動には、計画購買と非計画購買の二つの状態が存在すると仮定し、ネステッドロジットの枠組みで消費者ごとに状態の確率を算出した。実際の ID-POS データで、クラッカーおよび挽豆コーヒーのカテゴリ購買に対して実証分析した結果、クラッカーカテゴリでは計画購買と非計画購買の比率は半々で、挽豆コーヒーカテゴリでの計画購買の割合は 20%程度であった。Fong and DeSarbo (2007) は、変換点および各状態の回帰係数に加えて、それぞれの状態となると変数の異質性も含めて推定した。そして、米国市場における脳神経系医薬品の処方箋発行数に対して実証している。また、Brentnall et al. (2010) は、尤度比を用いて、消費者が ATM で引き落とす金額、場所、利用時間の情報から、変換点を推定している。

### 2.3.2 マルコフ過程モデル

マルコフ過程を仮定したアプローチでレジームスイッチングを推定するのは、時系列において局面が非周期的に入れ替わる場合や、極端に不連続な状況を検出する場合などで利用

されることが多い。Neftçi (1984) による米国失業率を対象にした実証分析では、失業率が非周期的でランダムに上昇および下降を繰り返すことから、二階のマルコフ過程モデルにより各局面を推定した。Hamilton (1989) の米国実質 GNP による経済局面の判定では、一階のマルコフ過程モデルにより GNP の好不況を推定した。バイオメディカル分野では、Gordon and Smith (1990) により、時系列信号の急激な状態変化を自動的に検出する手法として用いられている。また、金融分野でも、Kim and Nelson (1998) により、ファイナンスレジームの変換点推定などに用いられている。このようなマルコフ過程を仮定したアプローチでは、等時間間隔で観測された時系列データを前提とし、状態空間モデルの枠組みでモデル構築されることが多い。

Carlin et al. (1992) は、英国内における過去に発生した炭鉱事故件数を、ポアソン過程に基づくモデルで、発生件数の転換年と各レジームのポアソン分布レートをベイズ推定した。また、Carlin et al. (1992) は、同一の問題に対して、マルコフ過程を仮定したアプローチでも変換点を推定している。双方の推定結果を比較すると、変換点は必ずしも一致しておらず、推定アプローチにより差異が生じている。この差異に対する考察はないものの、当該分析データは好不況といった状態の繰り返しを表す時系列データとは異なり、マルコフ過程によるアプローチによる推定は不向きではないかと考える。

マーケティングの領域では、佐藤・樋口・北川 (2005) は POS データを用いて、観測されない非価格プロモーション実施の有無を状態と捉え、状態の時系列遷移を二階のマルコフ過程でモデル化し、一般状態空間モデルの枠組みで実証分析している。実際に観測されるのは、商品の売価と販売数量であり、非価格プロモーションである山積み陳列の実施状況は、教師なしデータで推定された。Park and Gupta (2011) は、特定カテゴリー商品が頻繁に購買される期間とそうでない期間を異なる購買レジームと捉え、消費者ごとにロジットモデルによる生起確率を算出し、一階のマルコフ過程でモデル化した。このことは、別の見方をすれば、ある特定の商品に対する消費者購買行動が、慣性行動 (inertia) にあるために購買が継続される状態か、または多様性追求行動 (variety-seeking) のあるため、継続的に購買されない状態にあるのかを推定するものである。ヨーグルトカテゴリー 2 年間の ID-POS データで実証分析した結果、38.3%の消費者で特定ヨーグルト商品の継続購買状態を確認した。

### 2.3.3 閾値モデル

レジームスイッチングを閾値モデルの枠組みで推定する利点は、前出二つのアプローチがデータ主導型であるのに対して、理論に基づく消費者の行動パターンや認知構造を明示的にモデルへ取り込むことが可能となる点にある。このような理論主導型のアプローチは、構造モデリングとも呼ばれ、近年の経済学およびマーケティングサイエンスでは主流な考え方となっている。まずは、構造モデリングについて以下にレビューしておく。構造化モデリングの問題は、いわゆるルーカス批判 (Lucas Critique) と呼ばれる Lucas (1976) の論文に端を発する。将来のポリシー変更にも対応できるモデル構築のためには、消費者の行動傾向や認知構造を明示的にモデルへ取り込む必要がある。一方で、モデル式に強い制約を課すことにもなるため、構造化における仮説が正しく設定できなければ、安定して推定できないリスクがある。また、Erdem (2005) は、選択問題を理論主導型でモデル化する際、3つのアプローチがあることを指摘している。第一は、合理的主体の利益または効用が最大化されるように意思決定が下されるもの。第二に、意思決定に心理学の理論を援用して、選択行動の予測論理を組込むもの。第三は、データから観測される不規則性を取り込み、選択行動に反映させるものである。特に、2つ目のアプローチは理論先行型であり、ポリシー変更に伴う経済またはマーケティング領域でのフォワードルッキング (Forward-looking) な予測に適用されてる。Bronnenberg et al. (2005) は、対象となる領域でポリシーに変更がなければ、データ主導型で導出されたモデルの予測能力は高いが、ポリシーに変更が生じる状況においては、構造モデリングによる予測が必要であると主張する。Chintagunta et al. (2006) は、消費者需要を集計データで扱う静的モデルに構造モデルを採用することで、消費者の理解を深めることが可能となるとともに、消費者のフォワードルッキングな行動を構造モデリングで動的に表すことの重要性を説いている。実際に、ある特定のカテゴリーでは、消費者のフォワードルッキング傾向は顕著であり、出自のさまざまなデータを取りまとめて利用する場合には、同一の仮定を置くという意味でフォワードルッキングな動的モデルの有用性を主張している。例えば、Osborne (2011) は、ブランドスイッチングにおける学習効果とスイッチングコストを考慮したブランド選択モデルを提案し、フォワードルッキングな学習効果を構造化してモデルに取り入れた。洗濯洗剤に対するスキャナーデータによる実証分析の結果、構造化を仮定しなければ、交差価格弾力性は45%過小評価されていることを示した。また、Gonul and Srinivasan (1996) は、クーポン利用の可能性を考慮したフォワードルッキングな消費者行動の構造モデルを構築した。フォワードルッキングなクーポ

ン利用の可能性とは、消費者が将来時点でクーポンを利用した購買を期待していることである。さらに、現時点でクーポンが利用可能であるかに依存し、将来時点でのクーポン利用可能性の期待値が変動するという仮説にもとづいた構造化となっている。子供用オムツの購買履歴データに基づく実証分析の結果、将来時点でのクーポン利用可能性の期待値が、購買行動に影響を与えることを示した。

このように、理論主導型の構造モデリングを用いたモデル推定は、消費者行動理論や行動経済学概念を明示的にモデルへ取り込むことが可能となる。そして、各レジームに対して変換点を定め、モデル推定するのが閾値モデルによるアプローチである。Kalyanaram and Little (1994) は、消費者の商品価格に対する知覚反応には、参照価格を基準に安い (gain) または高い (loss) と感じる価格帯に加えて、どちらでもない価格受容域 (LPA : Latitude of Price Acceptance) と呼ばれる中立的な価格帯が存在するという同化対比理論 (assimilation-contrast theory) に基づくモデルを提案した。Terui and Dahana (2006a) は、これら3つの知覚レジームに対して、2つの変換点を閾値として定め、消費者ごとに異なる価格反応を有するブランド選択を閾値プロビットモデルで実証した。インスタントコーヒーに対する ID-POS データを用いて、マルコフ過程モンテカルロ法 (MCMC : Markov chain Monte Carlo) によりモデル推定している。さらに、Terui and Dahana (2006b) のモデルには、ブランドロイヤリティおよび参照価格の構築に対しても構造モデリングが取り入れられ、参照価格の形成には前回購買機会で購入した商品の金額が最も効果的であることを示した。Terui and Ban (2008) は、TV 広告効果が露出量に応じて有効となるポイントが存在するという仮定の下、マーケティング反応を TV 広告のシェアオブボイス (Share of Voice) と閾値の大小関係で反応レジームが遷移する閾値プロビットモデルを構築した。洗剤およびインスタントコーヒーに対するシングルソースデータを用い、MCMC でモデル推定した結果、TV 広告の残存効果と有効閾値には消費者異質性があることが示され、さらにカテゴリーごとに特性は異質であると示した。

表 2.1: レジームスイッチングに関する主な先行研究一覧

文献	モデリングアプローチ	目的変数	消費者異質性	変換点指標
Hamilton (1989)	マルコフ過程モデル	米国実質 GNP	-	時間 (四半期)
Bucklin and Lattin (1991)	スイッチング回帰モデル	ブランド選択	○	効用関数
Gupta and Cooper (1992)	スイッチング回帰モデル	売上	-	値引率 (メーカーブランド, ストアブランド)
Carlin et al. (1992)	マルコフ過程モデル	炭鉱事故件数	-	時間 (年)
Kim and Nelson (1999)	マルコフ過程モデル	金利	-	時間 (年)
Fader et al. (2004)	スイッチング回帰モデル	新製品売上	-	発売日からの経過時間 (週)
佐藤・樋口・北川 (2005)	マルコフ過程モデル	非価格プロモーション	-	店頭価格と売上数量
Terui and Dahana (2006a,b)	閾値モデル	売上	○	参照価格
Terui and Ban (2008)	閾値モデル	売上	○	TV 広告露出量
Schweidel and Fader (2009)	スイッチング回帰モデル	新製品売上	-	発売日からの経過時間 (週)
Brentnall et al. (2008)	スイッチング回帰モデル	ATM 利用回数	○	時間 (日)
Park and Gupta (2011)	マルコフ過程モデル	売上	○	効用関数

## 2.4 消費者世帯の消費者購買行動の研究

消費者の小売業における購買点数の問題は、マーケティングサイエンスで頻繁に議論されるブランド選択問題とは異なり、特定商品やカテゴリーに限定せずに購買機会あたりの点数を扱う。小売業者の観点では、どの商品が幾つ購買されるかではなく、消費者の購買機会あたりの総購買点数が重要となる。同様に、ブランド選択と関連して、特定商品の購買間隔やブランドスイッチングを含めたカテゴリーの購買間隔ではなく、小売業者にとって重要なのは来店間隔である。しかしながら、ブランド選択や購買頻度を扱う研究は無数にあるものの、小売業における購買点数や来店間隔を扱う研究は限定的である。その理由の一つは、小売店舗における購買点数を扱う場合、SKU (Stock Keeping Unit) 数は通常でも1万点以上はあり、データ処理に対する負担が挙げられる。ビッグデータを扱う現代では、処理負担を制約条件として捉えず、消費者購買行動の研究を実施する環境は整っているものの、小売業における購買点数に関する先行研究は限定的である。また、来店間隔に関する研究は、ブランド選択と関連して来店の有無を同時に扱う研究も存在するが、ブランド購買頻度に関する先行研究と比較すると数は少ない。本小節では、カテゴリーおよびブランド選択の数量や頻度に関連する先行研究も含めて、消費者の購買行動を購買点数と来店間隔について先行研究を整理する。

### 2.4.1 購買点数モデル

購買点数の問題は、観測データが非負整数の離散データであることから、ポアソン分布に従う確率過程の問題として扱うのが一般的である。しかし、観測データにポアソン分布を適用するには、二つの問題が存在する。一つは、ポアソン分布の平均と分散は理論的に等価なのに対し、実際の観測データでは分散が大きくなる過分散の問題である。モデルのあてはまりを劣化させる原因となり、過分散をいかにモデルへ反映させるかを議論する先行研究が多数存在する。もう一つは、ゼロ過剰の問題で、実際の観測データにゼロを含む場合、ポアソン分布に対するあてはまりを劣化させる。この問題に対しては、クロスセクションデータの場合、その観測方法により、ある程度回避することが可能であるが、時系列データの場合には不可避なケースも多々生じる。以下には、これら消費者離散データに関する手法や枠組みについて概観したのち、購買点数モデルに関するマーケティング領域での先行研究をレビューする。

過分散の問題について、ポアソン分布のレートパラメータにガンマ分布を仮定した負の二項分布 (NBD: Negative Binomial Distribution) が、Ehrenberg (1959) によって提案されると、消費者行動の非負離散データを扱う枠組みとして幅広く利用されてきた。Chatfield et al. (1966) は、NBD に加えて、対数級数分布 (LSD: Logarithmic Series Distribution) を提案している。さらに、Sichel (1982) は、レートパラメータに一般逆ガウス分布を仮定した (IGP: generalized Inverse Gaussian distribution Poisson) 分布を提案した。浴室石鹸の購買データで実証分析したところ、IGPの方がモデル精度は有意であり、定期的に高頻度で購買する最寄品の消費者行動を表すのに適していると主張する。その他にも、非負制約を有する多様な分布をレートに仮定した様々な分布が提案されている。詳しくは、Brockett et al. (1996) や Karlis and Xekalaki (2005) に一覧表が掲載されているので参照されたい。NBD は解析的にも確立した比較的シンプルな確率分布であり、市場データとのあてはまりも良好であることから、非負離散の非集計データを扱う消費者購買の確率分布として利用されてきた。その後、購買点数の問題は消費者ごとのモデリングが主流となる。ベイズ推定が一般的でない時期の研究では、消費者レベルの購買点数モデルの推定法についても提案された。Cameron and Trivedi (1986) は、最尤推定 (ML: Maximum Likelihood) をベースに、擬似最尤推定 (PML: quasi ML), 擬似一般化最尤推定 (QGPMML: quasi-generalized PML) を提案し、Ramaswamy et al. (1994) は EM アルゴリズムを用いてモデル推定している。また、Marrison and Schmittlein (1988) は、NBD モデルに対するレビューにおいて、NBD モデリングの限界を3点指摘している。まずは、比較的到高頻度で購入される最寄品に対するモデル化には、周期性を取り入れる必要があり、NBD で周期性を表すには限界があること。次に、全消費者を対象としたモデリングでは、無購買が少なからず発生するため、ゼロスパイクが生じてしまうこと。最後に、消費者の購買行動は非定常であり、時間とともに分布パラメータが変動することである。これら限界を考慮した上で、NBD モデリングおよび推定値の解釈が必要であると説いている。

ゼロ過剰の問題に対して、Lambert (1992) は、ゼロが出現する分布と非ゼロのポアソン分布の混合分布として、ゼロ過剰ポアソン ZIP: (Zero-inflated Poisson) モデルを提案した。それ以来、ゼロ過剰の非負離散データ分析の枠組みとして、様々な領域で ZIP が利用されている。例えば、Lord et al. (2005) による衝突事故件数に対する ZIP シミュレーション推定など、ゼロ過剰問題における ZIP を用いた分析は多々報告されている。また、ゼロ過剰と並行して問題となるのが、データの系列相関であり、特にバイオメディカル関連のデー

タで遭遇する。Lee et al. (2006) は、系列相関の存在するデータに対する ZIP の改良版を提案し、子育てに従事する母親の母乳提供のデータを用いて実証分析した。さらに、Morgan et al. (2013) は、同様の問題に異質性を導入して、総合失調症患者ごとに ZIP モデルで実証分析した。

Cooil (1991) は、医療事故請求件数に対して、ポアソン分布のレートパラメータを医師ごとの属性データとガンマ分布に従う異質性で構造化した。Wedel et al. (1993) は、消費者異質性が生じるのは、レートの異なる有限数のポアソン分布が混合しているという前提から、潜在クラスポアソン回帰モデルを用いてモデル構築した。書籍販売のダイレクトマーケティングに関するデータを用いて、EM アルゴリズムでモデル推定したところ、3つの潜在クラスが採択され、ポアソン分布および負の二項分布に対する有意性が確認された。Shonkwiler and Harris (1996) は、米国郊外の過疎化地域と小売業ビジネスの集中度について、多変量ポアソン分布によるモデルで実証分析した。各レートパラメータとガンマ分布の形状パラメータを地域の属性データ（人口、平均所得、人口密度）で構造化し、3タイプ（ガーデニング、衣料品、家具）の小売企業数に対する多変量モデルを構築している。Greene (1998) は、MDR(major derogatory reports) と呼ばれるクレジットカードの信用レベルを減点させる事象の発生件数に対して、ポアソン分布のレートをカード保持者の属性情報で構造化してモデル推定した。信用リスクモデルでは、対象者がデフォルトとなる確率を算出する離散モデルを構築するのが一般的であるが、このケースではデフォルト要因として最も説明力のある MDR 発生件数を算出するモデルを構築している。Manchanda et al. (1999) は、洗剤と柔軟剤などの補完財が、互いにどのように影響し合い併売されるか、階層ベイズ多変量プロビットモデルの枠組みで分析し、マルコフ連鎖モンテカルロ法 (MCMC: Markov chain Monte Carlo method) で推定した。実証分析には、ケーキ生地とケーキフロストの補完財ペアを含めて分析するが、商品数が増加するとともに、補完財ペアの数も増大するため、小売業向けに拡張するには限界がある。Bermudez and Karlis (2011) は、対人や盗難など異なる種類の保険請求を対象に多変量ポアソン回帰の枠組みで、同時請求の関連性を含めて実証分析した。保険請求件数は、常時実施されるものでもなく、ゼロ過剰の問題が存在するが、当該モデルでは ZIP モデルを多変量に拡張している。Dippold and Hruschka (2013) は、併売対象を 27 カテゴリーおよび 11 サブカテゴリーに広げて、階層ベイズ多変量ポアソン分布の枠組みで実証分析した。異なるカテゴリーまたはサブカテゴリー商品間の併売に伴う相関を有するペアは限定的で、特定商品以外は無相関を仮定したモデルの適

合性の方が優れていると主張する。

#### 2.4.2 来店間隔モデル

消費者が同質である場合、一定期間内の来店客数がポアソン分布に従うならば、来店間隔は指数分布に従う。発生頻度と発生間隔の分布としては表裏一体の関係にあり、事象をどちらの枠組みで分析しても構わない。例えば、Brentnall et al. (2008) は、一定期間における ATM での消費者ごとの取引回数について、ポアソン回帰モデルの枠組みでモデル化した。レートパラメータに対して、共変量については考慮せず、曜日、時間帯、消費者ごとの利用傾向、過去の取引履歴を用いたデータ主導型構造化モデリングを行った。この期間の平均取引回数の逆数は、平均取引間隔に相当する。Burda et al. (2012) は、消費者のスーパーマーケットへの一カ月あたりの訪問回数をポアソン回帰の枠組みでモデル化した。ただし、レートパラメータを各消費者の効用関数で表し、自身の効用関数が最大になるように訪問回数が決定されるよう構造化され、極値分布に従うランダム項を与えることで、ロジットモデルの枠組みを適用している。この場合も、期間の平均来店回数の逆数は、平均来店間隔に対応する。Jeuland et al. (1980) でも示されるように、ある事象にポアソン分布のレートパラメータにガンマ分布に従う異質性を仮定すると、この発生件数の分布は負の二項分布であり、発生間隔はアーラン 2 分布となる。いずれの先行研究でも、消費者の連続する事象間隔の推定問題として捉えることができる。しかしながら、頻度と間隔の分析で大きく異なる点は、データ収集にある。頻度データの場合は、個人を識別する必要はないが、間隔データは個人ごとに間隔を記録しなければならない。そのため、消費者異質性を扱う場合、来店間隔で分析することが必須となる。

時間間隔の問題は、生存時間分析の枠組みを用いることが一般的で、特に Cox 比例ハザードモデル (PHM: Proportional Hazard Model) が幅広く利用されている。PHM は、Cox (1972) により提唱され、基準ハザードに対して共変量による影響が乗法的に作用するモデルであり、基準ハザードを定式化せずに共変量による影響の分析が可能である。基準ハザードに対する共変量の影響を加法的に作用させるモデルは、加法リスクモデル (ARM: Additive Risk Model) と呼ばれ、Aalen (1978) に提案された。PHM と ARM は、基準ハザードに対する共変量の影響構造が異なり、PHM が基準ハザードを拡大または縮小させるのに対して、ARM は基準ハザードを上下させる。時間間隔分析のもう一つの枠組みは、加速故障モデル (AFTM: Accelerated Failure Time Model) と呼ばれ、Prentice and Kalbfleish (1979) によって

提案された。AFTM は、共変量による影響が時間間隔に乗法的に作用するモデルである。その結果、PHM と ARM では基準ハザードに対して共変量が乗法および加法の形式で分離できたのに対して、AFTM では基準ハザードは分離できず、共変量と時間間隔が積の形でハザードの関数として包含される。

マーケティング領域における時点研究の主要目的は、精緻なモデルの実現によるマーケティング共変量の効果を解明することにある。そのため、多くの先行研究では、共変量と異質性のモデルへの様々な取込み方が議論されている。Gupta (1991) は、PHM の枠組みの基準ハザードに指数分布およびアーラン 2 分布を仮定し、レートパラメータにガンマ分布の異質性を仮定した。共変量による影響は、マーケティング変数の対数回帰変換で設定し、基準ハザードを伸縮させる役割を果たす。この共変量の設定は、PHM で一般的に取られる手法ではあるものの、表現の自由度としてはやや制約的である。そこで、Jain and Vilcassim (1991) は Box-Cox 変換で共変量の効果を、さらに消費者異質性のランダム項を加えたモデルを構築し、コーヒーカテゴリーのスキャンパネルデータで実証分析してモデルの有位性を確認した。

Seetharaman and Chintagunta (2003) は、従来の連続型 PHM を離散型に拡張して、基準ハザードと共変量の時間変動の効果を考慮して離散時間ハザードを定義し、時点ごとの購買有無にベルヌーイ過程の枠組みを適用した。各消費者の消費財（洗剤、ペーパータオル）における購買間隔を、従来の連続型と離散型の PHM で推定してモデル適合度を比較したところ、離散型 PHM が選択された。また、基準ハザードに 5 つの分布（指数分布、アーラン 2 分布、ワイブル分布、対数ロジスティック分布、指数べき分布）を仮定して、それぞれのモデル適合度を評価したところ、基準ハザードには指数べき分布が支持された。離散型 PHM は、購買していない時点の情報もモデルに組み入れられているため、連続型 PHM よりもモデル評価は大幅に向上している。Helsen and Schmittlein (1993) は、クラッカーに対するスキャナーパネルデータを用いて、PHM による生存時間モデル、プロビットによるブランド選択モデル、線形回帰モデルでマーケティングの枠組みでモデル推定したところ、PHM によるモデル評価が高く、生存時間分析によるマーケティング施策評価の有意性を主張している。

Seetharaman (2004) は、各消費者の消費財（洗剤、ペーパータオル、トイレットペーパー）における購買間隔を、マーケティング施策を共変量として、上述の 3 つの生存時間分析の枠組みで実証分析した。その結果、実データに対するモデルの適合度は、ARM, PHM, AFTM

の順で良好であることを示した。また、基準ハザードに5つの分布を仮定して、それぞれのモデル適合度を評価したところ、ARMでは対数ロジスティック分布、PHMに対しては対数べき分布が採択された。さらに、PHMにおける価格変数に対する係数が、ARMとAFTMとは異なり正を示したことも踏まえて、ARMを枠組みとした生存時間分析の有意性を説いている。しかしながら、マーケティング領域において、多くの先行研究ではPHMを採用しており、ARMを用いた実証分析は限定的である。

消費財の性質によって、規則的に購入するものと、ランダムで購入するものがあり、消費者の購入間隔の確率分布も異なる。そこで、Vakratsas and Bass (2002)は、基準ハザードに混合ワイブル分布を仮定したPHMモデルを提案した。ワイブル分布の形状は、形状パラメータの大きさに応じて変化し、ゼロの場合は指数分布となり、購入間隔は無記憶でランダムとなる。一方、形状パラメータが大きくなると、確率密度のピークは鋭くなり、特定の時間間隔での瞬間確率が高くなるため、購入行動は規則的になる。規則的またはランダムという二つのセグメントを仮定した混合ワイブル分布を基準ハザードに、ガンマ分布を消費者異質性に仮定して実証分析した。その結果によれば、ケチャップと砂糖カテゴリーの購入行動でランダム性が確認された。Allenby et al. (1999)は、金融商品の取引間隔は、取引度合いに応じて3つのモードが存在することを前提に、3つのセグメントを有する混合一般化ガンマ分布を仮定してモデル化した。さらに、消費者異質性を階層ベイズで構造化して、マルコフ連鎖モンテカルロ法(MCMC: Markoc chain Monte Carlo methods)でモデル推定している。いずれの先行研究も、混合分布で状態の異質性をモデル化している限り、時点ごとの状態を明示的に示すことはできていない。

Gupta (1988)は、消費者の来店から商品購入までの一連の購入行動を、購入間隔、ブランド選択、購入点数に分けてモデル化し、売上期待値を積乗型モデルで表した。各モデル推定には、購入間隔はアーラン2分布、ブランド選択は多項ロジットモデル、購入点数は累積ロジットモデルを用いた最尤法により算出した。全体の弾力性は、購入間隔、ブランド選択、購入点数の各弾力性の総和として求めた結果、セールスプロモーション効果によるブランドスイッチングで84%の売上増分に貢献していると推定された。

ブランド選択と購入間隔を同時にモデル化する先行研究も存在する。通常の購入間隔の算出では、連続する同一ブランドの購入間隔を対象とするが、異なるブランド間の購入間隔を区別し、ブランドスイッチングハザードとして分析するものである。Vilcassim and Jain (1991)は、ブランドスイッチングに各ブランドでの滞在時間を併せた準マルコフ過程の仮定

の下、各ブランドスイッチングの遷移確率を推定し、各ブランドスイッチに対応するスイッチングハザードを算出した。自己遷移を含めた各スイッチングハザードに対して、PHMの枠組みで共変量と消費者異質性を取り込み、4種類のクラッカーブランド間での消費者購買データで実証分析した。その結果、ブランドスイッチングごとのハザード形状は異質で、共変量であるマーケティング変数の反応も異なるため、ブランドスイッチング戦略を策定する上での有効性を説いている。一方で、PHMに仮定するハザードの分布関数には制限があり、厳密には限定的ではあるが、実務上は問題ではない。同様に、Gonul and Srinivasan (1993)もブランドスイッチングと購買間隔をスイッチングハザードに区別してPHMの枠組みで定式化し、最終的には自ブランドの購買間隔を推定している。また、Chintagunta and Prasad (1998)は、各消費者のハザードとブランド選択確率は独立であるとの仮定の下、スイッチングハザードをそれらの積でモデル化し、PHMの枠組みで実証分析している。

表 2.2: 購買行動に関する主な先行研究一覧

文献	購買行動	目的変数	確率分布	備考
Scichel (1982)	購買点数	ブランド売上	負の二項分布	異質性に一般ガウス分布
Gupta (1988)	購買間隔/点数	ブランド選択	アーラン2分布/順序ロジット	ブランド選択に多項ロジットモデル
Gupta (1991)	購買間隔	ブランド選択	アーラン2分布	PHMに共変量を対数線形変換
Coolil (1991)	購買点数	医療事故件数	負の二項分布	異質性にガンマ分布
Jain and Vilcassim (1991)	購買間隔	ブランド選択	3種類分布**	PHMに共変量を対数線形変換
Wedel et al. (1993)	購買点数	ブランド売上	潜在クラスポアソン分布	異質性に混合分布
Helsen and Schmittlein (1993)	購買間隔	ブランド選択	プロビット選択確率	PHMに共変量をプロビット変換
Vilcassim and Jain (1991)	購買間隔/BS*	ブランドスイッチ	指数分布	PHMに共変量を対数線形変換
Gronul and Srinivasan (1993)	購買間隔/BS*	ブランドスイッチ	ゴンベルツ分布	PHMに共変量を対数線形変換
Shonkwilder and Harris (1996)	購買点数	小売り企業数	負の二項分布	異質性にガンマ分布
Greene (1998)	購買点数	カード事故件数	ポアソン分布	レートパラメータを共変量で対数線形変換
Chintagunta and Prasad (1998)	購買間隔/BS*	ブランドスイッチ	対数ロジスティック分布	PHMに共変量を Box-Cox 変換
Allenby et al. (1999)	購買間隔	金融商品取引	混合一般化ガンマ分布	階層ベイズに共変量を積乗型変換
Vakratsas and Bass(2002)	購買間隔	ブランド選択	混合ワイブル分布	PHMに共変量を対数線形変換
Seetharaman and Chintagunta (2003)	購買間隔	ブランド選択	5種類分布***	離散型 PHM に共変量を対数線形変換
Seetharaman (2004)	購買間隔	ブランド選択	5種類分布***	PHM, ARM, AFTM に共変量を対数線形変換
Brenmall et al.(2008)	購買点数	ATM取引回数	ポアソン分布	レートパラメータを共変量で対数線形変換
Bermudez and Karlis (2011)	購買点数	保険請求件数	多変量ゼロ過剰ポアソン分布	共変量で対数線形変換
Burda et al. (2012)	購買点数	スーパー来店回数	混合ポアソン分布	階層ベイズに共変量を対数線形変換
Dippold and Hruschka (2013)	購買点数	商品の発売	多変量ポアソン分布	レートパラメータを共変量で対数線形変換

BS\* : Brand Switch (ブランドスイッチ)

3 種類分布\*\* : 指数分布, アーラン2分布, ワイブル分布

5 種類分布\*\*\* : 指数分布, アーラン2分布, ワイブル分布, 対数ロジスティック分布, 指数べき分布

## 2.5 サーベイ研究まとめと本研究の関連

本章では、消費者の心理会計に関する研究、レジームスイッチングに関する研究、消費者の購買行動に関する研究という3つの視点から、本研究のテーマに関連して先行研究を整理した。本小節では、1章で挙げた6つの着眼点と照らし合わせて、既存研究の限界と本研究の各テーマおけるねらいについてまとめる。

収支バランスの圧力または家庭内在庫バランスの圧力は、平衡状態から外れた際に心的圧力として消費者が知覚するものだが、それらを心理的影響要因として具体的にモデルに取り込んだ先例はない。心理会計の研究は、ある特定の状況の下で、効用最大化の原理から外れた消費者行動をアノマリーとして議論した研究が主である。家庭内在庫に関しては、その多少によって、消費者の購買行動が影響を受けることは実証されており、多数の研究でモデル説明変数として用いられている。これら心理的影響要因を包括的に理解するために、全ての研究テーマを通して、心的状況を収支バランスの圧力で表すための構造を提案して評価する。収支バランスを計るには、消費者ごとの給料日推定が必須であり、その推定を評価することも研究テーマのねらいである。さらに、これを基盤として購買点数と来店間隔を家庭内在庫を考慮することで関連させ、心的状況指標を二次元に拡張して消費者行動への影響を評価する。

購買点数モデルでは、モデル精度向上のために、ゼロ過剰と異質性に対処する多数の提案がなされているが、心理的状況を扱った消費者行動の構造モデリングは限定的である。消費者異質性に関して、集計離散データを扱う購買点数では、ポアソン分布のレートパラメータにガンマ分布を仮定した負の二項分布を仮定したモデルが、非集計データではレートパラメータを対数回帰変換で構造化したモデルを用いるのが一般的である。購買間隔では、負の二項分布に対応したアーラン2分布などを基準ハザードとし、比例ハザードの枠組みで消費者ごとの共変量を対数回帰変換して組込むのが一般的である。最近の研究では、階層ベイズで回帰変数を構造化する例も多い。しかしながら、心理的影響要因を異質性として取り込んだ先例は確認されない。

一方、時間間隔を扱うモデルに仮定する確率分布は、負の二項分布に対応したアーラン2分布の他に、指数分布、ワイブル分布、対数ロジスティック分布、ガンマ分布など多様な非負値分布が試行され、周期的に購入される嗜好品とランダムで購入される商品では購買行動パターンは異なり、定石として用いる確率分布は特に存在せず、多様な確率分布が提案されている。比例ハザードモデルの枠組み以外に、加法リスクモデル、加速故障モデル

ルにより、様々な確率分布に対応した共変量の取込みが可能となる。しかし、心的状況を考慮した時点研究は見当たらない。以上のことを鑑みて、図 2.2 に、6つの着眼点にもとづく既存研究の限界と本研究における各研究テーマのねらいについて整理した。

着眼点	既存研究の限界	研究テーマのねらい
<b>心的影響要因の構造</b> <b>収支バランスの圧力</b> <b>家庭内在庫バランスの圧力</b>	心理会計で説明する消費者行動のアノミーの研究のみ 直接効果としてモデル変数に取込んだ消費者反応の分析にとどまる	<b>研究テーマ1 &amp; 2 &amp; 3</b> 収支バランス圧力の影響構造の評価、給料日推定法の評価 <b>研究テーマ3</b> 収支および家庭内在庫バランスの圧力による二次元影響構造の評価
<b>消費者異質性</b>	心理的影響要因の消費者異質性を考慮した実例はない	<b>研究テーマ1 &amp; 2 &amp; 3</b> 各購買レジームの消費者反応と変換点の評価
<b>確率分布の異質性</b>	心理的影響要因と確率分布についての実例はない	<b>研究テーマ3</b> 非負値分布の来店間隔に対する適用性の評価
<b>購買点数</b>	同一消費者でも心理的影響要因により異なる反応を示した例はない	<b>研究テーマ1</b> 消費者ごとに、心理会計と購買点数の関連性を評価
<b>来店間隔</b>	比例ハザードの枠組みでの共変量への検討が多く、限定的である	<b>研究テーマ2 &amp; 3</b> 消費者ごとに、心理会計と来店間隔の関連性を評価

図 2.2: 既存研究の限界と各研究テーマのねらい

最後に、本研究の全体的な流れについて確認する。本研究の目的は、小売業における心理会計の消費者行動に対する影響メカニズムを解明することである。消費者行動とは、消費者ごとの購買点数と来店間隔であり、心理会計による影響メカニズムの解明とは、小売業店舗における消費者の購買履歴データ（ID-POS データ）を用いて心的状況をモデル化し、消費者行動との関係性を実証することである。第3章では、本研究の主要概念である心理会計の効果として、収支バランスの圧力による影響を ID-POS データを利用した閾値モデルで表現できることを示す。購買点数を目的変数とした統計モデルを構築し、スーパーマーケットの ID-POS データを用いて実証する。購買点数モデルは、来店間隔モデルと比

較し、統計モデルのバリエーションは限られており、ポアソン回帰モデルの枠組みでモデル化されることが一般的である。本研究では、階層ベイズをポアソン回帰モデルに組み入れた閾値モデルを構築する。第4章では、上述の心理会計モデルの枠組みを消費者の来店間隔を目的変数とした統計モデルに組み入れて、階層ベイズのモデルに対して ID-POS データで実証する。来店間隔モデルの確率分布には対数正規分布を仮定し、位置パラメータを取引バランスの圧力を含めた外部変数による回帰変換で構造化する。第5章では、購買点数と来店間隔を家庭内在庫を考慮することで関連させ、心理的影響要因として加え、消費者反応レジームを二次元化する。その上で、各レジームの確率密度の異質性を評価しながら、来店間隔と心理会計の関係性を解明する。図 2.3 に後述の各章に対応した本研究の全体的な流れについてまとめておく。

## 心理会計と消費者行動の関連性

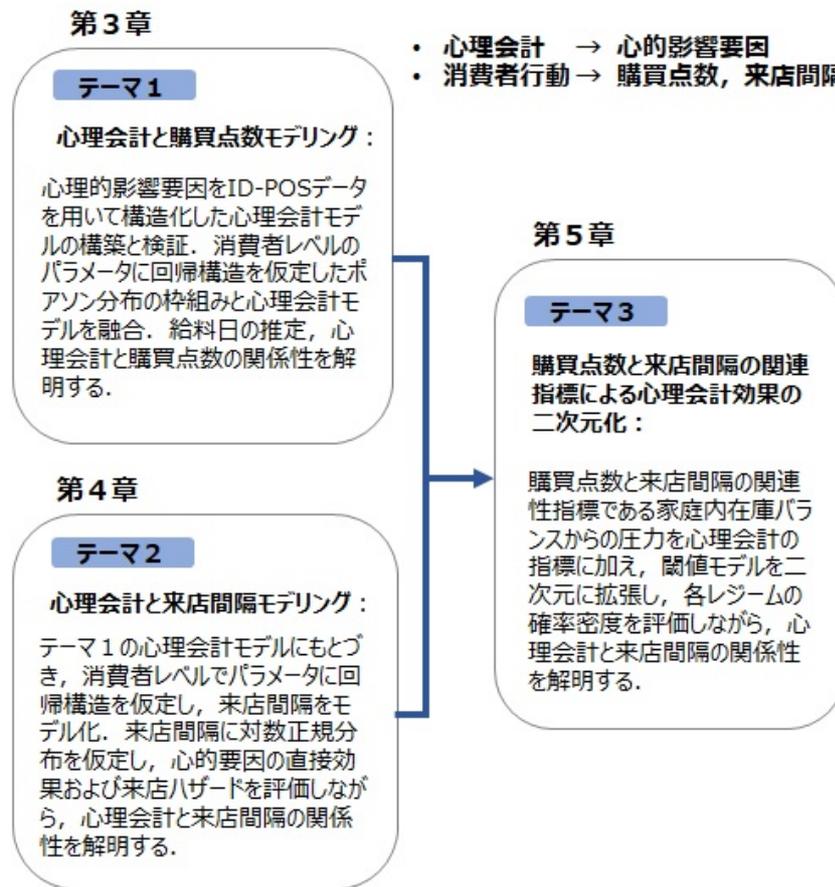


図 2.3: 本研究における各テーマの関連性

表 2.3 に本研究の各テーマで用いる記号一覧を示しておく。本研究の主要概念である心的負荷など、図 2.3 に示した研究テーマ全体で用いられる記号は共通である。構造化モデリングの説明変数など、研究テーマ全体で用いられるが、各テーマごとに次元などが異なることがあるが、記号の意味合いは同じため、同一記号を用いるので、詳細設定については各章に記述する。各テーマに固有な記号については、それらが関連する章を括弧内に追記している。また、記号の添え字に  $i$  と  $t_i$  が付いているものは、それぞれ消費者  $i$  と購買機会  $t_i$  に条件付けされた情報であることを示す。なお、各章の説明には、記号の右肩に括弧付きで  $(k)$  と示したものもあるが、これは明示的にレジーム  $k$  を表すものであり、表 2.3 においては明記していない。

表 2.3: 本研究の各テーマで用いる記号一覧

記号	説明
$l$	累積購買集計期間 (= 1, 2, 3)
$cum_{i,t_i}$	$t_i$ における累積購買金額 ; ( $cum_{i,t_i,1}, cum_{i,t_i,2}, cum_{i,t_i,3}$ )
$M_{i,j}$	消費者 $i$ の購買機会 $j$ における購買金額
$\alpha_i$	ロジット変換前の心的負荷構成パラメータ ; ( $\alpha_i^{(1)}, \alpha_i^{(2)}$ )
$\alpha_i^*$	ロジット変換後の心的負荷構成パラメータ ; ( $\alpha_i^{*(1)}, \alpha_i^{*(2)}$ )
$CummM_{i,t_i}$	心的負荷 ; $\alpha_i^{*(1)} cum_{i,t_i,1} + \alpha_i^{*(2)} cum_{i,t_i,2} + \alpha_i^{*(3)} cum_{i,t_i,3}$
$InvM_{i,t_i}$	在庫金額 ; $InvM_{i,t_i-1} + M_{i,t_i-1} - Consume_{i,t_i}$ (第 5 章)
$\gamma_{cum,i}$	心的負荷閾値パラメータ
$\gamma_{inv,i}$	在庫金額閾値パラメータ (第 5 章)
$\lambda_{i,t_i}$	ポアソン分布のレートパラメータ (第 3 章)
$\tau_{i,t_i}$	ワイブル分布の尺度パラメータ
$\mu_{i,t_i}$	対数正規分布の位置パラメータ
$\eta_{i,t_i}$	対数ロジスティック分布の位置パラメータ
$\kappa_i$	ワイブル分布の形状パラメータ
$\sigma_i^2$	対数正規分布の分散パラメータ
$s_i$	対数ロジスティック分布の尺度パラメータ
$\zeta_i$	その他パラメータ ; $\kappa_i, \sigma_i^2, s_i$ いずれか
$\omega_{i,t_i}$	各レジームの分布パラメータ ; ( $\tau_{i,t_i}, \kappa_i$ ), ( $\mu_{i,t_i}, \sigma_i^2$ ), ( $\eta_{i,t_i}, s_i$ ) いずれか
$\beta_i$	分布パラメータ構造化の回帰パラメータ
$\mathbf{x}_i$	分布パラメータ構造化の説明変数
$\varphi_{i,t_i}$	被構造化パラメータ ; $\mathbf{x}_{i,t_i}^t \beta_i (= \mu_{i,t_i}, \eta_{i,t_i})$ または $e^{\mathbf{x}_{i,t_i}^t \beta_i} (= \tau_{i,t_i})$
$\boldsymbol{\pi}_i$	時点に依存しない各レジームの分布パラメータ ; ( $\beta_i, \kappa_i$ ), ( $\beta_i, \sigma_i^2$ ), ( $\beta_i, s_i$ ) いずれか
$\mathbf{y}_i$	モデリング目的変数
$\mathbf{z}_i$	階層モデルの属性変数
$\boldsymbol{\theta}_i$	推定パラメータ ; ( $\beta_{i,1-6}^{(1)}, \beta_{i,1-6}^{(2)}, \ln(\gamma_{cum,i})$ ) (第 3 章)
$\boldsymbol{\psi}_i$	推定パラメータ ; ( $\beta_{i,1-5}^{(1)}, \zeta_i^{(1)}, \beta_{i,1-5}^{(2)}, \zeta_i^{(2)}, \beta_{i,1-5}^{(3)}, \zeta_i^{(3)}, \beta_{i,1-5}^{(4)}, \zeta_i^{(4)}, \ln(\gamma_{cum,i}), \ln(\gamma_{inv,i})$ ) (第 5 章)
$\boldsymbol{\phi}_i$	推定パラメータ ; ( $\beta_{i,1-6}^{(1)}, \beta_{i,1-5}^{(2)}, \ln(\gamma_{cum,i})$ ) (第 4 章)
$\Delta_\theta, \Delta_\psi, \Delta_\phi, \Delta_\alpha$	階層モデルの線形結合行列 ( $\theta, \psi, \phi, \alpha$ 各々に対応)
$\Sigma_\theta, \Sigma_\psi, \Sigma_\phi, \Sigma_\alpha$	階層モデルの分散共分散行列 ( $\theta, \psi, \phi, \alpha$ 各々に対応)
$\mathbf{X}$	全消費者説明変数行列 ; ( $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_H$ )
$\mathbf{Y}$	全消費者目的変数行列 ; ( $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_H$ )
$\mathbf{Z}$	全消費者属性変数行列 ; ( $\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_H$ )
$\mathbf{Cum}$	全消費者心的負荷行列 ; ( $cum_1, cum_2, \dots, cum_H$ )
$\mathbf{Inv}$	全消費者在庫金額行列 ; ( $InvM_1, InvM_2, \dots, InvM_H$ ) (第 5 章)
$\Theta$	全消費者推定パラメータ行列 ; ( $\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_H$ ) (第 3 章)
$\Psi$	全消費者推定パラメータ行列 ; ( $\boldsymbol{\psi}_1, \boldsymbol{\psi}_2, \dots, \boldsymbol{\psi}_H$ ) (第 5 章)
$\Phi$	全消費者推定パラメータ行列 ; ( $\boldsymbol{\phi}_1, \boldsymbol{\phi}_2, \dots, \boldsymbol{\phi}_H$ ) (第 4 章)
$\mathcal{A}$	全消費者構成パラメータ行列 ; ( $\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_H$ )

## 第3章 心理会計と購買点数モデリング

### 3.1 はじめに

本章では、心理会計と小売業における消費者行動に対する影響メカニズムの関連性を解明するため、まずは購買点数についてモデル化する。一般的に、消費財メーカーの立場から ID-POS データの分析をする場合、個々の商品あるいはブランドを単位とした分析をすることが多い。消費財メーカーにとって、個々の商品やブランドの売上が興味の対象だからである。一方、小売業者は顧客の購買機会あたりのバスケット構成やサイズを興味の対象にすることが多い。この点を踏まえれば、小売マーケティングを高度化するには、ID-POS データをアイテム単位で分析するだけでは不十分であり、買物かご（ショッピングバスケット）を単位とした分析を実現し、その中身の形成メカニズムを明らかにしなければならない。購買機会あたりの購買点数は、消費者が店舗で下した購買意思決定の回数を近似的に表し、消費者行動を解き明かすために重要な経営指標である。本研究では、消費者行動を示す変数として購買機会ごとの購買点数を目的変数とし、その形成メカニズムが心理会計によって連続的に切換わる構造をモデル化する。特に、本章においては心理会計を表す代理変数としてデータドリブンの立場から心的負荷を提案し、以降の章における心理会計分析のフレームワークを構築する。

本章は以降において、次の通りに構成する。3.2 節には、本章に関連する先行研究のレビュー結果を示す。3.3 節には、提案モデルを示し、3.4 節にはモデル推定のアルゴリズムを、3.5 節には実証分析の結果を示し、3.6 節は本研究のまとめである。

### 3.2 先行研究

心理会計と購買行動に関する先行研究として、Inman et al. (2009) は、消費者の心理的状態と非計画購買の関係性について分析している。また、Stilley et al. (2010) は、消費者は購買時に心理的予算を有して来店し、購入予定の商品またはカテゴリーと店内で購入の意思

決定を行うものに分けて潜在的に予算化していることを示した。小嶋 (1986) は、消費者の購買時における心的構成に応じて存在する、心理的に異なる複数の財布を心理的財布という概念で表し、時間、空間、状況、対象の様々な要因によって変化することを議論しており、心理会計と同様の概念である。

Manchanda et al. (1999) は、洗剤と柔軟剤などの補完財が同一バスケットに含まれるか、階層ベイズ多変量プロビットモデルの枠組みで分析した。当該モデルは、バスケットの構成を消費者の異質性に配慮してモデル化するという観点で興味深い研究であるが、対象とするカテゴリー数の増大には対応できないというデメリットを有している。一方、当該研究でなされているモデル化は、3.1 節で言及したバスケット構成に関連するものであり、購買点数を対象とする本研究とはその視点が異なっている。Bermudez and Karlis (2011) は、対人や盗難など異なる保険請求を対象に多変量ポアソン回帰の枠組みでその構造を実証分析した。Manchanda et al. (1999) および Bermudez and Karlis (2011) の両研究とも、予め分析対象の商品カテゴリーを限定した分析であり、対象商品あるいはカテゴリーが多くなるとモデル推定の負荷が大きくなり、SKU 数の多い商品群を対象とした場合、現実的な対応は困難である。この問題に対して Dippold and Hruschka (2013) は、実際に相関を有する商品ペアは限られており、特定の商品間以外は無相関を仮定したモデルの方がモデルの適合性が優れていることを示した。しかし、現実の商品数、カテゴリー数を想定すると、彼らのアプローチでも限定的な解決策にしかならず、小売業を対象とした購買点数問題に対しては、大きな課題が残っている。

### 3.3 モデル

本節には提案モデルを示す。消費者の小売店での購買点数は、小売店頭での値引きなどのプロモーション活動や慣性行動（平日に来店しやすい、週末に来店しやすい等）に加えて、消費者の購買時点での心的状況が影響する。行動経済学の知見を援用すると、この心的状況を捉える一つ概念として心理会計がある。心理会計とは、消費者の購入商品や購買時の状況に応じて、同一の消費者でも購買反応が異なるというものである。心理会計の下では評価関数が異なり、それぞれ独自の購買レジームが存在することを意味する。購買レジームの切換えは、購買時の心的状況によって生じるものであり、潜在的なものである。そこで、消費者の購買時における心的状況を表す潜在指標として、心的負荷を定め、消費者ごとに推定される閾値パラメータとの大小関係で、消費者の購買レジームが切換るもの

と仮定する。心的負荷とは、消費者の購買時の心理的な逼迫度を表す潜在指標であり、毎月の給料日ごとに軽減され、購買機会のたびに加重される。そこで本研究では、消費者の購買時における心的負荷を、消費者ごとの給与支給日を念頭においた潜在変数としてモデル化する。

提案モデルは、消費者の各購買機会を心的負荷と閾値パラメータの大小関係でレジーム分けし、来店あたりの購買点数の生起メカニズムをモデル化する。各レジームには、それぞれに対応した評価関数が存在することになる。観測される構造は、閾値で振り分けられるレジームごとに異なる回帰係数を有したポアソン回帰モデル（閾値ポアソン回帰モデル）の枠組みでモデル化する。これらの構造は、消費者ごとにその構造が大きく異なることに配慮し、階層ベイズの枠組みで消費者間の共通性を取込みモデル化する。以下、3.3.1節には心的影響要因モデル、3.3.2節には個体内モデル、3.3.3節には個体間モデルをそれぞれ示す。

### 3.3.1 心的影響要因モデル（心理会計モデル）

#### ■ 収支バランスの圧力モデル（心的負荷モデル）

本小節では、潜在変数である心的負荷のモデルを示す。消費者世帯の給料日は通常特定できないので、その前提で心的負荷をモデル化する。具体的には、代表的な給料日である毎月25日、5日、17日を前提とし、(3.1)式には、それぞれに対応した累積購買集計期間の記号を導入する。

$$\text{累積購買集計期間} \begin{cases} l=1 \Rightarrow \text{前月25日から今月24日まで} \\ l=2 \Rightarrow \text{前月5日から今月4日まで} \\ l=3 \Rightarrow \text{前月17日から今月16日まで} \end{cases} \quad (3.1)$$

(3.2)式には消費者*i*の集計対象期間*l*における購買機会*t<sub>i</sub>*までの累積購買金額を示す。

$$\text{cum}_{i,t_i,l} = \begin{cases} \sum_{j=1}^{\text{trans}^l(t_i)-1} M_{i,j,l} & \text{tran}^l(t_i) \neq 1 \\ 0 & \text{tran}^l(t_i) = 1 \end{cases} \quad (3.2)$$

$\text{trans}^l(t_i)$ は、消費者*i*の集計対象期間*l*における集計起点日から*t<sub>i</sub>*までの来店回数を表す。 $M_{i,j,l}$ は、消費者*i*の集計期間内*l*の購買機会*j*における購買金額を表す。本研究にお

ける心的負荷は、3つ累積購買金額の結合として(3.3)式で定義する。

$$CummM_{i,t_i} = \alpha_i^{*(1)} cum_{i,t_i,1} + \alpha_i^{*(2)} cum_{i,t_i,2} + \alpha_i^{*(3)} cum_{i,t_i,3} \quad (3.3)$$

$\alpha_i^{*(k)}$  ( $k = 1, 2, 3$ ) は  $0 \leq \alpha_i^{*(k)} \leq 1$  および  $\sum_{k=1}^3 \alpha_i^{*(k)} = 1$  の制約を満たすパラメータであり、 $\alpha_i^* = (\alpha_i^{*(1)}, \alpha_i^{*(2)})$  とする。(3.3)式の構造を、 $\alpha_i^{*(1)} = 1$  となるシングルインカム(給料日25日)を例に説明する。消費者*i*の当該期間中*n*回目の訪問機会*t<sub>i</sub>*を明示的に*t<sub>i,n</sub>*とすると、毎月25日以降の初回購買機会においては  $cum_{i,t_i,1} = 0$  である。2回目の購買機会では、初回購買機会での購買金額を用いて  $cum_{i,t_i,2,1} = M_{i,1,1}$  となり、3回目では2回目の購買金額  $M_{i,2,1}$  が加わり  $cum_{i,t_i,3,1} = M_{i,1,1} + M_{i,2,1}$  となる。*n*回目の購買機会では  $cum_{i,t_i,n,1} = M_{i,1,1} + M_{i,2,1} + \dots + M_{i,n-1,1}$  となる。次月25日以降は上記を繰り返して  $cum_{i,t_i,n,1}$  が生成される。他の累積購買集計期間についても同様である。また、 $\alpha_i^{*(1)} = \alpha_i^{*(2)} = 0.5$  はダブルインカム(給料日25日と5日)に対応しており、上記の例より多少複雑になるが、心的負荷の状態を同様に表現できる。図3.1には、シングルインカムの心的負荷を、図3.2は、2つの給料日がある程度混合したダブルインカムの心的負荷を例示した。本モデルを用いれば、上記の内容に加えて、通常は知り得ない、各世帯の給料日を推定できる。いずれにしても、本提案のモデル化により、 $CummM_{i,t_i}$  が小さければ心的負荷が軽減された状態を、その値が大きくなれば心的負荷が加重された状態をそれぞれ表現できる。

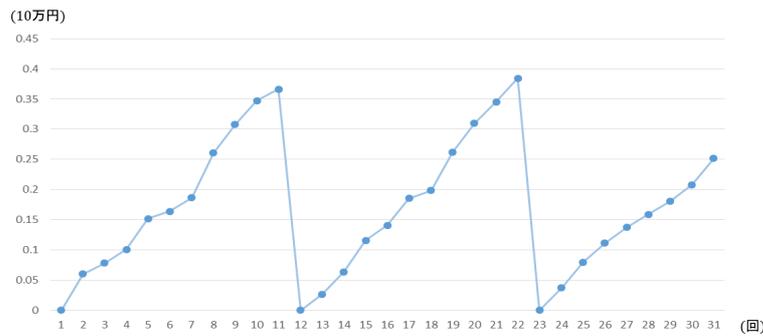


図 3.1: 心的影響要因 (シングルインカムの例)

本モデルの心的負荷とは、給料日を起点とした累積購買金額として定義される。毎月の給料日には、支出可能な予算が最大額確保された状態にあり、その時点から購買する度に予算残高は減少する。実際の支給金額は不明ではあるものの、累積購買金額に比例して予算残高は減少し、それとともに消費者が予算残高に対して抱くであろう不安感(支出に対

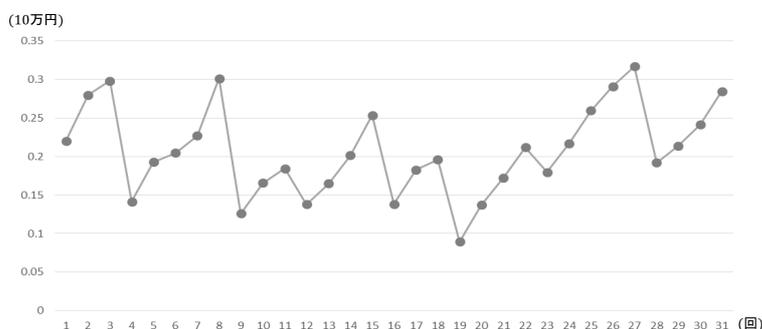


図 3.2: 心的影響要因 (ダブリインカムの例)

する心理的なプレッシャー) を心的負荷として表している。この不安感の度合いは、消費者世帯の家族構成や世帯所得金額などによって異なる。心的負荷は、給料日を基準(ゼロ)とした相対的なものであり、給料日を起点として購買する度に増加すると仮定する。そのため、給料日がどこに設定されるかによって、同じ時点であっても心的負荷の大きさも異なる。世帯に給与所得者が一人、または複数人でも同じ給料日の場合、心的負荷と累積購買の関係性は単純である。一方、世帯に異なる給料日の給与所得者が複数人いる場合は、解釈に留意が必要である。以下に、異なる給料日の給与所得者が二人存在する世帯を例に、心的負荷に関する意味合いについて解説しておく。図 3.3 において、起点 1 から始まる鋸歯状波形は  $cum_{i,t,1}$  に、起点 2 から始まる鋸歯状波形は  $cum_{i,t,2}$  に相当する。これらは、同一消費者世帯  $i$  の購買履歴データにもとづくため、時刻  $t$  における購買金額 ( $M_{i,t,t}$ ) は  $cum_{i,t,1}$  および  $cum_{i,t,2}$  で同一である。しかしながら、累積購買金額の起点(毎月の給料日)が異なるため、 $cum_{i,t,1} \neq cum_{i,t,2}$  である。異なる給料日の給与所得者が世帯に二人存在する場合、時刻 ( $t$ ) で購買金額 ( $M_{i,t,t}$ ) が生じたとき、それぞれの保有残高にどれだけの心理的負担を及ぼすかの比率が図 3.4 に示す  $\alpha_i^{*(1)} : \alpha_i^{*(2)}$  ということである。単純なケースとして、各給料日における支給額の割合で分配することが考えられる。支給額に関わらず、夫婦で均等に負担する世帯、世帯主が全て負担する世帯等さまざまなケースが存在する。この心理的負担比率を起点 1 および起点 2 とする累積購買金額全体に適用したものが図 3.5 であり、図 3.3 の各鋸歯状波形全体に、それぞれ  $\alpha_i^{*(1)}, \alpha_i^{*(2)}$  倍して得られる。ただし、 $\alpha_i^{*(1)} + \alpha_i^{*(2)} = 1$  の条件を課すことにより、起点 1 および起点 2 とする累積購買金額を併せた際の時刻 ( $t$ ) における消費者世帯 ( $i$ ) の購買金額は  $M_{i,j,t}$  となる。図 3.5 の 2 つの鋸歯状波形を合算させたものを図 3.6 に示す。さらに、起点 3 として異なる別の鋸歯状を追加した場合でも同様に

説明される。

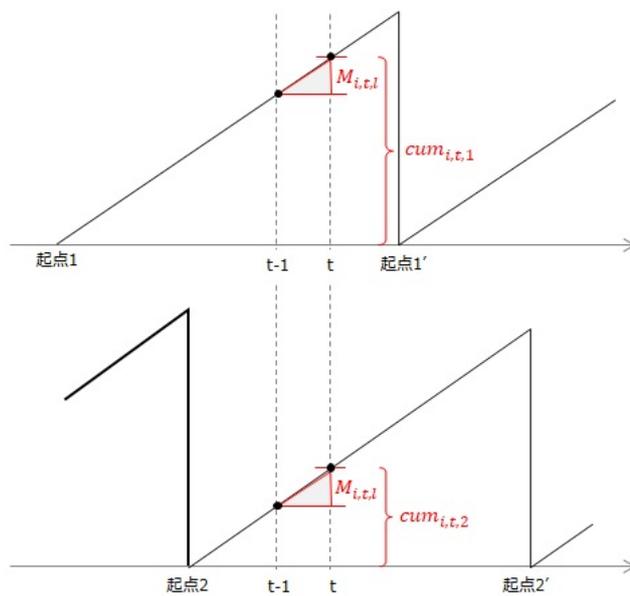


図 3.3: 累積購買金額 ( $M_{i,t,l}$ ) の給料日ごとの負担割合

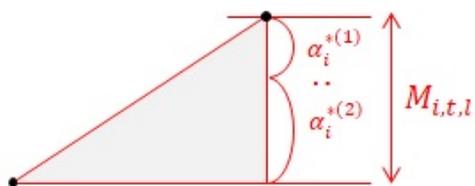


図 3.4: 起点 (給料日) の異なる 2 つの累積購買金額

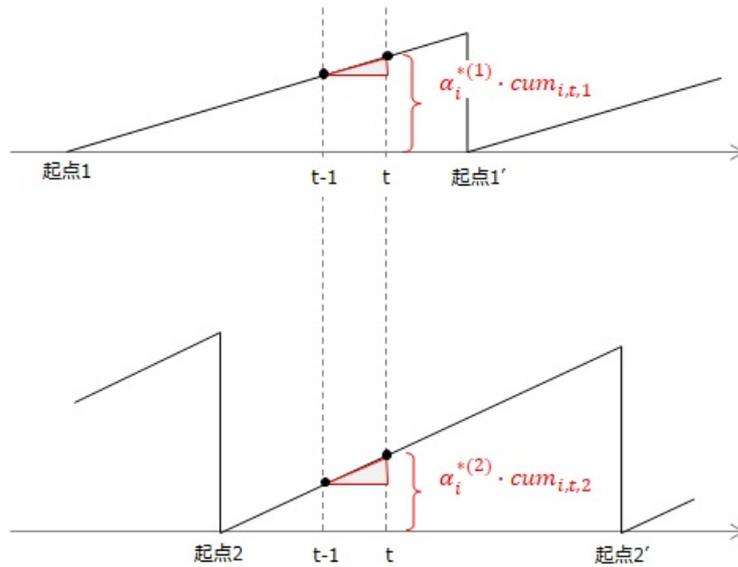


図 3.5: 給与日ごとの心理的負担割合で分配された累積購買金額

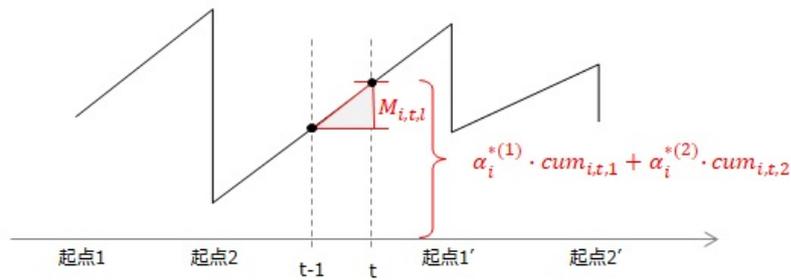


図 3.6: 異なる給料日の給与所得者 2 名いる場合の累積購買金額の合算

### 3.3.2 個体内モデル（観測モデル）

本小節には、本研究の個体内モデルである閾値購買点数モデルを示す。消費者  $i$  による購買機会  $t_i$  での購買点数を  $y_{i,t_i}$  とする。本研究では、(3.3) 式で示した心的負担と消費者  $i$  の閾値パラメータ  $\gamma_{cum,i}$  の大小関係により、 $Y_{i,t_i}$  の生起メカニズムの切替が生じると仮定する。本研究では二つのレジームを仮定し、心的負担が加重された状況をレジーム 1、一方

の心的負荷が軽減された状況をレジーム 2 とする。レジーム 1 とレジーム 2 では、異なる評価関数<sup>1</sup>を有する。本研究では、 $y_{i,t_i}$  がカウントデータである点を考慮し、ポアソン分布を用いて個体内モデルを定式化する。(3.4) 式が、本研究における個体内モデルである。

$$\begin{aligned} & Pr(Y_{i,t_i} = y_{i,t_i} \mid \lambda_{i,t_i}^{(1)}, \lambda_{i,t_i}^{(2)}, \gamma_{cum,i}, \alpha_i, \mathbf{cum}_{i,t_i}) \\ &= \begin{cases} \frac{(\lambda_{i,t_i}^{(1)})^{y_{i,t_i}} \exp(-\lambda_{i,t_i}^{(1)})}{y_{i,t_i}!} & CummM_{i,t_i} \geq \gamma_{cum,i} \quad (\text{レジーム 1}) \\ \frac{(\lambda_{i,t_i}^{(2)})^{y_{i,t_i}} \exp(-\lambda_{i,t_i}^{(2)})}{y_{i,t_i}!} & CummM_{i,t_i} < \gamma_{cum,i} \quad (\text{レジーム 2}) \end{cases} \end{aligned} \quad (3.4)$$

$\lambda_{i,t_i}^{(k)}, k = 1, 2$  は各レジームのレートパラメータであり、非負制約を有するため、 $\ln(\lambda_{i,t_i}^{(k)}) = \mathbf{x}_{i,t_i}^{t(k)} \boldsymbol{\beta}_i^{(k)}$ ,  $k = 1, 2$  のように対数回帰変換で構造化する。(詳細については付録 A.1 を参照) 各レジームの説明変数と回帰係数を、それぞれ  $\mathbf{x}_{i,t_i}^{(k)} = (x_{i,t_i,1}^{(k)}, x_{i,t_i,2}^{(k)}, \dots, x_{i,t_i,p_k}^{(k)})^t$  および  $\boldsymbol{\beta}_i^{(k)} = (\beta_{i,1}^{(k)}, \beta_{i,2}^{(k)}, \dots, \beta_{i,p_k}^{(k)})^t$ ,  $k = 1, 2$  とし、 $p_k$  は説明変数と回帰係数の次元である。消費者  $i$  の総購買機会数を  $N_i$  とすると、 $\mathbf{cum}_{i,l} = (cum_{i,t_{i,1},l}, cum_{i,t_{i,2},l}, cum_{i,t_{i,3},l}, \dots, cum_{i,t_{i,N_i},l})^t, l = 1, 2, 3$  であり、これらをまとめて  $\mathbf{cum}_i = (cum_{i,1}^t, cum_{i,2}^t, cum_{i,3}^t)$  とする。また、レジームに関わらず、消費者  $i$  の全購買機会 1 から  $N_i$  までの説明変数をまとめて  $\mathbf{x}_i = (\mathbf{x}_{i,t_{i,1}}^{(k_1)}, \mathbf{x}_{i,t_{i,2}}^{(k_2)}, \mathbf{x}_{i,t_{i,3}}^{(k_3)}, \dots, \mathbf{x}_{i,t_{i,N_i}}^{(k_{N_i})})^t$  と表す。ただし、時点  $t_{i,n}$  におけるレジームは  $CummM_{i,t_i}$  と  $\gamma_{cum,i}$  の大小関係で決定され、明示的に  $k_n$  とした。次に、どちらのレジームに振り分けられたかの集合を示す記号  $R^{(k)} (k = 1, 2)$  を導入する。ここで  $t_i$  ごとに  $k$  は、 $CummM_{i,t_i}$  と  $\gamma_{cum,i}$  により、(3.4) 式のレジーム番号に対応して割り当てられる。 $N_i$  に対応する時点を  $T_i$  とすると、(3.5) 式が消費者  $i$  の全購買機会  $\mathbf{y}_i = (y_{i,t_{i,1}}, y_{i,t_{i,2}}, \dots, y_{i,T_i})^t$  に対する尤度関数となる。

$$\begin{aligned} p(\mathbf{y}_i \mid \boldsymbol{\beta}_i^{(1)}, \boldsymbol{\beta}_i^{(2)}, \gamma_{cum,i}, \alpha_i, \mathbf{cum}_i, \mathbf{x}_i) &= \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}} \left( \frac{(\lambda_{i,t_i}^{(k)})^{y_{i,t_i}} \exp(-\lambda_{i,t_i}^{(k)})}{y_{i,t_i}!} \right) \right\} \\ &\propto \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}} \left( (\exp(\mathbf{x}_{i,t_i}^{t(k)} \boldsymbol{\beta}_i^{(k)}))^{y_{i,t_i}} \exp(-\exp(\mathbf{x}_{i,t_i}^{t(k)} \boldsymbol{\beta}_i^{(k)})) \right) \right\} \end{aligned} \quad (3.5)$$

さらに、消費者同士は独立であると仮定すると、(3.6) 式に示す全消費者 ( $i = 1, 2, \dots, H$ ) に対する全体尤度が定式化できる。なお、具体的なモデル変数 ( $\mathbf{x}_{i,t_i}$ ) に関する説明は、表 3.1 に後述する。

<sup>1</sup>心理会計は、プロスペクト理論を根拠とした概念であり、プロスペクト理論の参照点为本モデルの閾値に相当し、その前後で2つの異なる購買レジームを有するという考え方を踏襲する。

$$\begin{aligned}
p(\{y_i\}|\{\beta_i^{(1)}\}, \{\beta_i^{(2)}\}, \{\gamma_{cum,i}\}, \{\alpha_i\}, \{cum_i\}, \{x_i\}) &= \prod_{i=1}^H \left\{ \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}} \left( \frac{(\lambda_{i,t_i}^{(k)})^{y_{i,t_i}} \exp(-\lambda_{i,t_i}^{(k)})}{y_{i,t_i}!} \right) \right\} \right\} \\
&\propto \prod_{i=1}^H \left\{ \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}} \left( \exp(x_{i,t_i}^{(k)} \beta_i^{(k)})^{y_{i,t_i}} \exp(-\exp(x_{i,t_i}^{(k)} \beta_i^{(k)})) \right) \right\} \right\} \quad (3.6)
\end{aligned}$$

### 3.3.3 個体間モデル（階層モデル）

本小節には、消費者ごとの異質なパラメータの背後に存在する共通性の構造を示す階層モデルを示す。ポアソン回帰の回帰係数  $\beta_i^{(k)}$ ,  $k = 1, 2$  と閾値パラメータ  $\gamma_{cum,i}$  の対数をあわせて、 $\theta_i = (\beta_i^{(1)}, \beta_i^{(2)}, \log(\gamma_{cum,i}))$  と定義する。また、心的負荷モデルの構成パラメータ  $\alpha_i^*$  のロジット変換前のパラメータベクトルを  $\alpha_i = (\alpha_i^{(1)}, \alpha_i^{(2)})$  とする。ここで  $\alpha_i$  は、 $\alpha_i^{*(k)} = \frac{\exp(\alpha_i^{(k)})}{1 + \sum_{l=1}^2 \exp(\alpha_i^{(l)})}$ ,  $k = 1, 2$  の逆変換として定義する。このとき、(3.7), (3.8) 式が、消費者  $i$  の階層モデルとなる。なお、具体的な属性変数 ( $z_i$ ) に関する説明は、表 3.1 に後述する。

$$\theta_i = z_i^t \Delta_\theta + \epsilon_i^\theta, \epsilon_i^\theta \sim \mathcal{MVN}(\mathbf{0}, \Sigma_\theta) \quad (3.7)$$

$$\alpha_i = z_i^t \Delta_\alpha + \epsilon_i^\alpha, \epsilon_i^\alpha \sim \mathcal{MVN}(\mathbf{0}, \Sigma_\alpha) \quad (3.8)$$

$\theta_i, \alpha_i$  は、消費者  $i$  の属性変数  $z_i = (z_{i,1}, z_{i,2}, \dots, z_{i,q})^t$  と係数行列  $\Delta_\theta, \Delta_\alpha$  の線形結合で表し、 $q$  は属性変数の次元、 $\Sigma_\theta, \Sigma_\alpha$  は、それぞれの分散共分散行列である。事前分布の設定にあたっては、 $p(\Delta_\theta, \Sigma_\theta) = p(\Delta_\theta | \Sigma_\theta) p(\Sigma_\theta)$ ,  $p(\Delta_\alpha, \Sigma_\alpha) = p(\Delta_\alpha | \Sigma_\alpha) p(\Sigma_\alpha)$  の関係式を用い、 $p(\Delta_\theta | \Sigma_\theta), p(\Delta_\alpha | \Sigma_\alpha)$  は多変量正規分布に、 $p(\Sigma_\theta), p(\Sigma_\alpha)$  は逆ウィッシュャート分布を仮定する。（実証データによる推定で設定した事前分布については付録 A.2 を参照。）

$$\begin{aligned}
\delta_\theta &= \text{vec}(\Delta_\theta) \sim \mathcal{MVN}(\bar{\delta}_\theta, \Sigma_\theta \otimes A_\theta^{-1}) \\
\Sigma_\theta &\sim \mathcal{IW}(v_{\theta,0}, V_{\theta,0}) \quad (3.9)
\end{aligned}$$

$$\begin{aligned}
\delta_\alpha &= \text{vec}(\Delta_\alpha) \sim \mathcal{MVN}(\bar{\delta}_\alpha, \Sigma_\alpha \otimes A_\alpha^{-1}) \\
\Sigma_\alpha &\sim \mathcal{IW}(v_{\alpha,0}, V_{\alpha,0}) \quad (3.10)
\end{aligned}$$

### 3.4 アルゴリズム

本節では、提案モデルの事後分布を示し、それに基づくモデルの推定アルゴリズムを概説する。

#### 3.4.1 事後分布

本小節には、提案モデルの推定アルゴリズムの基となる事後分布を提示する。図 3.7 は消費者  $i$  の購買時点  $t_{i,t_i}$  における、本提案モデルから導出される有向非巡回グラフ (DAG : Directed Acyclic Graph) である。図 3.7 に示す DAG に基づき、消費者間の独立性を仮定すると、(3.11) 式の事後分布を導出できる。

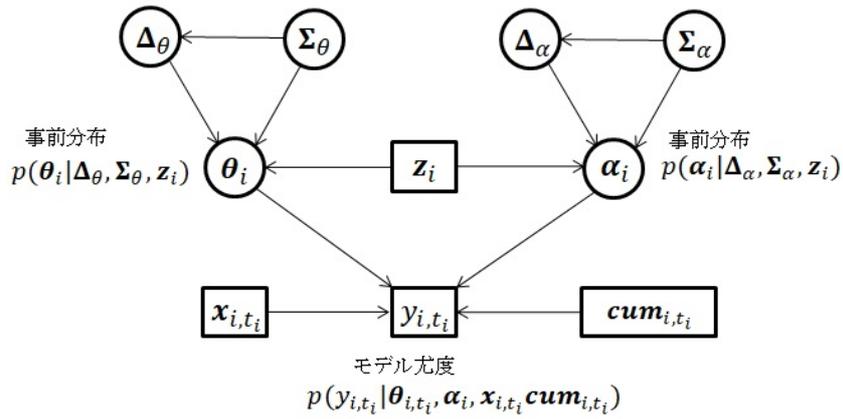


図 3.7: 提案モデルの有向非巡回グラフ

$$\begin{aligned}
 p(\Theta, \mathcal{A}|Y, X, Z, Cum) &\propto p(\Delta_\theta|\Sigma_\theta)p(\Sigma_\theta)p(\Delta_\alpha|\Sigma_\alpha)p(\Sigma_\alpha) \\
 &\times \prod_{i=1}^H p(y_i|\theta_i, \alpha_i, x_i, cum_i)p(\theta_i|\Delta_\theta, \Sigma_\theta, z_i)p(\alpha_i|\Delta_\alpha, \Sigma_\alpha, z_i)
 \end{aligned} \tag{3.11}$$

ただし、 $\Theta \equiv \{\theta_i\} = (\theta_1, \theta_2, \dots, \theta_H)$ ,  $\mathcal{A} \equiv \{\alpha_i\} = (\alpha_1, \alpha_2, \dots, \alpha_H)$ ,  $Z \equiv \{z_i\} = (z_1, z_2, \dots, z_H)$ ,  $X \equiv \{x_i\} = (x_1, x_2, \dots, x_H)$ ,  $Y \equiv \{y_i\} = (y_1, y_2, \dots, y_H)$ ,  $Cum \equiv \{cum_i\} = (cum_1, cum_2, \dots, cum_H)$  である。

### 3.4.2 カーネル

3.4.1節の事後分布に示した提案モデルには、 $\Theta, \mathcal{A}, \Delta_\theta, \Delta_\alpha, \Sigma_\theta, \Sigma_\alpha$  が含まれる。  $\Theta, \mathcal{A}$  は消費者ごとに異なるパラメータであり、  $\Delta_\theta, \Delta_\alpha, \Sigma_\theta, \Sigma_\alpha$  は消費者間で共通のパラメータである。 これらパラメータの推定には、マルコフ連鎖モンテカルロ法 (MCMC: Markov chain Monte Carlo method) を用いる。 推定アルゴリズムは、(3.11) 式に基づき構成する。 すなわち、  $\Theta, \mathcal{A}$  は非共役なため、そのサンプリングにはランダムウォークメトロポリス・ヘイスティングス (ランダムウォーク M-H) 法を用いる。 一方、階層パラメータ  $\Delta_\theta, \Delta_\alpha, \Sigma_\theta, \Sigma_\alpha$  は 3.3.3 節に示した通り共役になるため、標準的なギブスサンプラーを用いてサンプリングする。 消費者  $i$  ごとの  $\theta_i$  と  $\alpha_i$  のサンプリングには、ランダムウォーク M-H 法を用いるが、事後分布からのサンプル候補値を生成するためのカーネルを (3.12) 式と (3.13) 式に示す。

全ての消費者に対して共通なパラメータである  $\Delta_\theta, \Delta_\alpha, \Sigma_\theta, \Sigma_\alpha$  および  $\alpha_i$  を所与として、ランダムウォークサンプラーから生成した  $\theta_i$  を (3.12) 式に示す事後分布カーネルを用いて評価し、採択/棄却を確率的に決定する。

$$p(\mathbf{y}_i | \theta_i, \alpha_i, \mathbf{x}_i) p(\theta_i | \Delta_\theta, \Sigma_\theta, \mathbf{z}_i) \propto \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} \left( (\exp(\mathbf{x}_{i,t_i}^{(k)t} \boldsymbol{\beta}_i^{(k)}))^{y_{i,t_i}} \exp(-\exp(\mathbf{x}_{i,t_i}^{(k)t} \boldsymbol{\beta}_i^{(k)})) \right) \right\} \\ \times \exp \left\{ -\frac{1}{2} (\boldsymbol{\theta}_i - \mathbf{z}_i^t \boldsymbol{\Delta}_\theta)^t \boldsymbol{\Sigma}_\theta^{-1} (\boldsymbol{\theta}_i - \mathbf{z}_i^t \boldsymbol{\Delta}_\theta) \right\} \quad (3.12)$$

同様に、  $\alpha_i$  に対しては、  $\Delta_\theta, \Delta_\alpha, \Sigma_\theta, \Sigma_\alpha$  および  $\theta_i$  を所与として、ランダムウォークサンプラーから生成した  $\alpha_i$  を (3.13) 式に示す事後分布カーネルを用いて評価し、採択/棄却を確率的に決定する。

$$p(\mathbf{y}_i | \theta_i, \alpha_i, \mathbf{x}_i) p(\alpha_i | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i) \propto \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} \left( (\exp(\mathbf{x}_{i,t_i}^{(k)t} \boldsymbol{\beta}_i^{(k)}))^{y_{i,t_i}} \exp(-\exp(\mathbf{x}_{i,t_i}^{(k)t} \boldsymbol{\beta}_i^{(k)})) \right) \right\} \\ \times \exp \left\{ -\frac{1}{2} (\boldsymbol{\alpha}_i - \mathbf{z}_i^t \boldsymbol{\Delta}_\alpha)^t \boldsymbol{\Sigma}_\alpha^{-1} (\boldsymbol{\alpha}_i - \mathbf{z}_i^t \boldsymbol{\Delta}_\alpha) \right\} \quad (3.13)$$

推定アルゴリズムの詳細および階層パラメータを含めた初期値については、付録 A.2 に示す。 また、推定用のサンプルプログラムを付録 A.3 に示す。

## 3.5 実証分析

### 3.5.1 分析データ

本研究の実証分析を都内にあるスーパーマーケットの ID-POS データを用いて実施した。分析対象の消費者は、2007 年 1 月 1 日から 2007 年 12 月 31 日までの期間中に 50 回以上かつ毎月 1 回以上の購買履歴がある世帯からランダムに 1,000 人を抽出した。本モデルでは、消費者毎の購買点数を被説明変数としているため、カテゴリーやブランドの選択モデルとは異なり、予め購買対象となる商品の条件付けは行わない。したがって、特定カテゴリーに限定せず、店舗全体の特性を表す説明変数、および世帯固有の変数を用いる。

当該店舗で販売されている商品は、食料品と日用雑貨品に大別され、さらに食料品は野菜、魚、肉などの生鮮食料品とそれ以外の非生鮮食料品に分けられる。生鮮食料品は、市場で都度仕入れられるため定価はなく、時価で取引される。一方、非生鮮食料品はメーカーの定める定価が存在する。販売される各商品は、JAN (Japanese Article Number) と呼ばれる日本の共通商品コードに店舗独自のコードを付加したアイテムコードで販売価格や数量が管理されている。生鮮食料品に対しても、個別のアイテムコードが割り与えられているが、野菜や肉でも産地や品質などの違いによってコードが複数存在するため、これらに対して値引率を変数として扱うのは難しい。したがって、本実証分析では、値引率に対する議論は非生鮮食料品と日用雑貨品に限定する。通常、小売店舗で扱う商品の種類は大変多く、すべての商品が毎日購買されているわけではないため、日によって購買される商品数は変動する。一方、頻繁に購買される定番商品も存在し、年間を通して安定的に販売されている。本実証分析で用いる変数として、毎月必ず販売実績のある定番商品の中、15%以上の値引きを実施している商品割合の日次変動を図 3.8 に示す。同時に、世帯あたりの平均購買点数も示した。値引商品の割合が多い日に平均購買点数も多くなる場合も確認できるが、割引商品が多いというだけで、消費者の購買点数が多くなるとは限らない。

表 3.1 には、本実証分析に用いるモデル変数を示す。消費者の購買行動の研究では、さまざまな説明要因が取り上げられている。店外要因としては、TV や新聞などによるマス広告、新聞折込みによるチラシ広告などがある。これらは、消費者の店舗訪問を促進させる要因としても影響する。一方、店内要因としては、訪問時間帯、滞在時間、天候、混雑状況、帯同人数、購買リスト、支払方法など消費者側の状況要因、および店舗側要因として、品揃え、値引き、特別陳列、レジやスタッフの稼働数、店舗レイアウト、ポイントカード

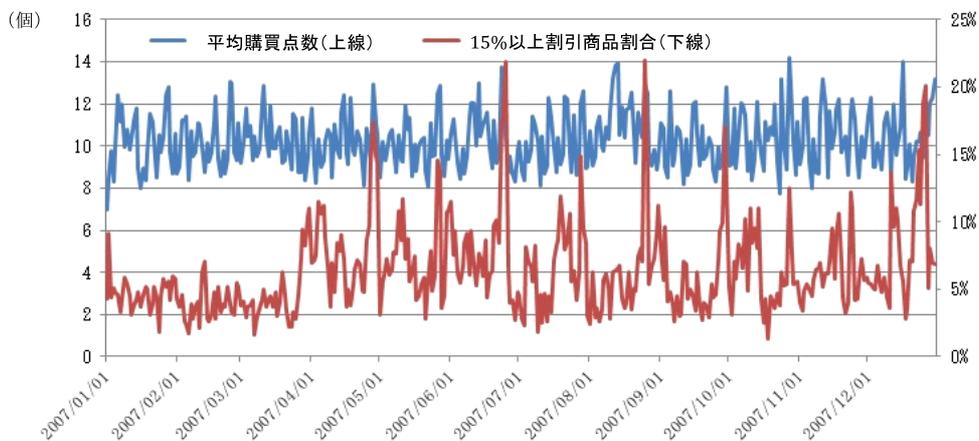


図 3.8: 15 %以上値引を実施している定番商品の割合

などが挙げられる。また、消費者属性の違いによっても購買行動に差が生じる可能性がある。ここでいう消費者属性は、所得、性別、年齢、世帯人数、居住地から店舗までの距離、店舗への交通手段などである。しかしながら、これらすべての要因を網羅して分析することは、データの利用可能性から不可能である。マーケティング領域のブランド選択の研究では、商品の値引き、チラシ広告への掲載、特別陳列の実施が説明変数として採用されることが多い。しかし、本実証分析データには、データ取得の都合上、チラシ広告と特別陳列に関する情報は含まれていない。また、分析対象を特定商品に限定しているわけではないため、特定の商品値引率を説明変数として直接採用することは意味がない。そこで、毎月一点以上購買履歴のある定番商品の中、15%以上の値引きが実施されている商品の割合 (*DCNT*) を値引き相当の説明変数 (図 3.8) として採用した。さらに、マーケティング領域では、消費者の購買行動を評価する指標として *RFM* (*Recency, Frequency, Monetary*) が用いられる。本分析では、前回購買機会からの経過日数 (*DRTN*) を説明変数に、年間累積購買金額の対数値 (*SPND*) と年間購買機会数の対数値 (*OPPT*) を消費者の属性変数 (個体間モデルの説明変数) に用いる。その他の説明変数には、来店時間ダミー (*TIME*) と来店曜日ダミー (*WKND*) が、属性変数には年齢 (*LAGE*) と性別 (*GNDR*) を採用した。なお、今回ランダムに抽出した消費者 1,000 人の平均年齢は 55.3 才、女性 81.8% (男性 18.2%)、平均購買金額 2.5 万円/月、平均購買回数 12.0 回/月である。

表 3.1: 変数表：モデル変数

レベル	記号	変数
消費者 $i \times$ 日 $t_i$ ( $\mathbf{x}_{i,t_i}$ )	$y_{i,t_i}$	購買点数 (被説明変数)
	$CNST$	定数：1
	$DCNT_{i,t_i}$	15 % 以上値引き商品比率
	$DRTN_{i,t_i}$	前回購買機会からの経過日数 (最大値 50 日で規格化)
	$TIME1_{i,t_i}$	来店時間ダミー：9-13 時=1, それ以外=0
	$TIME2_{i,t_i}$	来店時間ダミー：14-18 時=1, それ以外=0
	$WKND_{i,t_i}$	来店曜日ダミー：土日=1, 平日=0
消費者 $i$ ( $\mathbf{z}_i$ )	$LAGE_i$	年齢の対数値
	$GNDR_i$	性別ダミー：女性=1, 男性=0
	$OPPT_i$	年間購買機会数の対数値
	$SPND_i$	年間累積購買金額の対数値

### 3.5.2 モデル評価

本節には、モデルの推定結果を示す。本研究では、MCMC の総繰り返し回数を 50,000 回、バーンインサンプルを 45,000 回とした。

本モデルの評価として、購買レジームを仮定しないモデル (基本モデル)、式 (1) において累積購買集計期間が  $l=1$  のみを用いたモデル (L1 モデル)、 $l=2$  のみを用いたモデル (L2 モデル)、 $l=3$  のみを用いたモデル (L3 モデル)、および 3 つの累積購買金額の線形結合を採用したモデル (提案モデル) に対して DIC (Deviance Information Criterion) を比較した。表 3.2 には、バーンインサンプルを破棄した後の 5,000 サンプルを用いて算出した DIC を示す。DIC に基づけば、提案モデルが採択され、以降の結果検証では、これら 5,000 サンプルのデータを用いて行う。

表 3.2: DIC によるモデル比較

名称	モデル概要	DIC
基本モデル	消費者購買レジームを仮定しないモデル	974,501
L1 モデル	累積購買集計期間 $l=1$ のみを用いたモデル	894,859
L2 モデル	累積購買集計期間 $l=2$ のみを用いたモデル	898,272
L3 モデル	累積購買集計期間 $l=3$ のみを用いたモデル	896,753
提案モデル	3 つの累積購買金額の結合を採用したモデル	826,738

### 3.5.3 回帰パラメータの検証

表 3.3 には、世帯ごとに算出した各回帰係数の事後平均分布<sup>2</sup>の基本統計量を示す。表 3.4 の上段には、疑似 t-値（事後平均/事後標準偏差）により該当パラメータが 5% 有意である消費者の割合を、下段にはその有意性をレジームを考慮して集計し直した結果を示した。以降、表 3.3 に基づき議論するが、世帯ごとに対しても同様の議論が行える。図 3.9 には、各パラメータのレジーム 1 とレジーム 2 のパラメータごとの分布状況を示す。なお、レジーム 1 は心的負荷が加重されている状況を表し、レジーム 2 は心的負荷が軽減された状況に対応している。

表 3.3: 事後平均分布の基本統計量

区分	統計量	$\beta_{i,1}^{(k)}$	$\beta_{i,2}^{(k)}$	$\beta_{i,3}^{(k)}$	$\beta_{i,4}^{(k)}$	$\beta_{i,5}^{(k)}$	$\beta_{i,6}^{(k)}$
レジーム 1 (k=1)	平均値	1.9522	0.4906	1.5062	0.1792	0.1140	0.1441
	中央値	1.9577	0.5065	1.3344	0.1811	0.0911	0.1134
	最大値	3.2192	7.1457	12.5072	2.2776	1.5465	1.6930
	最小値	0.3291	-5.0787	-4.6191	-1.3913	-1.3191	-1.2099
	標準偏差	0.4547	1.6834	2.5388	0.4701	0.3812	0.3608
レジーム 2 (k=2)	平均値	2.0037	0.5366	1.7540	0.1210	0.1215	0.1188
	中央値	1.9795	0.5605	1.7048	0.1252	0.1091	0.1018
	最大値	3.5483	7.9674	11.1798	1.6387	1.5013	1.3347
	最小値	0.3658	-8.0389	-9.5910	-1.7144	-1.7587	-1.2896
	標準偏差	0.4828	2.1893	3.0692	0.3941	0.3447	0.3124

$\beta_{i,1}^{(k)}$  はレジームごとの定数項であり、説明変数の影響を除去したベースの影響を示す。 $\beta_{i,1}^{(1)} < \beta_{i,1}^{(2)}$  は、心的負荷が逼迫した状態で来店すると、それだけで買え控えの心理が働くことを示す。消費者によって異質ではあるが、平均的には買い控えの傾向を示す。値引商品の割合に関して、 $\beta_{i,2}^{(1)} < \beta_{i,2}^{(2)}$  となる消費者は心的負荷が緩慢なほど商品を購入しやすく、 $\beta_{i,2}^{(1)} \geq \beta_{i,2}^{(2)}$  の場合は、その逆の傾向を示す。消費者行動の観点から考えれば、 $\beta_{i,2}^{(1)} < \beta_{i,2}^{(2)}$  が自然であるが、心理会計の状況によって買物する商品の質に変化が生じている場合（例えば、大パック 1 個→安売りしている小分け複数など）を想定すれば、 $\beta_{i,2}^{(1)} \geq \beta_{i,2}^{(2)}$  ということも起こり得る。 $\beta_{i,3}^{(1)} < \beta_{i,3}^{(2)}$  は、前回購買からの経過時間が同じであれば、レジーム 2 の方が購買点数は大きく、 $\beta_{i,3}^{(1)} \geq \beta_{i,3}^{(2)}$  では、その逆となる。消費者行動の観点からは、 $\beta_{i,3}^{(1)} < \beta_{i,3}^{(2)}$  が自然

<sup>2</sup>事後分布にもとづく消費者ごとの平均値の分布を、ここでは事後平均分布と呼ぶ。

であるが、家庭内の需要を満たすべくいくつかの小売店を買いまわる行動が、レジーム1では該当の店舗のみで必要な買物をするだけの行動へ変化するなど想定すれば、 $\beta_{i,3}^{(1)} \geq \beta_{i,3}^{(2)}$ ということも起こり得る。平均的には、心的負荷が緩慢なときほど、前回購買からの時間間隔が長くなるほど購買点数は多くなる。 $\beta_{i,4}^{(k)}, \beta_{i,5}^{(k)}, \beta_{i,6}^{(k)}$ であるが、レジーム間で係数の大きさには大差はない。これら3つの係数は表3.4で見ると、両レジームともに有意な推定値の割合は20%前後と低く、 $\beta_{i,2}^{(k)}, \beta_{i,3}^{(k)}$ で40-50%程度、 $\beta_{i,1}^{(k)}$ では99%以上であるのとは異なる。また、 $\beta_{i,1}^{(k)}, \beta_{i,2}^{(k)}, \beta_{i,3}^{(k)}$ の標準偏差は、レジーム2の方が大きいだが、 $\beta_{i,4}^{(k)}, \beta_{i,5}^{(k)}, \beta_{i,6}^{(k)}$ は、レジーム間で標準偏差に大きな差は見られず、消費者異質性も大差ない。

表 3.4: 5%有意な推定値の割合 (%)

区分	$\beta_{i,1}^{(k)}$	$\beta_{i,2}^{(k)}$	$\beta_{i,3}^{(k)}$	$\beta_{i,4}^{(k)}$	$\beta_{i,5}^{(k)}$	$\beta_{i,6}^{(k)}$
レジーム1 (k=1)	99.7	59.5	69.4	38.4	34.0	43.8
レジーム2 (k=2)	100	66.6	75.6	35.8	37.9	48.1
レジーム1, 2とも有意である	99.7	39.7	51.7	15.4	15.2	22.0
レジーム1のみ有意である	0.0	19.8	17.7	23.0	18.8	21.8
レジーム2のみ有意である	0.3	26.9	23.9	20.4	29.8	26.1
レジーム1, 2とも有意でない	0.0	13.6	6.7	41.2	43.3	30.1

### 3.5.4 閾値パラメータの検証

本研究では、購買点数の生成メカニズムの切換点を、消費者ごとの潜在変数である閾値パラメータと心的負荷の大小関係から推定する。事後的に切換点を決定するデータ主導型のアプローチとは異なり、心理会計という消費者行動理論の知見を援用することで消費者購買状態の切換を推定している。表3.5には、消費者ごとに算出した閾値パラメータ ( $\gamma_{cum,i}$ ) の事後平均分布の基本統計量を示した。表3.6には、擬似t-値 (事後平均/事後標準偏差) により該当のパラメータが5%有意である消費者の割合を集計した結果を示す。これらパラメータは概ね安定的に推定されている。閾値パラメータの事後平均の平均は1.7万円であり、消費者の平均累積購買金額が2.5万円/月であることから、平均累積購買金額の68%を超える心理会計による購買レジームの切換が生じる換算となる。

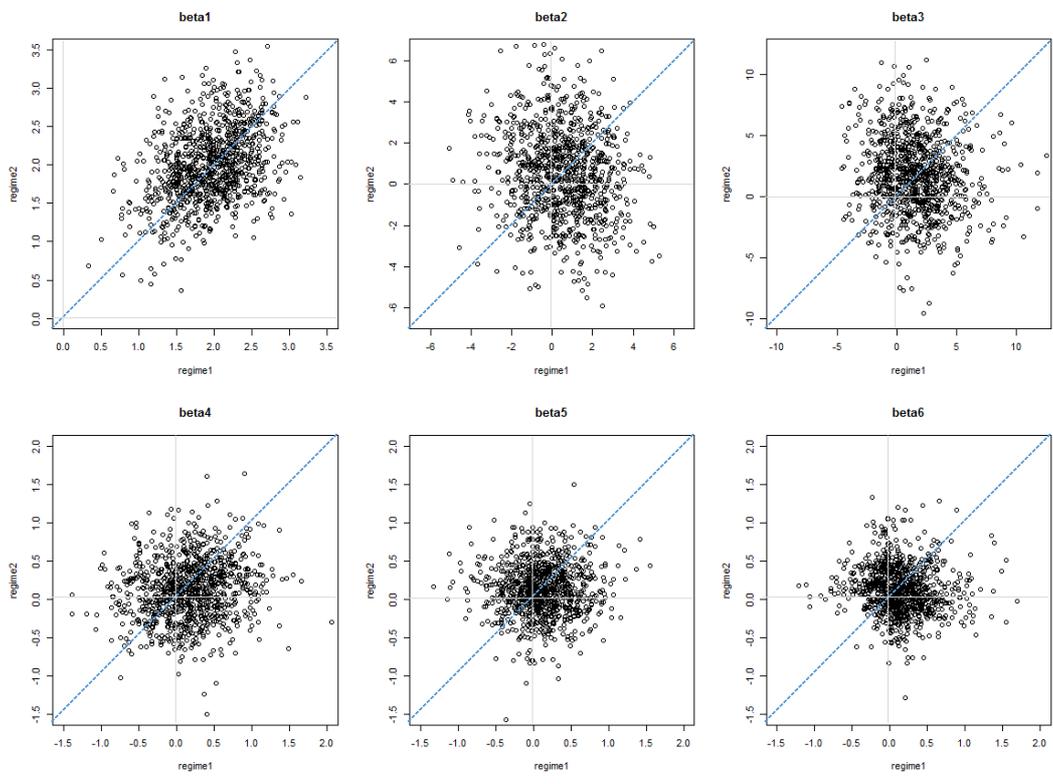


図 3.9: 回帰係数  $(\beta_{i,n}^{(1)}, \beta_{i,n}^{(2)})$ ,  $n = 1, 2, \dots, 6$  の散布図

表 3.5: 事後平均分布の基本統計量

統計量	閾値パラメータ ( $\gamma_{cum,i}$ )	構成パラメータ 1 ( $\alpha_i^{*(1)}$ )	構成パラメータ 2 ( $\alpha_i^{*(2)}$ )
平均値	0.1713	0.3538	0.3605
中央値	0.1073	0.0087	0.0079
最大値	1.8238	1.0000	1.0000
最小値	0.0055	0.0000	0.0000
標準偏差	0.2014	0.4347	0.4376

### 3.5.5 心的負荷パラメータの検証

表 3.5 には、消費者ごとに算出した心的負荷の構成パラメータ ( $\alpha_i^*$ ) の事後平均の基本統計量を示した。心的負荷のモデルが、代表的な給料日を基にしたモデル表現になっているた

め、各消費者の給料日に関して議論できる。表 3.6 には、擬似 t-値（事後平均/事後標準偏差）により該当のパラメータが 5%有意<sup>3</sup>である消費者の割合を集計した結果を示す。構成パラメータの各平均値は 0.35 程度であることから、各累積購買金額からの心的負荷への寄与は全体的に見ればほぼ均等である。図 3.10 には、 $\alpha_i^{*(1)}, \alpha_i^{*(2)}$  の事後平均の分布状況を示した。図中 (1,0), (0,1), (0,0) 近傍のプロットは購買期間がそれぞれ 1, 2, 3 のみ、 $\alpha^{*(1)} + \alpha^{*(2)} = 1$  の直線上のプロットは購買期間が 1 と 2、 $\alpha^{*(1)}$  軸上のプロットは購買期間が 2 と 3、 $\alpha^{*(2)}$  軸上のプロットは購買期間が 1 と 3、図中の三角形内のプロットは全ての購買期間で構成されるものであり、消費者ごとにその構成に差が生じている。

表 3.6: 5%有意な推定値の割合 (%)

閾値パラメータの対数値: $\ln(\gamma_{cum,i})$	$(\alpha_i^{(1)}, \alpha_i^{(2)})$	割合 (%)
$\ln(\gamma_{i,cum})$ が有意な場合 (N=970)	$\alpha_i^{(1)}, \alpha_i^{(2)}$ ともに有意である	71.6
	$\alpha_i^{(1)}$ のみ有意である	2.7
	$\alpha_i^{(2)}$ のみ有意である	12.2
	$\alpha_i^{(1)}, \alpha_i^{(2)}$ ともに有意でない	10.5
$\ln(\gamma_{i,cum})$ が有意でない場合 (N=30)	$\alpha_i^{(1)}, \alpha_i^{(2)}$ ともに有意である	2.5
	$\alpha_i^{(1)}$ のみ有意である	0.0
	$\alpha_i^{(2)}$ のみ有意である	0.3
	$\alpha_i^{(1)}, \alpha_i^{(2)}$ ともに有意でない	0.2

表 3.7 には、構成パラメータの推定値から、心的負荷の構成パターンの割合を示した。ただし、各購買期間で 1%に満たないと推定されたものは切り捨てて算出している。ここで各構成要素は、心的負荷を構成している期間における累積購買金額の重みを表している。本モデルの設定では、期間 1, 2, 3 は、給料日がそれぞれ 25 日, 5 日, 17 日に相当する。異なる給与支給日からの累積購買金額で心的負荷が構成される場合、世帯に複数の給与所得者が存在すると推察できる。実証分析に基づけば、心的負荷が各期間単独で構成される世帯が全体の 65%を占めており、単独ないしは複数の給与所得者が存在しても同一給料日である世帯がこれに相当すると考えられる。35%近くは心的負荷の構成に複数の累積購買金額が影響している。これらは、例えばパートタイムを含む給料日が異なる共働き世帯の構

<sup>3</sup> $\gamma_{cum,i}$  および  $\alpha_i^{(k)}$  に関しては、推定に当たって変換をしているため、疑似 t-値を用いた頻度論的検定は意味を有さない。ただし、ここではパラメータの推定値がある値の近傍に統計的な散らばりの範囲内で分布している否かを簡便に評価することを狙いとして疑似 t-値を用いた。厳密に評価するには HPD (Highest Posterior Density) リージョンを用いるべきである。

造を反映していると考えられる。

表 3.7: 構造パラメータの割合

心理的財布の構成	割合 (%)	平均構成比率 ( $\alpha_i^{*(1)} : \alpha_i^{*(2)} : \alpha_i^{*(3)}$ )
購買期間 1 のみ	24.8	1.00 : 0.00 : 0.00
購買期間 2 のみ	24.6	0.00 : 1.00 : 0.00
購買期間 3 のみ	16.2	0.00 : 0.00 : 1.00
購買期間 1 と 2	8.4	0.58 : 0.42 : 0.00
購買期間 2 と 3	9.4	0.00 : 0.51 : 0.49
購買期間 3 と 1	9.3	0.52 : 0.00 : 0.48
全ての購買期間	7.3	0.32 : 0.36 : 0.32

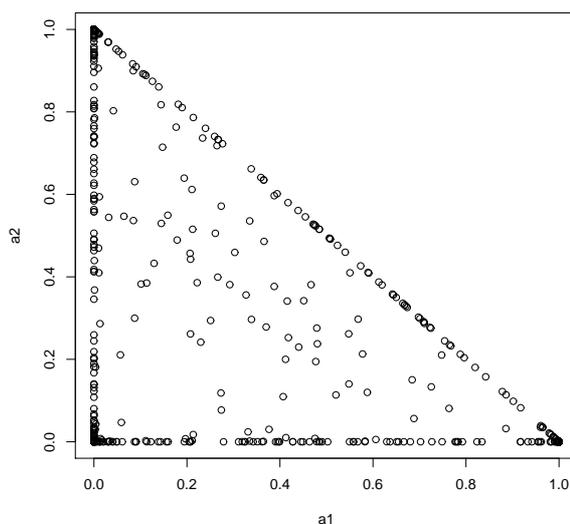


図 3.10: 構造パラメータ ( $\alpha_i^{*(1)}, \alpha_i^{*(2)}$ ) の分布

図 3.11 には、年間購買回数 191 回、年間累積購買金額 51 万円の消費者に対する心的負荷の推定結果を示す。構成パラメータと閾値パラメータは、それぞれ  $\alpha^* = (1.00, 0.00)$ ,  $\gamma_{cum} = 0.224$  と推定され、心的負荷は累積購買集計期間が  $l = 1$  の場合の累積購買金額のみで構成される。このことは、この世帯の所得を得ている者の給料日が 25 日であることを示唆する。一方、図 3.12 には、年間購買回数 175 回、年間累積購買金額 24 万円の消費者

に対する心的負荷の推定結果を示した。構成パラメータ  $\alpha^* = (0.52, 0.48)$ 、閾値パラメータ  $\gamma_{cum} = 0.067$  と推定され、給料日が25日と5日のダブルインカム世帯であることを示唆する。図3.11の例は、単一の購買期間で心的負荷が構成されるため、毎月1回ピークを有する波型の形状であり、レジームの切換が月に2回以下発生する最もシンプルなケースである。一方、図3.12の例は、毎月2回ピークを有する波形であり、閾値パラメータの値によって、レジームの切換が月に最大4回発生する可能性がある。そのため、レジームの切換頻度は、複数の累積購買集計期間から構成される方が頻繁に発生する可能性がある。

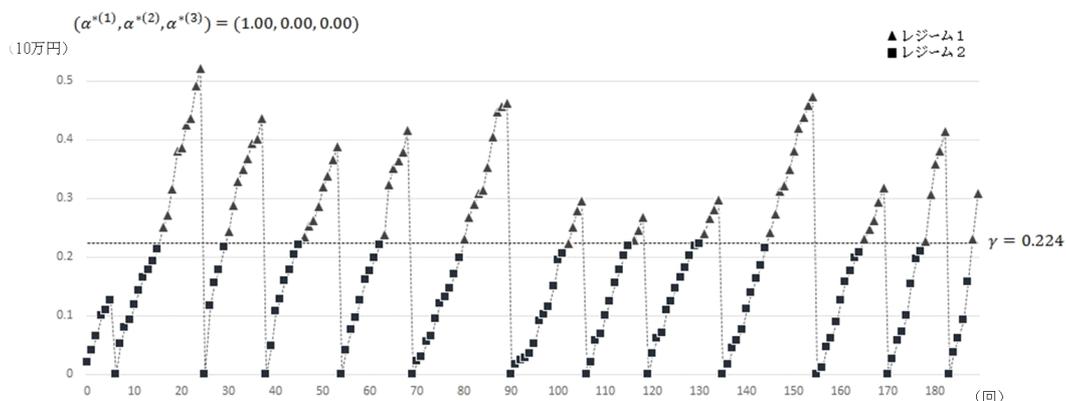


図 3.11: 心理的財布が購買期間 1 のみで構成される

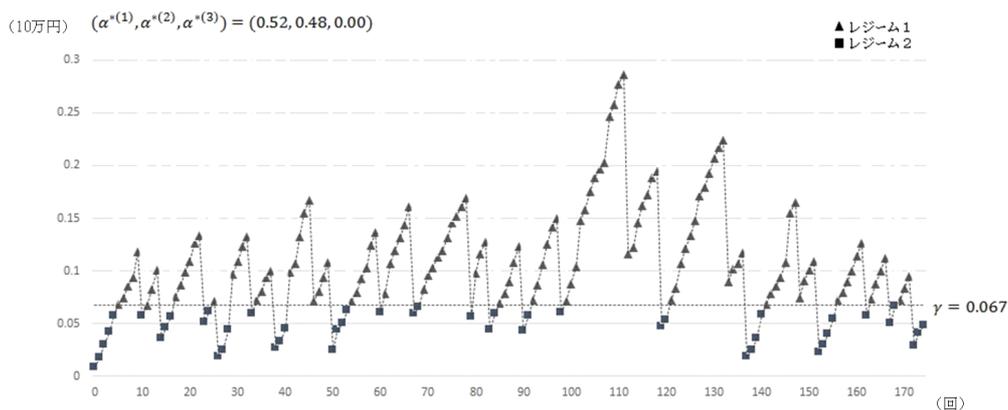


図 3.12: 心理的財布が購買期間 1 と 2 で構成される

### 3.5.6 階層パラメータの検証

本小節では、推定された階層パラメータにもとづき、消費者間の共通性を解釈する。表 3.8 には、階層パラメータの事後平均を示す。また、表中の括弧内に示した数値は疑似 t-値（事後平均/事後標準偏差）である。表中の太字は、その疑似 t-値に基づく 5% 有意と判定されたパラメータである。以降には、有意な推定結果に基づく解釈結果を示す。

累積購買金額が高く、購買頻度の低い消費者の定数項  $\beta_{i,1}^{(k)}$  は大きくなる傾向が見られる。年齢の正の影響は、世帯ライフステージの進展により、家族の人数が増加するために生じている。また、レジーム間で比較すると、女性はレジーム 2 の方がベース購買数量が大きい傾向にある。値引商品の割合  $\beta_{i,2}^{(k)}$  に対する影響は、レジーム 1 では購買頻度の高い消費者ほど値引商品を購入する傾向がうかがえる。購買間隔  $\beta_{i,3}^{(k)}$  に対しては、購買金額で正、購買頻度で負となるレジーム間で共通した傾向があり、その影響度合いはレジーム 2 の方が高い。また、女性はレジーム 1 では、購買間隔の購買点数に対する影響度が小さくなる傾向である。訪問時間ダミー  $\beta_{i,4}^{(k)}, \beta_{i,5}^{(k)}$  に関しても、購買金額で正、購買頻度で負のレジーム間で共通した影響が見られる。また、レジーム 1 では、女性ほど午前中の買物で購買点数を高くする傾向がある。週末ダミー  $\beta_{i,6}^{(k)}$  は、レジーム 2 では、消費者間での共通正は見られないが、レジーム 1 の購買金額では負、購買頻度では正という傾向が表れるのが特徴的である。もともと累積購買金額の高い消費者は週末にまとめ買いする傾向にあり、心的負荷が加重されてくると週末の大量買い傾向を是正して、必要なものを平日に買い足す購買行動に変化することを示唆する。対数変換後閾値パラメータ ( $\ln(\gamma_{cum,i})$ ) は、購買金額で正、購買頻度で負の影響を受けるのは他の係数と同じ符号条件であり、購買金額が増加すると閾値パラメータも大きくなる。ロジット変換前構造パラメータ ( $\alpha_i^{(1)}, \alpha_i^{(2)}$ ) は、全ての消費者属性で有意ではない。

### 3.5.7 給与所得者数と購買行動に関する考察

本小節では、消費者を心的負荷の構成方法によってセグメント化し、各セグメントの購買行動の特徴について考察する。表 3.7 の中、心的負荷が一つの購買期間で構成される消費者セグメント（単一期間セグメント N=656）と複数の購買期間からなる消費者セグメント（複合期間セグメント N=344）を比較する。これらセグメントは、心的負荷が、それぞれ図 3.11 と図 3.12 に示すような変動傾向を示す。単一期間セグメントよりも複合期間セ

表 3.8: 階層モデル係数の事後平均

変数	係数	<i>LAGE</i> $\delta_1$	<i>GNDR</i> $\delta_2$	<i>OPPT</i> $\delta_3$	<i>SPND</i> $\delta_4$
$CNST_i^{(1)}$	$\beta_{i,1}^{(1)}$	<b>0.3176</b> (8.3543)	0.0745 (1.8180)	<b>-0.1697</b> (-4.7660)	<b>0.4496</b> (12.8685)
$CNST_i^{(2)}$	$\beta_{i,1}^{(2)}$	<b>0.3237</b> (8.5880)	<b>0.1584</b> (3.8268)	<b>-0.2027</b> (-3.8268)	<b>0.4861</b> (14.9055)
$DCNT_i^{(1)}$	$\beta_{i,2}^{(1)}$	-0.1658 (-1.1177)	-0.1863 (-1.2051)	<b>0.3198</b> (2.3634)	-0.0817 (-0.6528)
$DCNT_i^{(2)}$	$\beta_{i,2}^{(2)}$	<b>0.3580</b> (2.0886)	-0.0286 (-0.1475)	-0.0195 (-0.1101)	-0.2346 (-1.3742)
$DRTN_i^{(1)}$	$\beta_{i,3}^{(1)}$	0.2177 (1.1615)	<b>-1.0343</b> (-4.8047)	<b>-0.4982</b> (-2.6552)	<b>1.2112</b> (6.5075)
$DRTN_i^{(2)}$	$\beta_{i,3}^{(2)}$	0.2056 (0.9077)	0.1688 (0.6613)	<b>-0.6624</b> (-2.9816)	<b>1.2550</b> (5.9947)
$TIME1_i^{(1)}$	$\beta_{i,4}^{(1)}$	0.0662 (1.4568)	<b>0.1593</b> (3.0995)	<b>-0.1850</b> (-3.7833)	<b>0.2134</b> (4.2063)
$TIME1_i^{(2)}$	$\beta_{i,4}^{(2)}$	-0.0377 (-1.0010)	-0.0401 (-0.9534)	<b>-0.0879</b> (-2.3602)	<b>0.2262</b> (6.4381)
$TIME2_i^{(1)}$	$\beta_{i,5}^{(1)}$	-0.0181 (-0.4667)	<b>0.0866</b> (2.1068)	<b>-0.1169</b> (-3.2627)	<b>0.2116</b> (4.7750)
$TIME2_i^{(2)}$	$\beta_{i,5}^{(2)}$	-0.0010 (-0.0292)	-0.0578 (-1.5425)	-0.0396 (-1.2417)	<b>0.1124</b> (3.7714)
$WKND_i^{(1)}$	$\beta_{i,6}^{(1)}$	-0.0041 (-0.1201)	-0.0502 (-1.2394)	<b>0.1324</b> (4.0119)	<b>-0.1382</b> (-4.1691)
$WKND_i^{(2)}$	$\beta_{i,6}^{(2)}$	-0.0048 (-0.1682)	-0.0353 (-1.0783)	0.0392 (1.4007)	-0.0079 (-0.2906)
対数変換後閾値パラメータ	$\ln(\gamma_{cum,i})$	<b>-0.6087</b> (-8.6145)	-0.1233 (-1.5675)	<b>-0.6870</b> (-10.0341)	<b>1.1152</b> (17.2960)
ロジット変換前構造パラメータ 1	$\alpha_i^{(1)}$	-0.7767 (-0.1410)	-3.3294 (-0.5597)	-0.4673 (-0.0871)	1.7425 (0.3512)
ロジット変換前構造パラメータ 2	$\alpha_i^{(2)}$	1.7786 (0.3371)	-4.9633 (-0.8435)	-2.0568 (-0.3963)	1.2743 (0.2660)

( ) 内数値は擬似 t-値

グメントの方が，変動が複雑である．表 3.9 に各セグメントに属する消費者の属性と閾値パラメータの平均値を示す．表 3.8 に示すように，閾値パラメータは年齢と購買回数で負，購買金額で正の影響を受ける．セグメント間での年齢差はほとんど認められないものの，購買回数と購買金額ではともに複合期間セグメントの方が平均値は大きく，結果として単一期間セグメントの閾値パラメータの方が，複合期間セグメントよりも 5,000 円程度高い．

表 3.9: セグメントごと消費者属性の平均値

消費者セグメント	年齢 (才)	女性比率 (%)	購買回数 (回/年)	購買金額 (万円/年)	閾値パラメータ (10 万円)
単一期間セグメント (N=656)	55.0	83.1	142.7	29.6	0.189
複合期間セグメント (N=344)	55.8	79.4	150.2	31.7	0.137

表 3.10: セグメントごとの事後平均分布の基本統計量

消費者セグメント	統計量	$\beta_{i,1}^{(k)}$	$\beta_{i,2}^{(k)}$	$\beta_{i,3}^{(k)}$	$\beta_{i,4}^{(k)}$	$\beta_{i,5}^{(k)}$	$\beta_{i,6}^{(k)}$
単一期間セグメント (N=656)	平均値	1.9496	0.4597	1.3356	0.1717	0.1126	0.1550
	標準偏差	0.4471	1.6484	2.4518	0.4509	0.3614	0.3627
レジーム 1 (k=1)	平均値	1.9836	0.5520	1.8143	0.1246	0.1197	0.1002
	標準偏差	0.4695	2.1685	3.0886	0.3917	0.3333	0.2866
複合期間セグメント (N=344)	平均値	1.9572	0.5493	1.8316	0.1936	0.1166	0.1232
	標準偏差	0.4694	1.7494	2.6705	0.5051	0.4169	0.3568
レジーム 1 (k=1)	平均値	2.0420	0.5073	1.6391	0.1141	0.1248	0.1544
	標準偏差	0.5057	2.2311	3.0331	0.3991	0.3659	0.3541
レジーム 2 (k=2)	標準偏差						

表 3.10 には，各セグメントに算出した消費者ごと事後平均分布の平均を示した． $\beta_{i,1}^{(1)} < \beta_{i,1}^{(2)}$  の関係は，両セグメントで変わらないものの，複合セグメントの方が係数は若干大きく，潜在的に購買点数が多くなる傾向がうかがえる． $\beta_{i,2}^{(k)}$  については，単一期間セグメントでは  $\beta_{i,2}^{(1)} < \beta_{i,2}^{(2)}$  となり，レジーム 1 では値引商品を購入することのお得感が薄れるが，一方，複合期間セグメントでは，この大小関係は逆転して  $\beta_{i,2}^{(1)} \geq \beta_{i,2}^{(2)}$  となり，レジーム 1 では値引商品に対するインセンティブは逆に高まる． $\beta_{i,3}^{(k)}$  に関して，単一期間セグメントでは  $\beta_{i,3}^{(1)} < \beta_{i,3}^{(2)}$  であるが，複合期間セグメントでは  $\beta_{i,3}^{(1)} > \beta_{i,3}^{(2)}$  と大小関係は逆転する．このことは， $\beta_{i,6}^{(1)}$  と  $\beta_{i,6}^{(2)}$

の大小関係も両セグメントで異なることと関連して、次のように解釈できる。複合期間セグメントは、世帯内に異なる給料日の複数の給与所得者が存在することから、少なくとも基本的には共働き世帯である。そのため、平日は充分に買い物をする時間に乏しく、週末にまとめ買いする傾向になる。心的負荷が加重された状況では、まず週末のまとめ買いを減らし、必要なものを平日に買い足していくような購買行動に変化する。これを反映して、 $\beta_{i,3}^{(1)} > \beta_{i,3}^{(2)}$  かつ  $\beta_{i,6}^{(1)} < \beta_{i,6}^{(2)}$  という関係性が推定されている。一方、単一期間セグメントでは、 $\beta_{i,3}^{(1)} < \beta_{i,3}^{(2)}$  となる。これらのセグメント間の反応傾向の差は、心的負荷の変動の複雑性に関連して生じている。図 3.11 と図 3.12 を比較して分かるように、複合期間セグメントの方がより激しく変動し、心理的財布の切替がより頻繁に生じる。そのため、心的負荷は軽減されやすく、かつ加重されやすい状態にあり、常時心的負荷が変動する状態に晒されている。このような状況において、消費者は近視眼的行動に陥りがちであり、単一期間セグメントとの反応傾向の差が生じる。

### 3.6 まとめ

本研究では、購買時における心理会計の影響によって同一消費者でも購買反応が変化すると仮定し、階層ベイズ閾値ポアソン回帰モデルの枠組みで購買点数生起の発生メカニズムをモデル化した。行動経済学から心理会計の概念を援用し、明示的にモデルへ組み込んだ。実証分析では、スーパーマーケットの ID-POS データを用いて、購買反応が異なるレジムの回帰係数とその切替点を消費者ごとに推定した。心的負荷のモデルは、消費者ごとに3つの代表的な給料日（25日、5日、17日）からの累積購買金額を用いて、それらを重みづけする形式で定式化出来ることを示した。さらに、この重みづけパラメータを用いれば、顧客ごとに未知の給料日を推定できる。一般的な購買モデル構築では、消費者は自身の効用を最大化するために、合理的な購買意思決定を下すと仮定する。しかし、本研究結果が示すとおり、購買意思決定には消費者の心的状況の関与は無視できず、心理会計に代表される消費者に対する心理的影響要因を考慮した購買行動モデルが必要となる。重要なのは、消費者は自身の心的状況にもとづいて購買反応を変化させることであり、実証分析でもこの構造が支持されている。ただし、提案の心的負荷は、3つの給料日の候補からの累積購買金額の重み付き平均をもってモデル化したにすぎず、その理論的サポートは非常に少なく、例えば、世帯ごとの給与所得額や負担割合は当該モデル化では評価できない。そもそも心的負荷とは無関係な富裕層に対して、心的負荷を算出して評価することには限

界がある。よって、推定した構成パラメータの解釈には当然限界があることになる。統計モデルによる心的負荷の一次近似という意味では、提案のモデルが一定の価値を有すると考えているが、上記の観点でモデル化、パラメータの解釈等に本研究では対応しきれなかった課題が残されており、今後の課題と考えている。重要な点なので注記しておく。

本研究に関して、二つの限界が挙げられる。一つ目は、本モデルの購買点数は生鮮食料品を含めた全ての商品を対象としているのに対して、マーケティング変数として重要な値引商品に生鮮食料品が含まれていないことである。そのため、実際に購買される商品の半数は生鮮食料品でありながら、これら商品の値引きの影響はモデルでは考慮していない。ただし、実際のデータでは、購買機会あたりの生鮮食料品とそれ以外商品の購買点数は、概ね正の相関（相関係数は0.6程度）があり、その観点からは現行のモデルでも消費者の購買行動に対しては充分である。二つ目は、本モデルでは購買行動の量的変動のみを扱い、購買商品の単価など、点数以外の異なる側面は考慮されていないことである。心的負荷が軽減されている状態では、加重されている状態と比べて、同じカテゴリーの商品でも単価の高い商品や代替品（例えば、牛肉ではなく鶏肉、ビールではなく発泡酒を購入する場合など）を選択することが想定される。このような変化の影響は提案モデルでは考慮できていない。

本研究では、小売業者視点から消費者の購買点数について分析した。消費者ごとに推定した各レジームの回帰係数と切換点の情報を利用すれば、消費者ごとにカスタマイズしたマーケティング活動を実現し、結果的に小売業のマーケティングを高度化することにつながる。一方で、小売業者にとってもう一つ重要な経営指標である消費者の来店間隔に対しても、同様に心理会計の枠組みで分析する必要がある。これに関しては、第4章以降でモデル構築および実証分析し、心理会計の来店間隔に対する影響メカニズムについて議論する。

## 第4章 心理会計と来店間隔モデリング

### 4.1 はじめに

本章では、心理会計の消費者行動に対する影響メカニズムの関連性を解明するために、消費者の小売店舗における来店間隔をモデル化する。通常、消費財メーカーの立場では、商品やブランドの購買頻度や他商品へのブランドスイッチングを分析することが多い。消費財メーカーにとって、自社の商品やブランドの購買頻度が興味の対象となっているからである。一方、小売業社にとっては、店舗への来店間隔を極小化させ、顧客との接点頻度を高めることが重要な経営指標の一つである。本研究では、心理的要因が来店間隔に与える影響について実証する。心理会計のモデリングフレームワークとしては、第3章で構築した心的負荷モデルを階層ベイズに組合せてモデリングする。

本章は以降において、次の通りに構成する。4.2節では、本章に関連する先行研究のレビュー結果を示す。4.3節には本研究の提案モデルを、4.4節にはモデル推定のアルゴリズムを、4.5節では本提案モデルにもとづく実証分析を示す。4.6節は本研究のまとめである。

### 4.2 先行研究

購買レジームが切換ると、回帰構造に用いられる変数も異質となるのはごく自然な考え方で、消費者レベルで有意な変数が異なることもある。これは、変数選択の問題として、マーケティング領域で議論されている。George and McCulloch (1993) は、有意でない変数に対しては通常よりも大きな分散を有すると仮定した階層ベイズの手法により、消費者レベルでの変数選択の問題を推定している。この手法を用いて、山田・佐藤 (2016) は百貨店顧客の来店回数生起メカニズムの構造異質性を解析し、消費者レベルでの変数選択問題を推定している。レジームに対する変数選択を推定するのではなく、変数とその構造を与件としてモデル化するアプローチは、構造化モデリングと呼ばれる。Terui and Ban (2008) は、マーケティングにおける広告ストックの効果は、投下量が充分でない場合は効かず、ある

閾値を超えると影響を与えるようになるとの仮定の下、消費者の広告ストックに対する購買反応をモデル化した。宮津・佐藤(2015)は、給料日からの累積購買金額を心的負荷としてモデル化し、心理的影響要因を考慮した購買点数モデル(第3章)を構築した。本研究でも、このモデルアプローチを採用し、心的影響要因による消費者の来店間隔に対する影響を推定する。本章では、心的負荷がある閾値を超えると、それ自体が来店間隔に影響を与えるという仮定の下、来店間隔に対する心的負荷の直接効果についても検証する。

## 4.3 モデル

本節では本件研究における提案モデルを示す。消費者の小売店への来店間隔は、店頭でのプロモーション活動や購買習慣などの影響を受ける。それに加えて、家計の収支バランスからの圧力も来店間隔に影響する。伝統的経済学では、消費者は効用最大化のために合理的な行動を取ることを前提とするが、行動経済学では、心理会計という概念で心的状況が消費者行動に影響することを説明する。心理会計の下では、同じ価値を有する財でも、消費者の置かれた心的状況によって異なる意思決定を下すというものである。すなわち、同じ消費者でも状況に依存して、異質な来店レジームが存在することを意味する。消費者がどのような心的状況に置かれているかは潜在的なものであり、消費者ごとに異なる。本研究では、消費者ごとの来店行動における心的状況を表す潜在変数として、給料日を起点とした消費者の累積購買金額である心的負荷を用いる。本提案モデルでは、3.3.1節で提案した心的負荷のフレームワークを消費者ごとの来店間隔に適用する。各レジームの確率分布には、対数正規分布を用い、位置パラメータに回帰構造を仮定してモデル化する。また、消費者ごとでも構造が異なることを考慮し、これらメカニズムを表すために階層モデルにより消費者間の共通性を取り込む。以下、4.3.1節、4.3.2節、および4.3.3節には、それぞれ心的影響要因モデル、個体内モデル、および個体間モデルを示す。

### 4.3.1 心的影響要因モデル(心理会計モデル)

本節では本研究における提案モデルを示す。本来店間隔モデルでは、心的負荷が逼迫した状況の来店レジームのみに、消費者の心的負荷をモデル変数として加え、その直接効果もあわせて推定する。

■ 収支バランスの圧力モデル（心的負荷モデル）

心的負荷モデルには、3.3.1 節で示したモデルを再掲する。給料日は特定できないので、その前提で心的負荷をモデル化する。具体的には、代表的な給料日である毎月 25 日、5 日、17 日を前提とし、(4.1) 式には、それぞれに対応した累積購買集計期間の記号を導入する。

$$\text{累積購買集計期間} \begin{cases} l=1 \Rightarrow \text{前月 25 日から今月 24 日まで} \\ l=2 \Rightarrow \text{前月 5 日から今月 4 日まで} \\ l=3 \Rightarrow \text{前月 17 日から今月 16 日まで} \end{cases} \quad (4.1)$$

(4.2) 式は、消費者  $i$  の集計対象期間  $l$  における購買機会  $t_i$  までの累積購買金額を示す。

$$\text{cum}_{i,t_i,l} = \begin{cases} \sum_{j=1}^{\text{trans}^l(t_i)-1} M_{i,j,l} & \text{tran}^l(t_i) \neq 1 \\ 0 & \text{tran}^l(t_i) = 1 \end{cases} \quad (4.2)$$

ここで、 $t_i$  は各消費者で異なり、期間中の来店回数も全消費者で同一ではない。 $\text{trans}^l(t_i)$  は、消費者  $i$  の集計対象期間  $l$  における集計起点日から  $t_i$  までの来店回数であり、 $M_{i,j,l}$  は、消費者  $i$  の集計期間  $l$  内の購買機会  $j$  における購買金額である。例えば、給料日 25 日の場合、消費者  $i$  の当該期間中  $n$  回目の購買機会  $t_i$  を明示的に  $t_{i,n}$  とするとき、毎月 25 日以降の初回購買機会においては  $\text{cum}_{i,t_{i,1},1} = 0$  である。2 回目の購買機会では、初回購買機会での購買金額を用いて  $\text{cum}_{i,t_{i,2},1} = M_{i,1,1}$  となり、3 回目では 2 回目の購買金額  $M_{i,2,1}$  が加算されて  $\text{cum}_{i,t_{i,3},1} = M_{i,1,1} + M_{i,2,1}$  となる。 $n$  回目の購買機会は、同様に  $\text{cum}_{i,t_{i,n},1} = M_{i,1,1} + M_{i,2,1} + \dots + M_{i,n-1,1}$  である。次月 25 日以降は上記を繰り返して  $\text{cum}_{i,t_{i,n},1}$  が生成される。(4.3) 式が、本研究における心的負荷のモデルである。 $\alpha_i^{*(k)}$  ( $k = 1, 2, 3$ ) は  $0 \leq \alpha_i^{*(k)} \leq 1$  および  $\sum_{k=1}^3 \alpha_i^{*(k)} = 1$  の制約を満たすパラメータであり、 $\alpha_i^* = (\alpha_i^{*(1)}, \alpha_i^{*(2)})$  とする。例えば、 $\alpha_i^{*(1)} = 1$  となる場合はシングルインカム（給料日 25 日）、 $\alpha_i^{*(1)} = \alpha_i^{*(2)} = 0.5$  はダブルインカム（給料日 25 日と 5 日）に対応しており、世帯における様々な家計の状況を表現できる。それぞれの例を図 4.1 に示す。ここで世帯とは、消費者が属する世帯を指し、本研究で消費者というとき、世帯の給与所得者を意味する。また、本モデルにおける  $\alpha_i^* = (\alpha_i^{*(1)}, \alpha_i^{*(2)})$  を推定することで、通常は知り得ない、各世帯の給料日推定も可能となる。このように、消費者の心的負荷を、給料日からの累積購買金額で (4.3) 式のようにモデル化することで、 $\text{Cummm}M_{i,t_i}$  が小さければ心的負荷が低い状態を、その値が大きくなれば心的負荷が高い状態を表現する。3.3.1 節で解説した通り、 $\alpha_i^{*(k)}$  ( $k = 1, 2, 3$ ) は、購買金額 ( $M_{i,t,l}$ ) に対する給料日ごとの心理的負担割合

の比率であり、消費者世帯ごとに異質である。

$$CummM_{i,t_i} = \alpha_i^{*(1)} cum_{i,t_i,1} + \alpha_i^{*(2)} cum_{i,t_i,2} + \alpha_i^{*(3)} cum_{i,t_i,3} \quad (4.3)$$

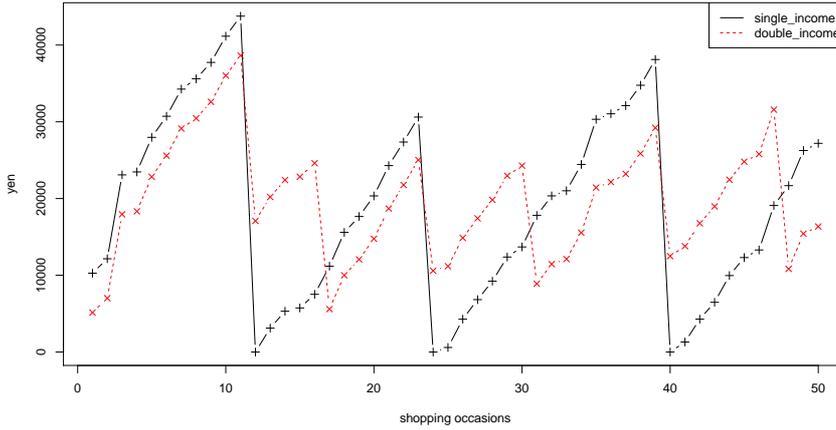


図 4.1: 心的影響要因（シングルインカムとダブルインカムの例）

### 4.3.2 個体内モデル（観測モデル）

本小節には、提案モデルの個体内モデルである閾値来店間隔モデルを示す。消費者  $i$  による購買時点  $t_{i,n_{i-1}}$  から  $t_{i,n_i}$  までの時間間隔  $y_{i,t_i} = \Delta d_{i,t_i}$  を、消費者  $i$  に対する購買時点  $t_i$  に対する購買間隔とする。本研究では、(4.3) 式で示した消費者ごとの潜在変数である心的負荷と閾値パラメータ  $\gamma_{cum,i}$  の大小関係により、2つの来店間隔  $Y_{i,t_i}$  の生起メカニズムが切換ると仮定してモデル化する。各レジームの評価関数<sup>1</sup>は異なり、両レジームには確率分布に対数正規分布を仮定して定式化する。(4.4) 式が、消費者  $i$  の時点  $t_i$  における心的影響要因を考慮した来店間隔の個体内モデルである。本研究は、目的変数は来店間隔と異なるが、心的負荷による閾値モデルの構成は 3.3.2 節と同様である。

$$Pr(Y_{i,t_i} = y_{i,t_i} | \mu_{i,t_i}^{(1)}, \mu_{i,t_i}^{(2)}, \sigma_i^{2(1)}, \sigma_i^{2(2)}, \gamma_{cum,i}, \alpha_i, cum_{i,t_i}) \quad (4.4)$$

<sup>1</sup>心理会計は、プロスペクト理論を根拠とした概念であり、プロスペクト理論の参照点为本モデルの閾値に相当し、その前後で2つの異なる購買レジームを有するという考え方を踏襲する。

$$= \begin{cases} \frac{1}{\sqrt{2\pi}\sigma_i^{(1)} y_{i,t_i}} \exp\left(\frac{-1}{2\pi\sigma_i^{2(1)}} \{\ln(y_{i,t_i}) - \mu_{i,t_i}^{(1)}\}^2\right), CummmM_{i,t_i} \geq \gamma_{cum,i} \text{ (レジーム 1)} \\ \frac{1}{\sqrt{2\pi}\sigma_i^{(2)} y_{i,t_i}} \exp\left(\frac{-1}{2\pi\sigma_i^{2(2)}} \{\ln(y_{i,t_i}) - \mu_{i,t_i}^{(2)}\}^2\right), CummmM_{i,t_i} < \gamma_{cum,i} \text{ (レジーム 2)} \end{cases}$$

本研究では、位置パラメータ  $\mu_i^{(k)}, k = 1, 2$  に説明変数  $\mathbf{x}_{i,t_i}$  と各レジームの回帰係数  $\beta_i^{(k)}, k = 1, 2$  に回帰変換  $\mu_{i,t_i}^{(k)} = \mathbf{x}_{i,t_i}^t \beta_i^{(k)}, k = 1, 2$  による構造化を仮定する。(なお、構造化に関する詳細は付録 B.1 を参照。) 3.3.2 節と同様、 $\beta_i^{(k)}$  は消費者  $i$  に固有な係数であるのに対して、 $\mathbf{x}_{i,t_i}$  は購買時点に依存するため、 $\mu_{i,t_i}^{(k)}$  も購買時点によって異なる。

次に、消費者の各購買機会が、どちらのレジームに振り分けられたかの集合を示す記号  $R^{(k)} (k = 1, 2)$  を導入する。ここで  $k$  は、 $CummmM_{i,t_i}$  と  $\gamma_{cum,i}$  の大小関係により、(4.4) 式のレジームの番号に対応して割り当てられる。また、消費者  $i$  の総購買機会数  $N_i$  に対応する時点  $t_{i,N_i}$  を  $T_i$  とするとき、(4.5) 式が消費者  $i$  の全購買機会  $\mathbf{y}_i = (y_{i,t_{i,1}}, y_{i,t_{i,2}}, \dots, y_{i,T_i})^t$  に対する来店間隔の尤度関数となる。

$$p(\mathbf{y}_i | \mathbf{x}_i, \beta_i^{(1)}, \beta_i^{(2)}, \sigma_i^{2(1)}, \sigma_i^{2(2)}, \gamma_{cum,i}, \mathbf{cum}_i, \alpha_i) \\ = \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} f_k(y_{i,t_i} | \mathbf{x}_{i,t_i}, \beta_i^{(1)}, \beta_i^{(2)}, \sigma_i^{2(1)}, \sigma_i^{2(2)}, \gamma_{cum,i}, \mathbf{cum}_{i,t_i}, \alpha_i^*) \right\} \quad (4.5)$$

消費者同士が独立であると仮定すると、全消費者 ( $i = 1, 2, \dots, H$ ) に対する全体尤度は (4.6) 式の通りである。なお、具体的なモデル変数 ( $\mathbf{x}_{i,t_i}$ ) に関する説明は、表 4.1 に後述する。

$$p(\{\mathbf{y}_i\} | \{\beta_i^{(1)}\}, \{\beta_i^{(2)}\}, \{\sigma_i^{2(1)}\}, \{\sigma_i^{2(2)}\}, \{\gamma_{cum,i}\}, \{\mathbf{cum}_i\}, \{\alpha_i\}, \{\mathbf{x}_i\}) \quad (4.6) \\ = \prod_{i=1}^H \left\{ \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} \frac{1}{\sqrt{2\pi}\sigma_i^{(k)} y_{i,t_i}} \exp\left(\frac{-1}{2\pi\sigma_i^{2(k)}} \{\ln(y_{i,t_i}) - \mathbf{x}_{i,t_i}^t \beta_i^{(k)}\}^2\right) \right\} \right\}$$

### 4.3.3 個体間モデル (階層モデル)

本小節では、消費者ごとの異質なパラメータの背後に共通性構造を仮定した階層モデルを説明する。消費者  $i$  に固有なパラメータベクトル  $\beta_i^{(1)}, \beta_i^{(2)}$  および閾値パラメータ  $\gamma_{cum,i}$  の対数値をあわせて、 $\phi_i = (\beta_i^{(1)}, \beta_i^{(2)}, \ln(\gamma_{cum,i}))$  を定義する。階層モデルのパラメータ構成において、各レジームの分散パラメータ  $\sigma_i^{2(1)}$  と  $\sigma_i^{2(2)}$  は階層モデルに含まれていない。その理由は、推定アルゴリズムに起因し、確率分布に対数正規分布を仮定することで、目的変数である来店間隔の対数値が正規分布に従い、分散パラメータ  $\sigma_i^{2(1)}, \sigma_i^{2(2)}$  は逆ガンマ分布か

らの完全条件付ギブスサンプリングが可能となるためである。(推定アルゴリズムの詳細は付録 B.1 参照。) また, 心的負荷モデルの構成パラメータ  $\alpha_i^*$  のロジット変換前のパラメータベクトルを  $\alpha_i = (\alpha_i^{(1)}, \alpha_i^{(2)})$  と定義する. つまり,  $\alpha_i$  は,  $\alpha_i^{*(k)} = \frac{\exp(\alpha_i^{(k)})}{1 + \sum_{l=1}^2 \exp(\alpha_i^{(l)})}, k = 1, 2$  の逆変換として表せる. このとき, (4.7) 式, (4.8) 式が, 消費者  $i$  の階層モデルとなる. なお, 具体的な属性変数 ( $z_i$ ) に関する説明は, 表 4.1 に後述する.

$$\phi_i = z_i^t \Delta_\phi + \epsilon_i^\phi, \epsilon_i^\phi \sim \mathcal{MVN}(\mathbf{0}, \Sigma_\phi) \quad (4.7)$$

$$\alpha_i = z_i^t \Delta_\alpha + \epsilon_i^\alpha, \epsilon_i^\alpha \sim \mathcal{MVN}(\mathbf{0}, \Sigma_\alpha) \quad (4.8)$$

$\phi_i, \alpha_i$  は, 消費者  $i$  の属性変数  $z_i = (z_{i,1}, z_{i,2}, \dots, z_{i,q})^t$  と係数行列  $\Delta_\phi, \Delta_\alpha$  の線形結合で表し,  $q$  は属性変数の次元,  $\Sigma_\phi, \Sigma_\alpha$  は, それぞれの分散共分散行列である. なお,  $\Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  の事前分布は, (4.9) 式, (4.10) 式のように設定する. 事前分布の設定にあたっては,  $p(\Delta_\phi, \Sigma_\phi) = p(\Delta_\phi | \Sigma_\phi) p(\Sigma_\phi), p(\Delta_\alpha, \Sigma_\alpha) = p(\Delta_\alpha | \Sigma_\alpha) p(\Sigma_\alpha)$  の関係式を用い,  $p(\Delta_\phi | \Sigma_\phi), p(\Delta_\alpha | \Sigma_\alpha)$  は多変量正規分布,  $p(\Sigma_\phi), p(\Sigma_\alpha)$  は逆ウィッシュヤート分布を仮定する. (実証データによる推定で設定した事前分布については付録 B.2 を参照.)

$$\begin{aligned} \delta_\phi &= \text{vec}(\Delta_\phi) \sim \mathcal{MVN}(\bar{\delta}_\phi, \Sigma_\phi \otimes A_\phi^{-1}) \\ \Sigma_\phi &\sim \mathcal{IW}(v_{\phi,0}, V_{\phi,0}) \end{aligned} \quad (4.9)$$

$$\begin{aligned} \delta_\alpha &= \text{vec}(\Delta_\alpha) \sim \mathcal{MVN}(\bar{\delta}_\alpha, \Sigma_\alpha \otimes A_\alpha^{-1}) \\ \Sigma_\alpha &\sim \mathcal{IW}(v_{\alpha,0}, V_{\alpha,0}) \end{aligned} \quad (4.10)$$

## 4.4 アルゴリズム

### 4.4.1 事後分布

本小節には, 提案モデルの推定アルゴリズムの基となる事後分布を提示する. 図 4.2 は消費者  $i$  の購買時点  $t_{i,t}$  における, 本提案モデルから導出される有向非巡回グラフ (DAG : Directed Acyclic Graph) である. 図 4.2 に示す DAG に基づき, 消費者間の独立性を仮定すると, (4.11) 式の事後分布を導出できる.

$$\begin{aligned} p(\Phi, \Omega^{(1)}, \Omega^{(2)}, \mathcal{A} | \mathbf{Y}, \mathbf{X}, \mathbf{Z}, \mathbf{Cum}) &\propto p(\Delta_\phi | \Sigma_\phi) p(\Sigma_\phi) p(\Delta_\alpha | \Sigma_\alpha) p(\Sigma_\alpha) \\ &\times \prod_{i=1}^H p(\mathbf{y}_i | \phi_i, \sigma_i^{(1)}, \sigma_i^{(2)}, \alpha_i, \mathbf{x}_i, \mathbf{cum}_i) p(\phi_i | \Delta_\phi, \Sigma_\phi, z_i) p(\alpha_i | \Delta_\alpha, \Sigma_\alpha, z_i) \end{aligned} \quad (4.11)$$

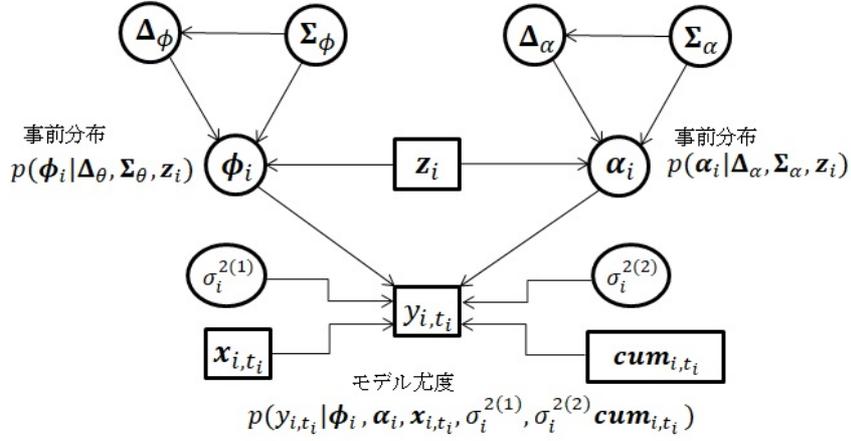


図 4.2: 提案モデルの有向非巡回グラフ

ただし、 $\Phi \equiv \{\phi_i\} = (\phi_1, \phi_2, \dots, \phi_H)$ ,  $\Omega^{(1)} \equiv \{(\sigma_i^{2(1)}) = \sigma_1^{2(1)}, \sigma_2^{2(1)}, \dots, \sigma_H^{2(1)}\}$ ,  
 $\Omega^{(2)} \equiv \{(\sigma_i^{2(2)}) = \sigma_1^{2(2)}, \sigma_2^{2(2)}, \dots, \sigma_H^{2(2)}\}$ ,  $\mathcal{A} \equiv \{\alpha_i\} = (\alpha_1, \alpha_2, \dots, \alpha_H)$ ,  
 $Z \equiv \{z_i\} = (z_1, z_2, \dots, z_H)$ ,  $X \equiv \{x_i\} = (x_1, x_2, \dots, x_H)$ ,  $Y \equiv \{y_i\} = (y_1, y_2, \dots, y_H)$ ,  
 $Cum \equiv \{cum_i\} = (cum_1, cum_2, \dots, cum_H)$  である。

#### 4.4.2 カーネル

前節の事後分布に示した提案モデルには、 $\Phi, \mathcal{A}, \Omega^{(1)}, \Omega^{(2)}, \Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  が含まれる。 $\Phi, \mathcal{A}, \Omega^{(1)}, \Omega^{(2)}$  は消費者ごとに異なるパラメータであり、 $\Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  は消費者間で共通のパラメータである。これらパラメータの推定には、マルコフ連鎖モンテカルロ法 (MCMC: Markov chain Monte Carlo method) を用いる。推定アルゴリズムは、(4.11) 式に基づき構成する。すなわち、 $\Phi, \mathcal{A}$  は非共役なため、そのサンプリングにはランダムウォークメトロポリス・ヘイスティングス (ランダムウォーク M-H) 法を用いる。一方、階層パラメータ  $\Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  は 4.3.3 節に示した通り共役になるため、標準的なギブスサンプラーを用いてサンプリングする。本モデルでは、確率密度に対数正規分布を仮定することで、観測値である来店間隔の対数値は正規分布に従うため、 $\sigma_i^{2(1)}$  と  $\sigma_i^{2(2)}$  は逆ガンマ分布からのギブスサンプリングとなることに注意する。消費者  $i$  ごとの  $\phi_i$  と  $\alpha_i$  のサンプリングには、ランダムウォーク M-H 法を用いるが、事後分布からのサンプル候補値を生成するためのカーネルを (4.12) 式と (4.13) 式に示す。

全ての消費者に対して共通なパラメータである  $\Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  および  $\alpha_i$  を所与として、ランダムウォークサンプラーから生成した  $\phi_i$  を (5.13) 式に示す事後分布カーネルを用いて評価し、採択／棄却を確率的に決定する。

$$\begin{aligned}
& p(\mathbf{y}_i | \phi_i, \sigma_i^{2(1)}, \sigma_i^{2(2)}, \alpha_i, \mathbf{x}_i) p(\phi_i | \Delta_\phi, \Sigma_\phi, \mathbf{z}_i) \\
& \propto \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}} \frac{1}{\sqrt{2\pi}\sigma_i^{(k)} y_{i,t_i}} \exp\left(\frac{-1}{2\pi\sigma_i^{2(k)}} \{\ln(y_{i,t_i}) - \mathbf{x}_{i,t_i}^t \beta_i^{(k)}\}^2\right) \right\} \\
& \quad \times \exp\left\{-\frac{1}{2}(\phi_i - \mathbf{z}_i^t \Delta_\phi)^t \Sigma_\phi^{-1} (\phi_i - \mathbf{z}_i^t \Delta_\phi)\right\} \quad (4.12)
\end{aligned}$$

同様に、 $\alpha_i$  に対しては、 $\Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  および  $\phi_i$  を所与として、ランダムウォークサンプラーから生成した  $\alpha_i$  を (4.13) 式に示す事後分布カーネルを用いて評価し、採択／棄却を確率的に決定する。

$$\begin{aligned}
& p(\mathbf{y}_i | \phi_i, \alpha_i, \mathbf{x}_i) p(\alpha_i | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i) \\
& \propto \prod_{k=1}^2 \left\{ \prod_{t_i \in R^{(k)}} \frac{1}{\sqrt{2\pi}\sigma_i^{(k)} y_{i,t_i}} \exp\left(\frac{-1}{2\pi\sigma_i^{2(k)}} \{\ln(y_{i,t_i}) - \mathbf{x}_{i,t_i}^t \beta_i^{(k)}\}^2\right) \right\} \\
& \quad \times \exp\left\{-\frac{1}{2}(\alpha_i - \mathbf{z}_i^t \Delta_\alpha)^t \Sigma_\alpha^{-1} (\alpha_i - \mathbf{z}_i^t \Delta_\alpha)\right\} \quad (4.13)
\end{aligned}$$

推定アルゴリズムの詳細および階層パラメータを含めた初期値については、付録 B.2 に示す。また、推定用のサンプルプログラムを付録 B.3 に示す。

## 4.5 実証分析

### 4.5.1 分析データ

本研究では、都内にあるスーパーマーケットの ID-POS データを用いて実証分析を行う。2001 年 1 月 1 日から 2001 年 12 月 31 日までの期間中、欠損データのない消費者 1,325 世帯のうち、50 回以上かつ毎月 1 回以上の購買履歴のある消費者 100 人をランダムに抽出した。表 4.1 に本実証分析で採用する変数を示す。ここで、(4.3) 式で示した潜在変数である心的負荷 ( $CummM_{i,t_i}$ ) を説明変数として採用し、心的要因の直接効果も推定する。この心的負荷の直接効果は、本章における来店間隔モデルのみに採用し、第 3 章および第 5 章のモデルでは採用していない。

表 4.1: モデル変数

変数	記号	説明	平均値	標準偏差
$y_{i,t_i}$	$DRTN_{i,t_i}$	購買間隔 (被説明変数)	2.02	1.98
$x_{i,t_i}$	$CNST_{i,t_i}$	定数: 1	1.00	0.00
	$PURCH_{i,t_i}$	前回購買機会の購買点数	14.30	8.16
	$ITEMR_{i,t_i}$	前回購買商品の日雑品・加工食品比率	0.66	0.21
	$DSCNT_{i,t_i}$	日雑品・加工食品の店舗全体割引率	0.16	0.12
	$INSTM_{i,t_i}$	チラシの掲載商品点数の平方根	6.10	4.58
	$CummM_{i,t_i}$	$CummM_{i,t_i} = \alpha_i^{*(1)} cum_{i,t_i,1} + \alpha_i^{*(2)} cum_{i,t_i,2} + \alpha_i^{*(3)} cum_{i,t_i,3}$ (4.3) 式の潜在変数, 逐次推定値を用いる 入力時は, $\ln(CummM_{i,t_i}/1000 + 0.001)$ に変数変換	-	-
	$z_i$	$LPAID_i$	平均購買金額/1000 の対数値	0.43
$WORK1_i$		就業形態ダミー (家事専業=1, それ以外=0)	0.30	0.46
$WORK2_i$		就業形態ダミー (パート=1, それ以外=0)	0.55	0.50
$WORK3_i$		就業形態ダミー (フルタイム=1, それ以外=0)	0.11	0.31
$FOOT_i$		来店手段 (徒歩=1, それ以外=0)	0.61	0.49

本モデルでは、購買対象商品やカテゴリーを特に指定せず、消費者ごとに購買が発生した来店間隔を目的変数として用いる。そのため、店舗全体の特性を表す変数として、チラシや値引などのプロモーションに関わる変数は特定の商品やカテゴリーに偏ることのないように選択する必要がある。当該スーパーマーケットで販売されている商品は、食料品と日用雑貨品に大別され、さらに食料品は生鮮食料品と加工食品などの非生鮮食料品に分けられる。生鮮食料品は、市場でその都度仕入れられるために定価がなく、値引率を算出することができない。そのため、本モデルで採用する平均割引率は日用雑貨品と加工食品に限定され、店舗全体での平均割引率は16%である。また、チラシに掲載された商品点数の平方根は、一日当たり平均6.10と比較的多い。スーパーマーケットのチラシは、一枚の紙面に商品の写真と値段を数多く掲載するカタログ形式のものが一般的であり、小売業における主要なプロモーション施策の一つである。本モデルには、マーケティング活動を表す指標として、これら値引とチラシに関する変数を用いる。消費者の来店間隔には、直近の購買点数および購買品目にも大きく依存する。生鮮食料品は消費期限が短く、一度の購買量にも限度がある一方、日用雑貨品や加工食品は長期間保存できるため、まとめ買いが可能である。本モデル変数の購買機会当たりの購買点数は14.3点であり、その内66%が日用

雑貨品と加工食品が占める。階層モデルを構成する消費者ごとの属性変数は、購買機会あたりの平均購買金額（千円）の対数値、就業形態、および来店手段ダミーを採用する。モデル期間前のホールドアウトサンプルから算出した全消費者の購買機会あたりの平均購買金額は 1,537 円であり、61%の消費者が店舗から徒歩圏内に居住している。就業形態では、フルタイムの消費者が比較的少ない。しかしながら、実際の消費性向は世帯所得に依存するため、消費者属性の就業形態と一致するとは限らず、本モデルの推定値を解釈する際には注意が必要である。

#### 4.5.2 モデル評価

本実証分析では、MCMC の総繰り返し回数 50,000 回、バーンインサンプルを 45,000 回とし、消費者あたり 5,000 サンプルを用いて算出した対数周辺尤度および DIC の比較によりモデルを評価する。本モデルの評価として、来店レジームを仮定しないモデル（基本モデル）、潜在変数である心的負荷をレジーム 1 に含めず、レジーム 1 と 2 で同一の説明変数を用いるモデル（対称モデル）、レジーム 1 のみに心的負荷を追加したモデル（非対称モデル 1）、およびレジーム 2 のみに心的負荷を追加したモデル（非対称モデル 2）に対して、DIC (Deviance Information Criterion) および対数周辺尤度を比較した。この結果から、レジーム 1 に潜在変数である心的負荷を取り込んで構造化モデリングされた非対称モデル 1 が採択される。以降の分析では、非対称モデル 1 の推定結果に基づいて議論する。

表 4.2: DIC および対数周辺尤度によるモデル評価

	基本モデル	対称モデル	非対称モデル 1	非対称モデル 2
DIC	52,152.26	44,374.50	39,813.53	39,981.00
対数周辺尤度	-24,529.15	-22,845.47	-19,822.21	-19,837.00

#### 4.5.3 回帰パラメータの検証

消費者ごとに推定した回帰パラメータの事後平均分布<sup>2</sup>の基本統計量と疑似 t-値（事後平均/事後標準偏差）で評価した各パラメータの 5%有意である消費者の割合を表 4.3 に示す。

<sup>2</sup>事後分布にもとづく消費者ごとの平均値の分布を、ここでは事後平均分布と呼ぶ。

階層ベイズの枠組みで推定した回帰パラメータは、消費者ごとの反応係数として推定されるが、本検証では、全消費者の分布である表 4.3 の推定値に基づいて議論する。なお、消費者別に対しても同様の検証が可能である。まずは、来店間隔のベースとなる対数正規分布における位置パラメータ  $\mu_i^{(k)}$  の定数項  $\beta_{i,1}^{(1)}$  であるが、説明変数からの影響が全て一定である場合、 $\beta_{i,1}^{(1)} > \beta_{i,1}^{(2)}$  となり、相対的に心的負荷が軽減されているレジーム 2 の方が来店間隔は短くなる。しかしながら、本モデルで採用した心的負荷の直接効果の影響は、 $\beta_{i,6}^{(1)}$  の符号が負であることから分かるように、心的負荷が高まるに連れて来店間隔を縮退させ、全体的な来店間隔は短くなる。 $\beta_{i,2}^{(k)}$  について、心的負荷が逼迫したレジーム 1 では、前回購買点数に対する反応が負であり、来店間隔を縮小する傾向を示す。これは、 $\beta_{i,3}^{(1)} < \beta_{i,3}^{(2)}$  が示すように、心的負荷が高まると購買品目における生鮮食品の割合の影響も小さくなる傾向にあることと関連する。また、値引きに関しては  $\beta_{i,4}^{(1)} < \beta_{i,4}^{(2)}$  と、レジーム 1 の方が来店間隔は短くなる傾向を示す。チラシに関する影響度合いであるが、心的負荷が緩慢なレジーム 2 では負であり、チラシでの掲載点数が多いほど来店間隔は短くなるように作用する。レジーム 1 では正となり、チラシにおける商品の掲載点数は来店に効きにくくなる。全体的に、心的負荷が逼迫した状況では、必要なものを必要な時に購買する傾向となることを示唆する。つまり、消費者の計画購買度合いが増し、マーケティング施策は効きにくくなることを示唆する。ここで論じた回帰パラメータ特性は、消費者異質性を包含しており、消費者世帯の特性にもとづく各種セグメント化した世帯ごとにも異なり、4.5.8 節で詳細を議論する。

#### 4.5.4 閾値パラメータの検証

消費者ごとに推定した心的負荷閾値 ( $\gamma_{cum,i}$ ) の事後平均分布の基本統計量と疑似 t-値 (事後平均/事後標準偏差) から算出した 5%有意<sup>3</sup>な推定値の割合を表 4.3 に示す。また、心的負荷閾値 ( $\gamma_{cum,i}$ ) の事後平均の度数分布を図 4.3 に示す。心的負荷閾値の事後平均の平均値は 11,649 円であり、消費者の一か月あたりの平均累積購買金額が 42,597 円であることから、来店行動に対して月間購買金額の 27%を超えるあたりで心的状況が逼迫した状態へ移行する。また、心的負荷閾値 ( $\gamma_{cum,i}$ ) と心的負荷による直接効果 ( $\beta_{i,6}^{(1)}$ ) の関連性を理解する

<sup>3</sup> $\gamma_{cum,i}$  および  $\alpha_i^{(k)}$  に関しては、推定に当たって変換をしているため、疑似 t-値を用いた頻度論的検定は意味を有さない。ただし、ここではパラメータの推定値がある値の近傍に統計的な散らばりの範囲内で分布している否かを簡便に評価することを狙いとして疑似 t-値を用いた。厳密に評価するには HPD (Highest Posterior Density) リージョンを用いるべきである。

表 4.3: 事後平均分布の基本統計量

係数	平均値	中央値	最小値	最大値	標準偏差	有意割合*
$\beta_{i,1}^{(1)}$	0.4052	0.3900	-0.7397	1.4549	0.3760	82%
$\beta_{i,2}^{(1)}$	-0.0068	0.0036	-0.5043	0.1586	0.0789	22%
$\beta_{i,3}^{(1)}$	0.1499	0.1351	-0.8320	0.6743	0.2381	65%
$\beta_{i,4}^{(1)}$	0.0577	0.0509	-0.7608	1.4232	0.4127	70%
$\beta_{i,5}^{(1)}$	0.0142	0.0007	-0.2914	0.9730	0.1101	19%
$\beta_{i,6}^{(1)}$	-0.0453	-0.0598	-0.3933	0.6258	0.1554	66%
$\beta_{i,1}^{(2)}$	0.3724	0.3298	-0.6494	1.5750	0.4618	84%
$\beta_{i,2}^{(2)}$	0.0502	0.0248	-0.3706	0.8450	0.1500	39%
$\beta_{i,3}^{(2)}$	0.2434	0.2416	-1.2171	1.1805	0.4380	76%
$\beta_{i,4}^{(2)}$	0.1151	0.1983	-0.9531	1.0491	0.4491	81%
$\beta_{i,5}^{(2)}$	-0.0166	0.0012	-0.5850	0.5322	0.1557	31%
$\sigma_i^{2(1)}$	0.5962	0.5631	0.2455	1.0129	0.2160	81%
$\sigma_i^{2(2)}$	0.9263	0.9649	0.5981	1.0231	0.0949	10%
$\gamma_{cum,i}$	11,649	7,554	440	111,679	14,887	100%
$\alpha_i^{(1)}$	0.3333	0.2600	0.0000	1.0000	0.3671	63%
$\alpha_i^{(2)}$	0.3341	0.3393	0.0000	1.0000	0.3464	67%

有意割合\*: 疑似 t-値 (事後平均/事後標準偏差) で評価した各パラメータの 5%有意である消費者の割合

ために、これら 2 つの推定値の散布図を図 4.4 に示す。世帯ごとデータのばらつきはあるものの、閾値が大きくなるにつれて心的負荷の反応係数も大きくなることが分かる。このことは、閾値の大きな消費者ほど、心的負荷による直接効果の影響が弱くなることを示唆する。心的負荷閾値の低い消費者は、心的負荷が相対的に低い時点から心理的な圧力を感じ始め、さらにその圧力による来店間隔への影響度合いも高い。ほとんどの消費者で  $\beta_{6,i}^{(1)}$  の符号は負であり、心的負荷が高まるほど来店間隔は短くなる傾向を示す。これを検証するために、消費者世帯を  $\beta_{6,i}^{(1)}$  の符号で二つに分類し、それぞれの閾値パラメータの分布を図 4.5 に箱ひげ図で表した。  $\beta_{6,i}^{(1)}$  の符号が負である 67 世帯の閾値パラメータの平均値は 8,585 円であるのに対し、符号が正である 33 世帯の平均値が 17,870 円と倍近く大きい。これは、閾値パラメータの高い世帯は、そもそも家計に余裕があり、心的負荷には反応しない世帯であると考えられる。但し、符号が負となる世帯でも、心的負荷閾値が大きくなるにつれて、来店間隔を縮退させる効果も薄れてくる。消費者異質性が存在するものの、多くの消

費者世帯では、心的負荷が逼迫した状態では、必要なものを必要な時に購入するような計画購買の傾向を示し、 $\beta_{6,i}^{(1)}$  の符号が負で絶対値が大きいほど、その傾向は強くなる。

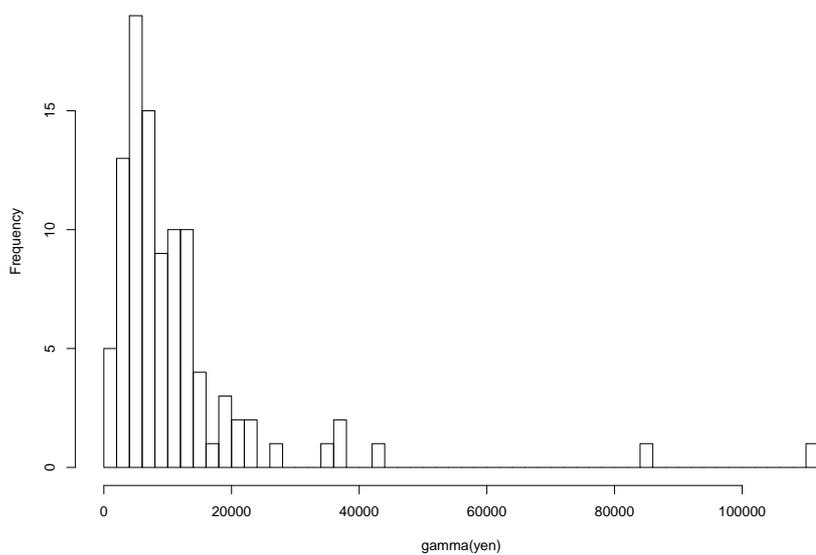


図 4.3: 心的負荷閾値 ( $\gamma_{cum,i}$ ) の度数分布.

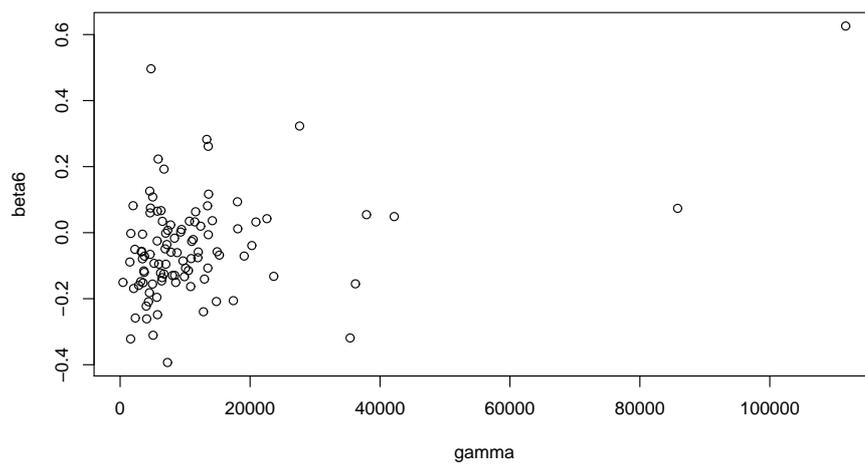


図 4.4: 散布図 ( $\gamma_{cum,i} - \beta_{i,6}^{(1)}$ )

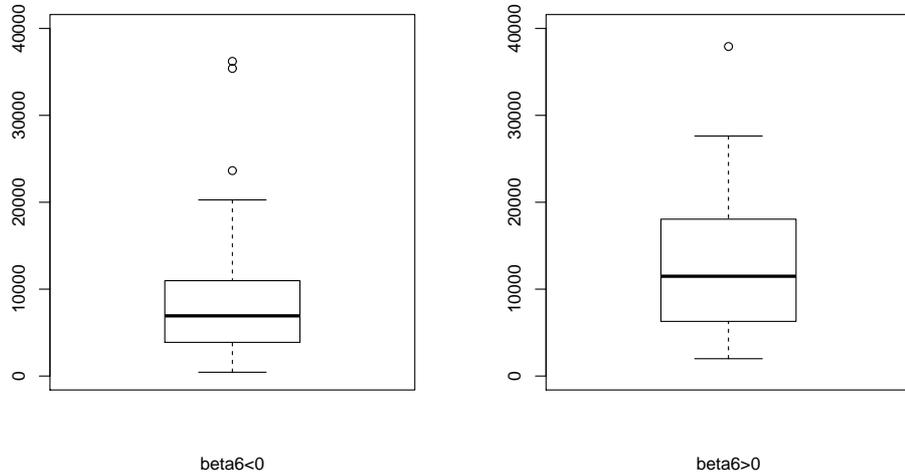


図 4.5: 心的負荷への反応と閾値パラメータの関係性

#### 4.5.5 心的負荷パラメータの検証

本モデルで推定された心的負荷パラメータについて検証する。表 4.3 に、これらパラメータの事後平均分布の基本統計量を示す。心的負荷は、代表的な給料日からの累積購買金額の線形結合として表す。通常は、各消費者の給料日は事前情報として設定できないが、これら心的負荷パラメータを推定することで、消費者世帯の給料日の推定が可能となる。図 4.6 には構成パラメータ  $(\alpha^{(1)}, \alpha^{(2)})$  の散布図を示す。図中、 $(1,0)$ ,  $(0,1)$ ,  $(0,0)$  近傍のプロットは、購買期間がそれぞれ 1, 2, 3 のみ、 $\alpha^{(1)} + \alpha^{(2)} = 1$  直線上のプロットは購買期間が 1 と 2、 $\alpha^{(1)}$  軸上は購買期間 2 と 3、 $\alpha^{(2)}$  軸上は購買期間 3 と 1、図中の三角形内は全購買期間で心的負荷が構成される世帯を表す。

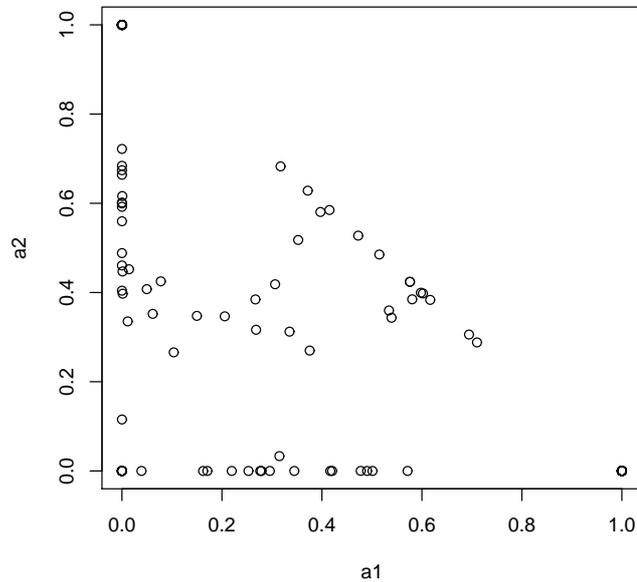


図 4.6: 心的負荷構成パラメータの分布

表 4.4 には、3つの代表的給料日を想定した購買期間を用いて推定した、心的負荷構成パラメータの構成パターンと割合を示す。ここで、推定されたパラメータが1%に満たない場合は切り捨てて算出した。期間1, 2, 3は、給料日がそれぞれ25日, 5日, 17日に対応する。心的負荷が、二つ以上の購買期間から構成されるものは、世帯に二人以上の給与所得者が存在することを示す。本実証分析では、全体の39%で単独または複数の同一給料日の給与所得者を有する世帯だと推定される。残る61%の世帯は、パートタイムやアルバイトを含む給料日の異なる給与所得者を含んだ世帯構造を有する。核家族化している現代において、給与所得者が3人以上有する世帯が、全体の19%あるのは若干高く感じるかもしれない。しかし、派遣社員などは給与支給が月二回設定されることも多く、その場合は一人の給与所得者でも二人にカウントされ、二人世帯の場合でも給与所得者が3人と見なされることを反映する。

表 4.4: 構造パラメータの割合

心的負荷の構成	割合	平均構成比率 ( $\alpha_i^{*(1)} : \alpha_i^{*(2)} : \alpha_i^{*(3)}$ )
購買期間 1 のみ	17%	1.00 : 0.00 : 0.00
購買期間 2 のみ	13%	0.00 : 1.00 : 0.00
購買期間 3 のみ	9%	0.00 : 0.00 : 1.00
購買期間 1 と 2	12%	0.54 : 0.46 : 0.00
購買期間 2 と 3	15%	0.00 : 0.54 : 0.46
購買期間 3 と 1	15%	0.33 : 0.00 : 0.67
全ての購買期間	19%	0.26 : 0.36 : 0.38

#### 4.5.6 階層パラメータの検証

推定された階層パラメータにもとづき、消費者間の共通性について検証する。表 4.5 に階層パラメータの事後平均を示す。表中の括弧内に示した数値は擬似 t-値（事後平均/事後標準偏差）である。これら階層モデルの回帰パラメータは一部を除き、有意な共通性があまり確認されない。実証分析対象の世帯数が 100 では、不十分であった可能性も否めないが、その中でも擬似 t-値が高い係数について検証する。定数項に関して、職業に関わらず、レジーム 1 で正で有意な影響を与えている。これは、一般的に心的負荷が逼迫した状態では来店間隔を長くなるように作用することを示唆する。有意性は少々低くなるが、世帯あたり総累積購買金額の定数項に与える影響の符号が、レジーム 1 で正、レジーム 2 では負となる。累積購買金額が高い消費者方が、心的状態が逼迫したときほど、来店間隔を縮退させる方向に作用している。つまり、総購買金額が高い世帯ほど、来店間隔が短くなる傾向が高いと考えられる。心的負荷閾値に対して、徒歩圏内ダミー以外の属性変数では、有意な影響を与えている。しかし、徒歩圏内ダミーは、全体的に見て、どの係数に対しても有意な影響力を有しておらず、有効な属性変数ではないことが示唆される。さらに、フルタイムの就業ダミーがレジーム 2 で値引き係数に正の影響で有意であるが、他の就業形態の消費者と比較して、心的負荷が緩慢な状況でも値引きに反応しにくいと考えられる。

表 4.5: 階層モデル係数の事後平均

変数	係数	<i>LPAID</i> $\delta_1$	<i>WORK1</i> $\delta_2$	<i>WORK2</i> $\delta_3$	<i>WORK3</i> $\delta_4$	<i>FOOT</i> $\delta_5$
<i>CNST</i> <sub><i>i</i></sub> <sup>(1)</sup>	$\beta_{i,1}^{(1)}$	-0.3789 (-1.3331)	0.4861 (2.9693)	0.5501 (3.5088)	0.5762 (2.6924)	0.0630 (0.5763)
<i>CNST</i> <sub><i>i</i></sub> <sup>(2)</sup>	$\beta_{i,1}^{(2)}$	0.4887 (1.5085)	0.2409 (1.2736)	0.0841 (0.4682)	-0.0586 (-0.2396)	0.0432 (0.3475)
<i>PURCH</i> <sub><i>i</i></sub> <sup>(1)</sup>	$\beta_{i,2}^{(1)}$	-0.0177 (-0.0834)	0.0071 (0.0570)	-0.0101 (-0.0864)	0.0127 (0.0820)	0.0038 (0.0472)
<i>PURCH</i> <sub><i>i</i></sub> <sup>(2)</sup>	$\beta_{i,2}^{(2)}$	-0.0229 (-0.1040)	-0.0210 (-0.1638)	0.0232 (0.1891)	-0.0229 (-0.1400)	0.0793 (0.9336)
<i>ITEMR</i> <sub><i>i</i></sub> <sup>(1)</sup>	$\beta_{i,3}^{(1)}$	0.1583 (0.6593)	0.1222 (0.8904)	-0.0176 (-0.1352)	0.0267 (0.1524)	0.0859 (0.9257)
<i>ITEMR</i> <sub><i>i</i></sub> <sup>(2)</sup>	$\beta_{i,3}^{(2)}$	0.1366 (0.4435)	0.0840 (0.4646)	0.1425 (0.8411)	0.3939 (1.6947)	0.0487 (0.4081)
<i>DSCNT</i> <sub><i>i</i></sub> <sup>(1)</sup>	$\beta_{i,4}^{(1)}$	-0.2884 (-0.9787)	0.0893 (0.5107)	0.0677 (0.4116)	0.0996 (0.4542)	0.1530 (1.3387)
<i>DSCNT</i> <sub><i>i</i></sub> <sup>(2)</sup>	$\beta_{i,4}^{(2)}$	-0.2109 (-0.6900)	0.1492 (0.8381)	0.1219 (0.7144)	0.5140 (2.2306)	0.0617 (0.5221)
<i>INSTM</i> <sub><i>i</i></sub> <sup>(1)</sup>	$\beta_{i,5}^{(1)}$	0.0202 (0.0930)	0.0160 (0.1264)	0.0294 (0.2500)	0.0086 (0.0539)	-0.0266 (-0.3253)
<i>INSTM</i> <sub><i>i</i></sub> <sup>(2)</sup>	$\beta_{i,5}^{(2)}$	-0.0052 (-0.0236)	0.0651 (0.5101)	-0.0035 (-0.0282)	0.0372 (0.2269)	-0.0535 (-0.6180)
<i>CummM</i> <sub><i>i</i></sub> <sup>(1)</sup>	$\beta_{i,6}^{(1)}$	0.3398 (1.49834)	-0.1828 (-1.4072)	-0.1709 (-1.3974)	-0.2140 (-1.2847)	-0.0261 (-0.3051)
心的負荷閾値	$\ln(\gamma_{cum,i})$	6.5761 (9.1862)	6.0261 (14.2456)	5.8488 (14.9221)	5.9571 (11.1372)	0.4514 (1.6039)
心的負荷構成 パラメータ 1	$\alpha_i^{(1)}$	4.6526 (1.9219)	-36.8833 (-1.8747)	-17.3374 (-0.9412)	-43.1437 (-1.7569)	-4.6015 (-0.35634)
心的負荷構成 パラメータ 2	$\alpha_i^{(2)}$	18.8939 (0.5769)	-20.6767 (-1.0864)	-16.7853 (-0.9168)	-19.8601 (-0.8128)	1.9962 (0.1534)

( ) 内数値は擬似 t-値

#### 4.5.7 分散パラメータの検証

本モデルで推定された対数正規分布の分散パラメータについて検証する。表 4.3 に示されるよう、レジーム 1 の分散の方が小さく、心的負荷が逼迫した状態では、来店ハザードが急峻となる。このことは、心的負荷が緩慢なときの方が、来店間隔はランダムであり、逼迫している状態の方が、来店間隔は短くなることを示唆する。（次節図 4.7 にハザード関数の例を参照。）

#### 4.5.8 心理会計と世帯セグメントの来店間隔に関する考察

本小節では、レジームごとに推定された消費者世帯の来店行動について考察する。推定された 100 世帯のうち、両来店レジームを占有するのは 78%と最も多く、レジーム 1 のみ 17%、レジーム 2 のみ 6%である。それぞれの来店反応に対する回帰パラメータの事後平均分布の基本統計量を表 4.6、表 4.7、表 4.8 に示す。各世帯セグメントの閾値パラメータの大きさは、レジーム 2 のみセグメントで最も高く、レジーム 1 のみセグメントの閾値よりも 7 倍以上の大きさである。これら世帯は、4.5.4 節で検証した心的負荷の影響をあまり受けないセグメントに相当し、表 4.8 における  $\beta_{i,6}^{(1)}$  の符号も正となる。また、両レジームを占有するセグメントの閾値は、これら 2 つのセグメントの閾値の中間の値である。レジーム 1 のみを占有する世帯セグメントの閾値パラメータは相対的に低く、心的負荷の増加に伴い直ぐにレジーム 1 へ遷移し、心理的影響要因に敏感な世帯セグメントである。レジーム遷移後は、チラシ係数が負であり、チラシにより消費者の来店が訴求される。一方、レジーム 2 のみを占有する世帯セグメントは、マーケティング施策に対しては特に反応を示さず、そもそも高所得世帯であるため、心理的影響をあまり受けない世帯だと考えられる。両レジームを遷移する世帯セグメントでは、心的負荷による直接効果の反応は負であり、心的負荷が増加することで来店間隔を短縮させる。心的負荷以外の反応係数の符号は正であるが、レジーム 2 との相対比較では、定数項以外はレジーム 1 の方が小さく、心的負荷が高まると来店間隔は縮小する方向に作用する。このことは、レジーム 1 に遷移することで、である消費者の計画購買傾向が高まり、来店間隔は縮小する傾向があることを示唆している。

表 4.6: 両レジーム占有する世帯の事後平均分布の基本統計量

係数	平均値	中央値	最小値	最大値	標準偏差
$\beta_{i,1}^{(1)}$	0.4313	0.3953	-0.3597	1.4549	0.3614
$\beta_{i,2}^{(1)}$	0.0052	0.0036	-0.0329	0.0389	0.0131
$\beta_{i,3}^{(1)}$	0.1755	0.1692	-0.2127	0.6743	0.2171
$\beta_{i,4}^{(1)}$	0.0285	0.0494	-0.7496	1.0436	0.3941
$\beta_{i,5}^{(1)}$	0.0042	0.0014	-0.0361	0.0981	0.0228
$\beta_{i,6}^{(1)}$	-0.0409	-0.0588	-0.3933	0.4964	0.1484
$\beta_{i,1}^{(2)}$	0.3830	0.3232	-0.6372	1.5750	0.4669
$\beta_{i,2}^{(2)}$	0.0383	0.0242	-0.2452	0.8450	0.1133
$\beta_{i,3}^{(2)}$	0.2983	0.2510	-0.6315	1.1805	0.4135
$\beta_{i,4}^{(2)}$	0.0876	0.1983	-0.9531	0.9830	0.4600
$\beta_{i,5}^{(2)}$	0.0123	0.0063	-0.4714	0.5322	0.1136
$\sigma_i^{2(1)}$	0.6046	0.6019	0.2510	0.9843	0.1902
$\sigma_i^{2(2)}$	0.9244	0.9426	0.7172	1.0231	0.0764
$\gamma_{cum,i}$	9,286	7,312	440	42,187	6,633

表 4.7: レジーム 1 のみ占有する世帯の事後平均分布の基本統計量

係数	平均値	中央値	最小値	最大値	標準偏差
$\beta_{i,1}^{(1)}$	0.4578	0.5059	-0.3088	0.9008	0.2977
$\beta_{i,2}^{(1)}$	0.0072	0.0047	-0.0030	0.0267	0.0086
$\beta_{i,3}^{(1)}$	0.0389	0.0159	-0.2255	0.4061	0.1799
$\beta_{i,4}^{(1)}$	0.0950	0.0392	-0.7608	0.6171	0.3457
$\beta_{i,5}^{(1)}$	-0.0021	-0.0028	-0.0165	0.0128	0.0081
$\beta_{i,6}^{(1)}$	-0.0885	-0.0698	-0.2225	0.0364	0.0707
$\beta_{i,1}^{(2)}$	0.1996	0.2782	-0.6494	0.7417	0.4109
$\beta_{i,2}^{(2)}$	0.1253	0.1086	-0.3706	0.6838	0.2735
$\beta_{i,3}^{(2)}$	-0.0398	0.0140	-1.2171	0.6737	0.5044
$\beta_{i,4}^{(2)}$	0.1450	0.0459	-0.6489	0.8193	0.3794
$\beta_{i,5}^{(2)}$	-0.1655	-0.2306	-0.5850	0.2873	0.2560
$\sigma_i^{2(1)}$	0.4001	0.3976	0.2455	0.6183	0.1097
$\sigma_i^{2(2)}$	1.0088	1.0095	1.0010	1.0120	0.0028
$\gamma_{cum,i}$	7,257	5,105	1,646	20,271	5,239

表 4.8: レジーム 2 のみ占有する世帯の事後平均分布の基本統計量

係数	平均値	中央値	最小値	最大値	標準偏差
$\beta_{i,1}^{(1)}$	-0.0746	-0.0019	-0.7397	0.4603	0.4761
$\beta_{i,2}^{(1)}$	-0.2008	-0.2503	-0.5043	0.1581	0.2692
$\beta_{i,3}^{(1)}$	0.1126	0.2709	-0.8320	0.4726	0.4986
$\beta_{i,4}^{(1)}$	0.3408	0.1819	-0.4503	1.4232	0.7135
$\beta_{i,5}^{(1)}$	0.1881	0.1090	-0.2914	0.9730	0.4394
$\beta_{i,6}^{(1)}$	0.0124	-0.0502	-0.3189	0.6258	0.3368
$\beta_{i,1}^{(2)}$	0.6950	0.6942	0.2895	1.2992	0.3692
$\beta_{i,2}^{(2)}$	0.0035	0.0048	-0.0196	0.0263	0.0166
$\beta_{i,3}^{(2)}$	0.2882	0.2735	-0.1011	0.7848	0.3101
$\beta_{i,4}^{(2)}$	0.3926	0.3174	-0.1258	1.0491	0.4439
$\beta_{i,5}^{(2)}$	0.0035	0.0049	-0.0164	0.0146	0.0116
$\sigma_i^{2(1)}$	1.0110	1.0111	1.0083	1.0129	0.0016
$\sigma_i^{2(2)}$	0.7319	0.6652	0.5981	0.9787	0.1459
$\gamma_{cum,i}$	54,074	37,067	17,424	111,679	36,324

次に、消費者ごとに推定されたパラメータをもとに、各レジームに対する来店ハザード関数について検証する。本提案モデルの確率分布として仮定した、対数正規分布の位置パラメータは構造化されており、購買機会ごとの説明変数に応じて連続的に変動する。従って、各レジームのハザード関数も変動するため、消費者ごとに一意に同定してハザード関数を評価することはできない。ここでは、表 4.9 に挙げた代表的な 9 つの消費者世帯に対して、それぞれ来店間隔と説明変数の平均値およびレジームの回帰パラメータから算出した分布パラメータに対応するハザード関数について検証する。

表 4.9: レジーム占有率と関連パラメータ

消費者 番号	位置パラメータ: $\mu_i^{(k)}$		分散パラメータ: $\sigma_i^{2(k)}$		レジーム占有率		来店間隔		閾値 $\gamma_{cum,i}$
	(k=1)	(k=2)	(k=1)	(k=2)	(k=1)	(k=2)	(k=1)	(k=2)	
usr1	0.2525	2.1217	0.4109	1.0128	99.2%	0.8%	1.44	8.00	3,744
usr2	0.4178	1.3518	0.5095	0.9744	92.9%	7.1%	1.71	5.62	18,056
usr3	0.7312	1.0701	0.5095	0.8622	26.4%	73.6%	2.34	3.69	14,056
usr4	0.1038	-	0.3005	-	100%	0%	1.17	-	3,269
usr5	0.3885	-	0.4113	-	100%	0%	1.67	-	4,985
usr6	0.3584	-	0.4335	-	100%	0%	1.59	-	8,366
usr7	-	0.7772	-	0.6464	0%	100%	-	2.62	3,744
usr8	-	0.8376	-	0.8382	0%	100%	-	3.34	18,056
usr9	-	1.0801	-	0.6565	0%	100%	-	3.39	14,810

図 4.7 には、消費者 1,2,3 のハザード関数を示す。これら消費者は、2つのレジーム間の占有率にはばらつきはあるものの、両レジームに購買機会を有する。また、ハザード関数で比較すると、いずれもレジーム 1 の方が、ピークは高く急峻な形状を有している。位置パラメータと分散パラメータは、レジーム 1 で小さく、来店間隔も短くなり、かつ瞬時的来店確率は高まる。このことは、心的負荷が逼迫した状態では、計画購買の傾向が強まり、必要なものを必要なときに購買するため、結果的に来店間隔も短くなることを表している。図 4.8 に示すのは、レジーム間を遷移しない消費者世帯のハザード関数で、左側は消費者 4,5,6 でレジーム 1 のみ、右側は消費者 7,8,9 でレジーム 2 のみに滞留する。いずれの場合も、同一レジーム内では同質的な傾向が確認できる。異なる消費者ではあるが、これら同質的傾向は、上述の消費者 1,2,3 の場合と同様に、レジーム 1 の位置パラメータおよび分散パラメータが小さく、ハザード関数もレジーム 1 の方がやや高く急峻である。一つのレジームの留まる消費者の来店行動は、いずれも来店ハザードは緩慢で、来店間隔のランダム性は増加すると考えられる。また、その傾向は、心的負荷が逼迫したレジーム 1 の方が高い。このことは、心的負荷に敏感な消費者ほど、閾値は低くかつ影響を受けやすいことを示唆する。以上の議論は、来店ごとに変動する説明変数の平均値にもとづいた平均的な来店行動に対する傾向であり、時点および消費者ごとに同様の議論が可能である。

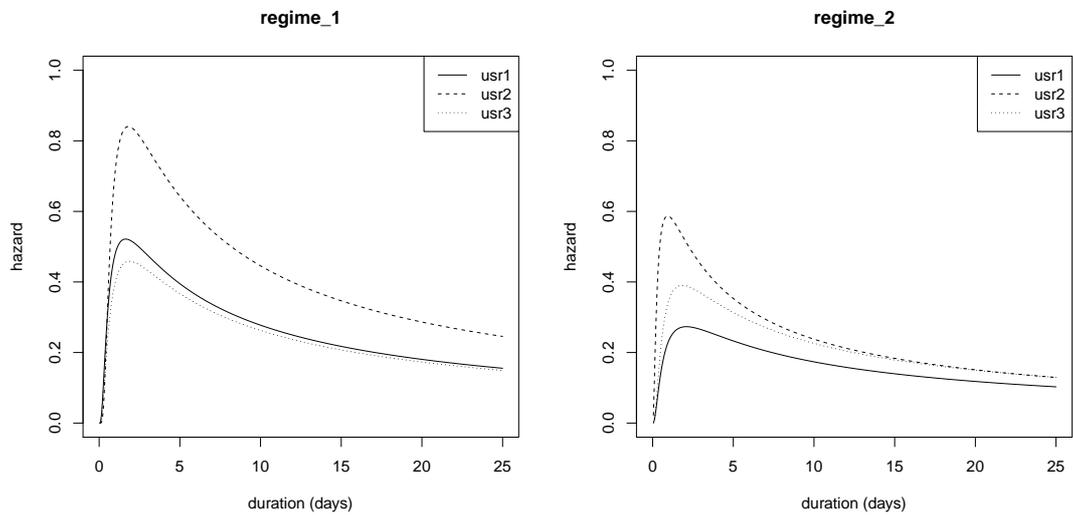


図 4.7: 来店レジーム 1 と 2 を占有する消費者世帯のハザード関数

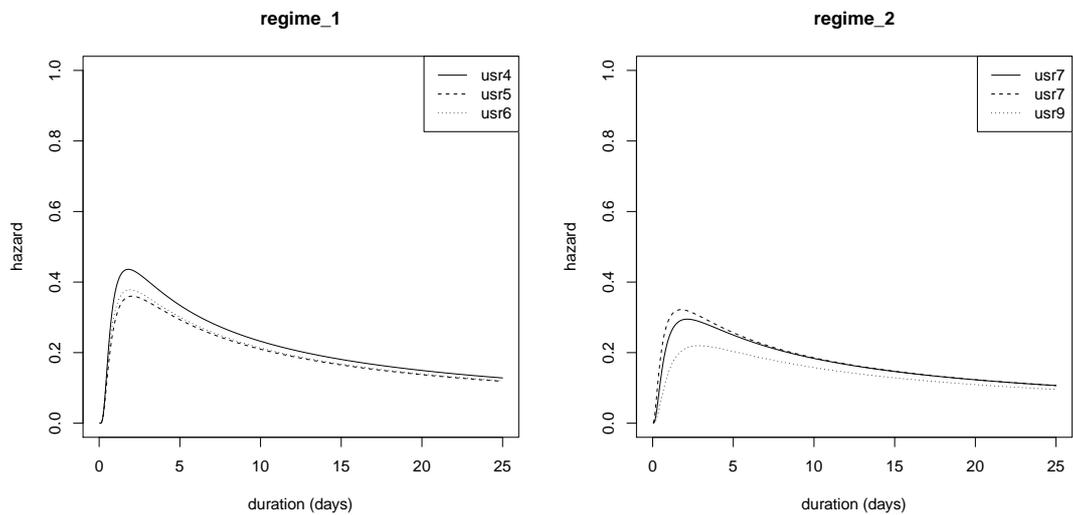


図 4.8: 単一レジームに滞留する消費者世帯のハザード関数

## 4.6 まとめ

本研究では、消費者の心的状況による影響を考慮した来店間隔モデルを構築した。心的状況を表す潜在変数として、第3章で構築した心理会計のモデルを用い、その直接効果も含めて各消費者の心的状況の切換点と各レジームの消費者反応を小売店舗のID-POSデータを用いて推定した。実証分析の結果によると、心的負荷による直接効果の反応は、符号は負であり、心的負荷が高まると来店間隔は短くなるように作用する。これは、累積購買金額がかさみ、心的負荷が高くなると、必要なものを必要なときに購買するという計画購買の傾向が強まることを示唆する。そのような状況では、マーケティング施策に対する消費者反応は鈍くなり、購入する商品項目も変化する。ただし、心的負荷で推定している構成パラメータの解釈には限界があることは、3.6で注記した通りである。

推定された分布パラメータから算出した各消費者の来店ハザードは、単峰で、レジームによってピークの位置と高さが異なる。全ての消費者が、各レジームに購買機会を有するとは限らず、消費者によっては単一レジームに留まり、レジーム間を遷移しないこともある。複数レジームに購買機会を有する消費者は、心的負荷が高まると位置パラメータおよび分散パラメータの双方とも値が小さくなり、来店間隔は短くかつ瞬時的来店確率も高まる。一方、購買機会が単一のレジームに留まる消費者の来店ハザードは、比較的緩慢でピークも高くない。このように、同じ消費者でも心的状況が異なることで、消費者反応は異質となり、購買行動に反映され、一見非合理的だと思える消費者行動を引き起こす。直接効果に対する消費者反応と閾値パラメータの関係には、閾値がある一定の値までは負の相関を示し、閾値の低い消費者ほど直接効果の影響を受けやすい。

このように、ID-POSに記録された事実ベースのデータだけではなく、心理会計に代表される消費者の心的状況という心理的な側面を考慮してモデル化することで、モデルの説明力は向上し、結果として消費者の深い理解につながる。本研究では、心的負荷が逼迫したレジームで直接効果の影響が表れると仮定してモデル化したが、レジームごとに異なる確率分布についての議論は充分でない。さらに、購買点数と来店間隔は、(1.1)式で示した  $INV_t = INV_{t-1} + Q_{t-1} - CR \cdot I_{t-1,t}$  の漸化式により関連付けられており、それぞれが独立に変動するとは限らない。例えば、購買点数が多く家庭内在庫が充分にある場合とそうでない状況では、来店間隔の特性も異なると考えられる。第5章では、購買点数と来店間隔の関連性を家庭内在庫として、心理会計の指標に加えて二次元化し、消費者行動を多面的な側面から議論する。

# 第5章 心理会計モデルの二次元化拡張と 来店間隔モデリング

## 5.1 はじめに

本章では、第4章に引き続き、心理会計と消費者の来店行動の関連性を解明するために、小売店舗に対する消費者の来店間隔をモデル化する。但し、心理会計の代理変数として、第3章と第4章で用いた心的負荷に加えて、購買点数との関連指標でもある家庭内在庫を金額換算した在庫金額を併用した二次元モデルを構築する。本研究における取引効用の評価頻度は、給与は毎月決まった日に支給されるため、心的負荷で月内の変化に、在庫金額では日々の変化に対応して取引効用を評価する。これにより、詳細な心理的影響を変化を捉え、消費者行動への理解を深めることを目的とする。

本章は以降において、次の通りに構成する。5.2節では、本章に関連する先行研究のレビュー結果を示す。5.3節には本研究の提案モデルを、5.4節にはモデル推定のアルゴリズムを、5.5節では本提案モデルにもとづく実証分析を示す。5.5節は本研究のまとめである。

## 5.2 先行研究

購買間隔の先行研究として、Allenby et al. (1999) は、個人投資の取引間隔を投資家ごとにモデル化に際し、取引状態を頻度に応じて3つのレジームに区分し、それぞれ異なる確率分布を推定する。レジーム切替点の推定には、過去の購買間隔データを用いたデータ主導型のアプローチであり、心理会計で理論化された構造をモード切替に取り込むようなモデル構築はできない。それに対して、Ferreira (1975), Geweke and Terui (1993), Chen and Lee (1995), またマーケティング領域では Terui and Danaha (2006) と Terui and Ban (2008) に代表される、連続混合モデルの一種である閾値変数と閾値パラメータを用いて生成モデルの切替を表現するアプローチが存在する。Miyatsu and Sato (2018) は、このアプローチに従い、閾値関数に給料日からの累積購買金額を用いて、消費者の心的状況に応じた来店レ

ゲームの切換えを表現した(第4章)。しかし、来店間隔は前回購買機会における購買点数に応じた家庭内在庫量にも依存する。そこで本提案モデルでは、家庭内在庫量を金額換算した在庫金額を考慮して心理会計指標の二次元化を試み、消費者の来店間隔モデルを拡張する。

### 5.3 モデル

本節では本研究における提案モデルを示す。消費者の小売店への来店間隔は、店頭でのプロモーション活動、食品・日雑品等の家庭内在庫量、消費者の購買習慣などの影響を受ける。それに加えて、消費者が抱く心的状況も来店間隔に影響する。伝統的経済学では、消費者は効用最大化のために合理的な行動を取ることを前提とするが、行動経済学では、心理会計という概念で心的状況が購買行動に影響すると考えられている。これにより、一見非合理的と思えるような消費者の購買行動を説明する。心理会計とは、本来同じ価値を有する金銭でも、使用目的や入手状況によって異なる価値評価を下すというものである。すなわち、同じ消費者でも状況により異なる購買行動レジームが存在することを意味する。消費者がどのような心的状況に置かれているかは潜在的なものであり、消費者ごとに異なる。本研究では、消費者ごとの購買行動における心的状況を表す潜在変数として、前章の4.3.1節と同様に給料日を起点とした消費者の累積購買金額を心的負荷、さらに食品・日雑品等の家庭内在庫量のアナログ値を在庫金額として用いる。これら二つの潜在変数を用いることで、心的負荷により給料日ごとの大きな心的状況の変化を、在庫金額では日々変動する家庭内在庫量による細かな心的状況の変動を捉える。心理会計は、プロスペクト理論を根拠とした概念であり、プロスペクト理論の参照点の本モデルの閾値に相当し、その前後で異なる評価関数を仮定する。この考え方に従い、本モデルでは、異なる2つの閾値で区分される4つの来店レジームが、それぞれ異なる確率分布を有する。

提案モデルでは、これら二つの潜在変数と消費者ごとの閾値との大小関係で心的状況の変化を捉える。そして、消費者ごとの4つのレジームそれぞれに対して、来店間隔の生起メカニズムをモデル化する。閾値構造を導入することで、例えば、心的負荷が閾値を超えると給料日からの累積購買が増加することで消費者が心理的に圧迫された状況を表現でき、在庫金額が閾値を下回ると家庭内在庫量が希薄であることによる心理的圧迫が加わるという状況を表現できる。各レジームには、それぞれに対応した来店間隔の確率分布を仮定する。本研究では、目的変数が非負であることを考慮して、ワイブル分布、対数正規分布、

対数ロジスティック分布のいずれかを仮定し、レジームごとに異なる係数を有した回帰モデルの枠組みで定式化する。また、消費者ごとでも構造が異なることを考慮し、これらメカニズムを表現するために階層モデルにより消費者間の共通性を取り込む。以下、4.3.1項には心的影響因子モデルとして心的負荷モデルと在庫金額モデル、4.3.2項には個体内モデル、4.3.3項には個体間モデルをそれぞれ示す。

### 5.3.1 心的影響因子モデル（心理会計モデル）

本研究では、消費者の購買行動における心理的影響因子を潜在変数としてモデルに取り込む。心理的影響因子には、新たな収入が得られるまでに支出の蓄積が及ぼす心的負荷、家庭内在庫を金額換算した在庫金額を仮定する。在庫金額は、家庭内に備蓄される財の多寡が消費者に与える心理的圧迫度合いを表現している。心的負荷で消費者の購買行動における大きな消費者行動レジームの変化を、在庫金額では各レジーム内の細かな変動を捉える。以下に、これら二つの心理的影響要因のモデル化について示す。

#### ■ 収支バランスの圧力モデル（心的負荷モデル）

心的負荷モデルは、3.3.1節で示したモデルを用いる。以下にモデル式を再掲する。給料日は特定できないので、その前提で心的負荷をモデル化する。具体的には、代表的な給料日である毎月25日、5日、17日を前提とし、(5.1)式には、それぞれに対応した累積購買集計期間の記号を導入する。

$$\text{累積購買集計期間} \begin{cases} l=1 & \Rightarrow \text{前月 25 日から 今月 24 日まで} \\ l=2 & \Rightarrow \text{前月 5 日から 今月 4 日まで} \\ l=3 & \Rightarrow \text{前月 17 日から 今月 16 日まで} \end{cases} \quad (5.1)$$

(5.2)式は、消費者  $i$  の集計対象期間  $l$  における購買機会  $t_i$  までの累積購買金額を示す。

$$\text{cum}_{i,t_i,l} = \begin{cases} \sum_{j=1}^{\text{trans}^l(t_i)-1} M_{i,j,l} & \text{tran}^l(t_i) \neq 1 \\ 0 & \text{tran}^l(t_i) = 1 \end{cases} \quad (5.2)$$

ここで、 $t_i$  は各消費者で異なり、期間中の来店回数も全消費者で同一ではない。 $\text{trans}^l(t_i)$  は、消費者  $i$  の集計対象期間  $l$  における集計起点日から  $t_i$  までの来店回数であり、 $M_{i,j,l}$  は、消費者  $i$  の集計期間内の購買機会  $j$  における購買金額である。例えば、給料日25日の場合、消費者  $i$  の当該期間中  $n$  回目の購買機会  $t_i$  を明示的に  $t_{i,n}$  とするとき、毎月25日以降の初回購買

機会においては  $cum_{i,t_i,1} = 0$  である。2 回目の購買機会では、初回購買機会での購買金額を用いて  $cum_{i,t_i,2} = M_{i,1,1}$  となり、3 回目では 2 回目の購買金額  $M_{i,2,1}$  が加算されて  $cum_{i,t_i,3} = M_{i,1,1} + M_{i,2,1}$  となる。n 回目の購買機会は、同様に  $cum_{i,t_i,n} = M_{i,1,1} + M_{i,2,1} + \dots + M_{i,n-1,1}$  である。次月 25 日以降は上記を繰り返して  $cum_{i,t_i,n}$  が生成される。(5.3) 式が、本研究における心的負荷のモデルである。 $\alpha_i^{*(k)}$  ( $k = 1, 2, 3$ ) は  $0 \leq \alpha_i^{*(k)} \leq 1$  および  $\sum_{k=1}^3 \alpha_i^{*(k)} = 1$  の制約を満たすパラメータであり、 $\alpha_i^* = (\alpha_i^{*(1)}, \alpha_i^{*(2)})$  とする。例えば、 $\alpha_i^{*(1)} = 1$  となる場合はシングルインカム（給料日 25 日）、 $\alpha_i^{*(1)} = \alpha_i^{*(2)} = 0.5$  はダブルインカム（給料日 25 日と 5 日）に対応しており、世帯における様々な家計の状況を表現できる。ここで世帯とは、消費者が属する世帯を指し、本研究で消費者というとき、世帯の代表者を意味する。また、本モデルにおける  $\alpha_i^* = (\alpha_i^{*(1)}, \alpha_i^{*(2)})$  を推定することで、副次的であるが、各世帯の給料日推定も可能となる。このように、消費者の心的負荷を、給料日からの累積購買金額で (5.3) 式のようにモデル化することで、 $CummM_{i,t_i}$  が小さければ心的負荷が低い状態を、その値が大きくなれば心的負荷が高い状態を表現する。3.3.1 節で解説した通り、 $\alpha_i^{*(k)}$  ( $k = 1, 2, 3$ ) は、購買金額 ( $M_{i,t,i}$ ) に対する給料日ごとの心理的負担割合の比率であり、消費者世帯ごとに異質である。

$$CummM_{i,t_i} = \alpha_i^{*(1)} cum_{i,t_i,1} + \alpha_i^{*(2)} cum_{i,t_i,2} + \alpha_i^{*(3)} cum_{i,t_i,3} \quad (5.3)$$

#### ■ 家庭内在庫バランスの圧力モデル（在庫金額モデル）

本小節では、家庭内在庫を金額換算した在庫金額のモデルを示す。本モデルは、Bucklin and Lattin(1991) による家庭内在庫の算出法に従う。(5.4) 式が在庫金額を定義する漸化式である。

$$InvM_{i,t_i} = InvM_{i,t_i-1} + M_{i,t_i-1} - Cnsm_{i,t_i} \quad (5.4)$$

消費者  $i$  の購買機会  $t_i$  時点における在庫金額  $InvM_{i,t_i}$  は、前回購買機会  $t_i - 1$  時点における在庫金額  $InvM_{i,t_i-1}$  に購買金額  $M_{i,t_i-1}$  を加算し、 $t_i$  と  $t_i - 1$  間の時間間隔  $\Delta d_{i,t_i}$  中に消費した家庭内在庫の金額換算分  $Cnsm_{i,t_i}$  を減じて算出する。本研究では、 $Cnsm_{i,t_i}$  を、 $Cnsm_{i,t_i} = \min[ InvM_{i,t_i-1} + M_{i,t_i-1}, \Delta d_{i,t_i} \cdot consm_{day,i} ]$  で定義する。各消費者の一日あたりの消費量は一定と仮定する。式中  $consm_{day,i}$  は消費者  $i$  は消費者  $i$  の一日当たりの平均消費量の金額換算値を示す。(5.4) 式は、在庫金額が非負であることを反映して、経過期間中の消費量が平均的な消費ペースでは賸えない場合、残存している全在庫金額を消費してゼロとなる構造を表現している。なお、以降の実証分析では、消費者  $i$  の在庫金額の初期値  $InvM_{i,0}$  と一日あたりの平均消費量  $consm_{day,i}$  を購買データのホールドアウトサンプルから算定する。

図 5.1 はシングルインカムの心的負荷と在庫金額を，図 5.2 には 2 つの給料日が混合したダブルインカムの心的負荷と在庫金額を例示した．横軸は購買機会の回数である．

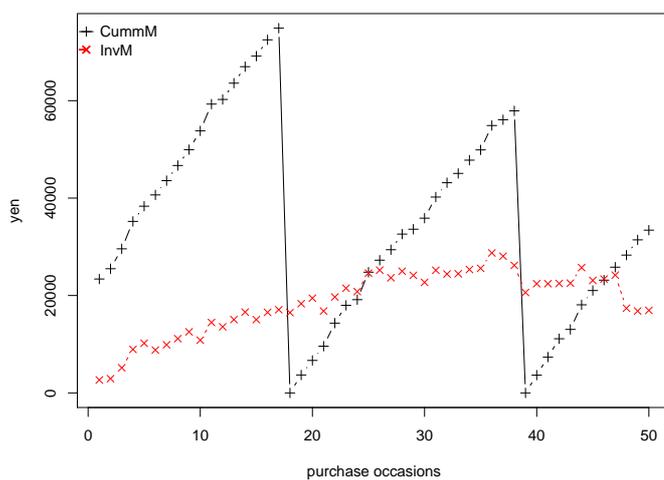


図 5.1: 心的影響要因 (シングルインカムの例)

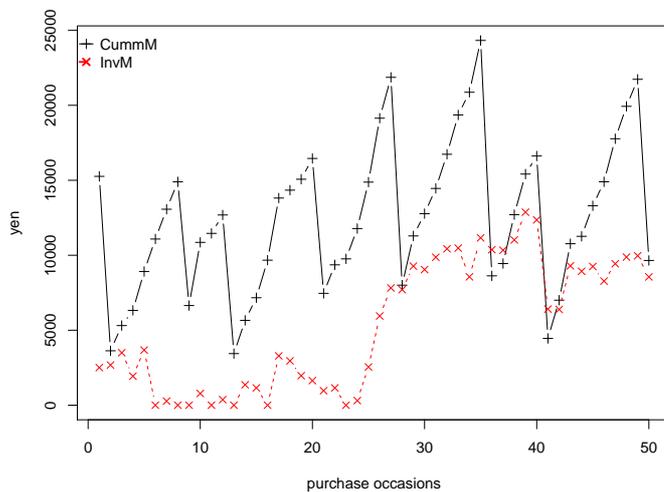


図 5.2: 心的影響要因 (ダブルインカムの例)

### 5.3.2 個体内モデル（観測モデル）

本小節には、提案モデルの個体内モデルである閾値来店間隔モデルを示す。消費者  $i$  による購買時点  $t_{i,n_i-1}$  から  $t_{i,n_i}$  までの時間間隔  $y_{i,t_i} = \Delta d_{i,t_i}$  を、消費者  $i$  の購買時点  $t_i$  に対する購買間隔とする。本研究では、(5.3) 式および (5.4) 式で示した消費者ごとの潜在変数と閾値パラメータ  $\gamma_{cum,i}$ ,  $\gamma_{inv,i}$  の大小関係により、4 つの来店間隔  $Y_{i,t_i}$  の生起メカニズムが切換ると仮定してモデル化する。各レジームの評価関数<sup>1</sup> は異なり、確率分布も同一とは限らない。本研究では、 $y_{i,t_i}$  が非負連続データである点を考慮し、各レジームの確率分布に、ワイブル分布、対数正規分布、対数ロジスティック分布のいずれかを仮定して定式化する。(5.5) 式が、消費者  $i$  の時点  $t_i$  における心的影響要因を考慮した来店間隔の個体内モデルである。

$$Pr(Y_{i,t_i} = y_{i,t_i} \mid \omega_{i,t_i}^{(1)}, \omega_{i,t_i}^{(2)}, \omega_{i,t_i}^{(3)}, \omega_{i,t_i}^{(4)}, \gamma_{cum,i}, \gamma_{inv,i}, \alpha_i, cum_{i,t_i}, InvM_{i,t_i})$$

$$= \begin{cases} f_1(y_{i,t_i} \mid \omega_{i,t_i}^{(1)}) & CumM_{i,t_i} \geq \gamma_{cum,i}, InvM_{i,t_i} \geq \gamma_{inv,i} \text{ (レジーム 1)} \\ f_2(y_{i,t_i} \mid \omega_{i,t_i}^{(2)}) & CumM_{i,t_i} < \gamma_{cum,i}, InvM_{i,t_i} \geq \gamma_{inv,i} \text{ (レジーム 2)} \\ f_3(y_{i,t_i} \mid \omega_{i,t_i}^{(3)}) & CumM_{i,t_i} < \gamma_{cum,i}, InvM_{i,t_i} < \gamma_{inv,i} \text{ (レジーム 3)} \\ f_4(y_{i,t_i} \mid \omega_{i,t_i}^{(4)}) & CumM_{i,t_i} \geq \gamma_{cum,i}, InvM_{i,t_i} < \gamma_{inv,i} \text{ (レジーム 4)} \end{cases} \quad (5.5)$$

$\omega_{i,t_i}^{(1)}, \omega_{i,t_i}^{(2)}, \omega_{i,t_i}^{(3)}, \omega_{i,t_i}^{(4)}$  は、各レジームのパラメータベクトルである。本研究では、説明変数  $x_{i,t_i}$  と各レジームの回帰係数  $\beta_i^{(1)}, \beta_i^{(2)}, \beta_i^{(3)}, \beta_i^{(4)}$  を用いて、ワイブル分布の場合は尺度パラメータ  $\tau_{i,t_i}$  に対数回帰変換、対数正規分布と対数ロジスティック分布の場合は位置パラメータそれぞれ  $\mu_{i,t_i}, \eta_{i,t_i}$  に回帰変換による構造化を仮定する。（なお、構造化に関する詳細は付録 C.1 を参照。）ここで、説明変数と回帰係数で構造化されたパラメータを被構造化パラメータと呼ぶことにする。回帰係数  $\beta_i^{(k)}$  は消費者  $i$  に固有な時点に依存しないパラメータであるのに対し、説明変数  $x_{i,t_i}$  は時点依存のため、被構造化パラメータは時点依存となることに注意する。表記を単純化する都合上、被構造化パラメータを  $\varphi_{i,t_i}^{(k)} (= x_{i,t_i}^t \beta_i^{(k)}$  または  $e^{x_{i,t_i}^t \beta_i^{(k)}}$ ) と表記する。また、ワイブル分布の形状パラメータ  $\kappa_i$ 、対数正規分布の分散パラメータ  $\sigma_i^2$ 、対数ロジスティック分布の尺度パラメータ  $s_i$  をその他のパラメータと呼び  $\zeta_i$  とする。以上より、各レジームのパラメータベクトルは、 $\omega_{i,t_i}^{(k)} = (\varphi_{i,t_i}^{(k)}, \zeta_i^{(k)})$  となる。また、消費者  $i$  に固有の時間に依存しないパラメータベクトルを  $\pi_i^{(k)} = (\beta_i^{(k)}, \zeta_i^{(k)})$  とする。

<sup>1</sup>心理会計は、プロスペクト理論を根拠とした概念であり、プロスペクト理論の参照点が本モデルの閾値に相当し、その前後で2つの異なる購買レジームを有する。さらに、ここでは家庭内在庫量にも、同様の概念を適用している。

次に、消費者の各購買機会が、どちらのレジームに振り分けられたかの集合を示す記号  $R^{(k)}$  ( $k = 1, 2, 3, 4$ ) を導入する。ここで  $k$  は、 $CummM_{i,t_i}$  と  $\gamma_{cum,i}$  および  $InvM_{i,t_i}$  と  $\gamma_{inv,i}$  の大小関係により、(5.5) 式のレジームの番号に対応して割り当てられる。また、消費者  $i$  の総購買機会数  $N_i$  に対応する時点  $t_{i,N_i}$  を  $T_i$  とするとき、(5.6) 式が消費者  $i$  の全購買機会  $\mathbf{y}_i = (y_{i,t_{i,1}}, y_{i,t_{i,2}}, \dots, y_{i,T_i})^t$ 、 $\mathbf{InvM}_i = (InvM_{i,t_{i,1}}, InvM_{i,t_{i,2}}, \dots, InvM_{i,T_i})^t$  に対する来店間隔の尤度関数である。

$$p(\mathbf{y}_i | \mathbf{x}_i, \boldsymbol{\pi}_i^{(1)}, \boldsymbol{\pi}_i^{(2)}, \boldsymbol{\pi}_i^{(3)}, \boldsymbol{\pi}_i^{(4)}, \gamma_{cum,i}, \gamma_{inv,i}, \mathbf{cum}_i, \boldsymbol{\alpha}_i, \mathbf{InvM}_i) = \prod_{k=1}^4 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} f_k(y_{i,t_i} | \mathbf{x}_{i,t_i}, \boldsymbol{\pi}_i^{(k)}, \gamma_{cum,i}, \gamma_{inv,i}, \mathbf{cum}_{i,t_i}, \boldsymbol{\alpha}_i^*, InvM_{i,t_i}) \right\} \quad (5.6)$$

消費者同士は独立であると仮定すると、(5.7) 式が、全消費者 ( $i = 1, 2, \dots, H$ ) に対する全体尤度になる。なお、具体的なモデル変数 ( $\mathbf{x}_{i,t_i}$ ) に関する説明は、表 5.1 に後述する。

$$p(\{\mathbf{y}_i\} | \{\mathbf{x}_i\}, \{\boldsymbol{\pi}_i^{(1)}\}, \{\boldsymbol{\pi}_i^{(2)}\}, \{\boldsymbol{\pi}_i^{(3)}\}, \{\boldsymbol{\pi}_i^{(4)}\}, \{\gamma_{cum,i}\}, \{\gamma_{inv,i}\}, \{\mathbf{cum}_i\}, \{\boldsymbol{\alpha}_i\}, \{\mathbf{InvM}_i\}) = \prod_{i=1}^H \left\{ \prod_{k=1}^4 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} f_k(y_{i,t_i} | \mathbf{x}_{i,t_i}, \boldsymbol{\pi}_i^{(k)}, \gamma_{cum,i}, \gamma_{inv,i}, \mathbf{cum}_{i,t_i}, \boldsymbol{\alpha}_i^*, InvM_{i,t_i}) \right\} \right\} \quad (5.7)$$

### 5.3.3 個体間モデル (階層モデル)

本小節では、消費者ごとの異質なパラメータの背後に共通性構造を仮定した階層モデルについて説明する。消費者  $i$  に固有なパラメータベクトル  $\boldsymbol{\pi}_i^{(k)}$  のうち、その他パラメータ  $\phi_i^{(k)}$  のみ対数値としたベクトルを  $\boldsymbol{\pi}_i^{*(k)} = (\boldsymbol{\beta}_i^{(k)}, \ln(\phi_i^{(k)}))$  とする。このとき、 $\boldsymbol{\pi}_i^{*(1)}, \boldsymbol{\pi}_i^{*(2)}, \boldsymbol{\pi}_i^{*(3)}, \boldsymbol{\pi}_i^{*(4)}$  と閾値パラメータ  $\gamma_{cum,i}, \gamma_{inv,i}$  の対数値をあわせて、 $\boldsymbol{\psi}_i = (\boldsymbol{\pi}_i^{*(1)}, \boldsymbol{\pi}_i^{*(2)}, \boldsymbol{\pi}_i^{*(3)}, \boldsymbol{\pi}_i^{*(4)}, \ln(\gamma_{cum,i}), \ln(\gamma_{inv,i}))$  を定義する。また、心的負荷モデルの構成パラメータ  $\boldsymbol{\alpha}_i^*$  のロジット変換前のパラメータベクトルを  $\boldsymbol{\alpha}_i = (\alpha_i^{(1)}, \alpha_i^{(2)})$  と定義する。つまり、 $\boldsymbol{\alpha}_i$  は、 $\alpha_i^{*(k)} = \frac{\exp(\alpha_i^{(k)})}{1 + \sum_{l=1}^2 \exp(\alpha_i^{(l)})}, k = 1, 2$  の逆変換として表せる。このとき、(5.8) 式、(5.9) 式が、消費者  $i$  の階層モデルとなる。なお、具体的な属性変数 ( $\mathbf{z}_i$ ) に関する説明は、表 5.1 に後述する。

$$\boldsymbol{\psi}_i = \mathbf{z}_i^t \boldsymbol{\Delta}_\psi + \boldsymbol{\epsilon}_i^\psi, \boldsymbol{\epsilon}_i^\psi \sim \mathcal{MVN}(\mathbf{0}, \boldsymbol{\Sigma}_\psi) \quad (5.8)$$

$$\boldsymbol{\alpha}_i = \mathbf{z}_i^t \boldsymbol{\Delta}_\alpha + \boldsymbol{\epsilon}_i^\alpha, \boldsymbol{\epsilon}_i^\alpha \sim \mathcal{MVN}(\mathbf{0}, \boldsymbol{\Sigma}_\alpha) \quad (5.9)$$

$\boldsymbol{\psi}_i, \boldsymbol{\alpha}_i$  は、消費者  $i$  の属性変数  $\mathbf{z}_i = (z_{i,1}, z_{i,2}, \dots, z_{i,q})^t$  と係数行列  $\boldsymbol{\Delta}_\psi, \boldsymbol{\Delta}_\alpha$  の線形結合で表し、 $q$  は属性変数の次元、 $\boldsymbol{\Sigma}_\psi, \boldsymbol{\Sigma}_\alpha$  は、それぞれの分散共分散行列である。なお、 $\boldsymbol{\Delta}_\psi, \boldsymbol{\Delta}_\alpha, \boldsymbol{\Sigma}_\psi, \boldsymbol{\Sigma}_\alpha$

の事前分布は，(5.10) 式，(5.11) 式のように設定する．事前分布の設定にあたっては， $p(\Delta_\psi, \Sigma_\psi) = p(\Delta_\psi|\Sigma_\psi)p(\Sigma_\psi)$ ,  $p(\Delta_\alpha, \Sigma_\alpha) = p(\Delta_\alpha|\Sigma_\alpha)p(\Sigma_\alpha)$  の関係式を用い， $p(\Delta_\psi|\Sigma_\psi)$ ,  $p(\Delta_\alpha|\Sigma_\alpha)$  は多変量正規分布， $p(\Sigma_\psi)$ ,  $p(\Sigma_\alpha)$  は逆ウィッシュャート分布を仮定する．(実証データによる推定で設定した事前分布については付録 B.2 を参照.)

$$\begin{aligned}\delta_\psi &= \text{vec}(\Delta_\psi) \sim \mathcal{MVN}(\bar{\delta}_\psi, \Sigma_\psi \otimes A_\psi^{-1}) \\ \Sigma_\psi &\sim \mathcal{IW}(v_{\psi,0}, V_{\psi,0})\end{aligned}\tag{5.10}$$

$$\begin{aligned}\delta_\alpha &= \text{vec}(\Delta_\alpha) \sim \mathcal{MVN}(\bar{\delta}_\alpha, \Sigma_\alpha \otimes A_\alpha^{-1}) \\ \Sigma_\alpha &\sim \mathcal{IW}(v_{\alpha,0}, V_{\alpha,0})\end{aligned}\tag{5.11}$$

## 5.4 アルゴリズム

### 5.4.1 事後分布

本小節には，提案モデルの推定アルゴリズムの基となる事後分布を提示する．図 5.3 は消費者  $i$  の購買時点  $t_{i,t_i}$  における，本提案モデルから導出される有向非巡回グラフ (DAG : Directed Acyclic Graph) である．図 5.3 に示す DAG に基づき，消費者間の独立性を仮定すると，(5.12) 式の事後分布を導出できる．

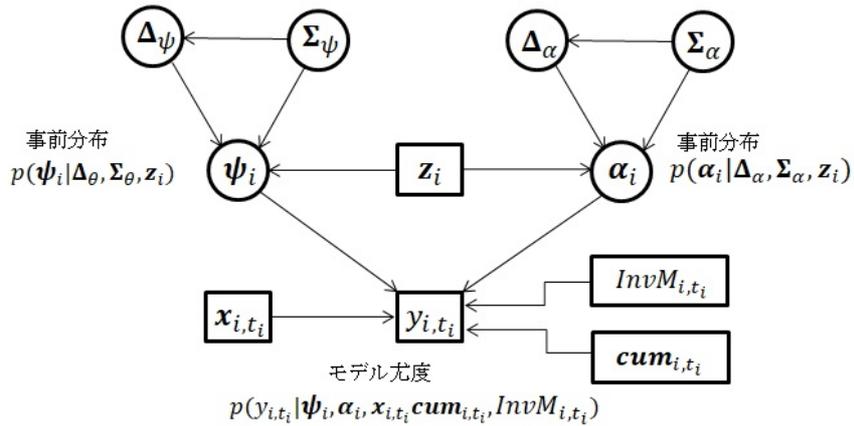


図 5.3: 提案モデルの有向非巡回グラフ

$$\begin{aligned}
p(\Psi, \mathcal{A}|Y, X, Z, Cum, Inv) &\propto p(\Delta_\psi|\Sigma_\psi)p(\Sigma_\psi)p(\Delta_\alpha|\Sigma_\alpha)p(\Sigma_\alpha) \\
&\times \prod_{i=1}^H p(\mathbf{y}_i|\psi_i, \alpha_i, \mathbf{x}_i, cum_i, InvM_i)p(\psi_i|\Delta_\psi, \Sigma_\psi, \mathbf{z}_i)p(\alpha_i|\Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i) \quad (5.12)
\end{aligned}$$

ただし,  $\Psi \equiv \{\psi_i\} = (\psi_1, \psi_2, \dots, \psi_H)$ ,  $\mathcal{A} \equiv \{\alpha_i\} = (\alpha_1, \alpha_2, \dots, \alpha_H)$ ,  $Z \equiv \{\mathbf{z}_i\} = (\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_H)$ ,  $X \equiv \{\mathbf{x}_i\} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_H)$ ,  $Y \equiv \{\mathbf{y}_i\} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_H)$ ,  $Cum \equiv \{cum_i\} = (cum_1, cum_2, \dots, cum_H)$ ,  $Inv \equiv \{InvM_i\} = (InvM_1, InvM_2, \dots, InvM_H)$  である.

## 5.4.2 カーネル

5.4.1 節の事後分布に示した提案モデルには,  $\Psi, \mathcal{A}, \Delta_\psi, \Delta_\alpha, \Sigma_\psi, \Sigma_\alpha$  が含まれる.  $\Psi, \mathcal{A}$  は消費者ごとに異なるパラメータであり,  $\Delta_\psi, \Delta_\alpha, \Sigma_\psi, \Sigma_\alpha$  は消費者間で共通のパラメータである. これらパラメータの推定には, マルコフ連鎖モンテカルロ法 (MCMC: Markov chain Monte Carlo method) を用いる. 推定アルゴリズムは, (5.12) 式に基づき構成する. すなわち,  $\Psi, \mathcal{A}$  は非共役なため, そのサンプリングにはランダムウォークメトロポリス・ヘイスティングス (ランダムウォーク M-H) 法を用いる. 一方, 階層パラメータ  $\Delta_\psi, \Delta_\alpha, \Sigma_\psi, \Sigma_\alpha$  は 5.3.3 節に示した通り共役になるため, 標準的なギブスサンプラーを用いてサンプリングする. 消費者  $i$  ごとの  $\psi_i$  と  $\alpha_i$  のサンプリングには, ランダムウォーク M-H 法を用いるが, 事後分布からのサンプル候補値を生成するためのカーネルを (5.13) 式と (5.14) 式に示す.  $f_k(\cdot)$  は, レジーム  $k$  における来店間隔の確率分布で, ワイブル分布, 対数正規分布, 対数ロジスティック分布のいずれかである.

全ての消費者に対して共通なパラメータである  $\Delta_\psi, \Delta_\alpha, \Sigma_\psi, \Sigma_\alpha$  および  $\alpha_i$  を所与として, ランダムウォークサンプラーから生成した  $\psi_i$  を (5.13) 式に示す事後分布カーネルを用いて評価し, 採択/棄却を確率的に決定する.

$$\begin{aligned}
p(\mathbf{y}_i|\psi_i, \alpha_i, \mathbf{x}_i)p(\psi_i|\Delta_\psi, \Sigma_\psi, \mathbf{z}_i) &\propto \prod_{k=1}^4 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} f_k(y_{i,t_i} | \mathbf{x}_{i,t_i}, \pi_i^{*(k)}) \right\} \\
&\times \exp \left\{ -\frac{1}{2} (\psi_i - \mathbf{z}_i^t \Delta_\psi)^t \Sigma_\psi^{-1} (\psi_i - \mathbf{z}_i^t \Delta_\psi) \right\} \quad (5.13)
\end{aligned}$$

同様に,  $\alpha_i$  に対しては,  $\Delta_\psi, \Delta_\alpha, \Sigma_\psi, \Sigma_\alpha$  および  $\psi_i$  を所与として, ランダムウォークサ

ンプラーから生成した  $\alpha_i$  を (5.14) 式に示す事後分布カーネルを用いて評価し、採択／棄却を確率的に決定する．

$$p(\mathbf{y}_i | \psi_i, \alpha_i, \mathbf{x}_i) p(\alpha_i | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i) \propto \prod_{k=1}^4 \left\{ \prod_{t_i \in R^{(k)}}^{T_i} f_k(y_{i,t_i} | \mathbf{x}_{i,t_i}, \pi_i^{*(k)}) \right\} \\ \times \exp \left\{ -\frac{1}{2} (\alpha_i - \mathbf{z}_i^t \Delta_\alpha)^t \Sigma_\alpha^{-1} (\alpha_i - \mathbf{z}_i^t \Delta_\alpha) \right\} \quad (5.14)$$

推定アルゴリズムの詳細および階層パラメータを含めた初期値については、付録 C.2 に示す．また、推定用のサンプルプログラムを付録 C.3 に示す．

## 5.5 実証分析

### 5.5.1 分析データ

本研究では、第4章の購買点数モデルの実証分析で用いたデータと同一の都内にあるスーパーマーケットの ID-POS データを用いて実証分析を行う．2001年1月1日から2001年12月31日までの期間中、欠損データのない消費者1,325人のうち、年間50回以上かつ毎月1回以上の購買履歴のある消費者1,158人の中からランダムに100人抽出して分析対象とした．ここで、100人に限定したのは、本研究において4レジームに3種類の確率分布を仮定した81通りのシミュレーション（後述の5.5.2節モデル評価を参照）を行うため、計算負荷と時間制約の観点からサンプルを100人と限定した．表5.1に本実証分析で採用する変数を示す．食料品や日用雑貨品の購入でスーパーマーケットへ来店する場合、通常は週に1回程度は恒常的に来店するとの仮定から、年間50回以上かつ月1回以上という条件で抽出した．購買頻度がこれ以下に低下すると、他の小売店舗で購買する頻度も高くなると考えられ、消費者の心理的影響を1つの店舗の ID-POS データだけでは十分に捉えられなくなる懸念が生じる．

本モデルでは、購買対象商品やカテゴリーを特に指定せず、消費者ごとに購買が発生した来店間隔を目的変数として用いる．そのため、店舗全体の特性を表す変数として、チラシや値引などのプロモーションに関わる変数は特定の商品やカテゴリーに偏ることのないように選択する必要がある．当該スーパーマーケットで販売されている商品は、食料品と日用雑貨品に大別され、さらに食料品は生鮮食料品と加工食品などの非生鮮食料品に分けられる．生鮮食料品は、市場でその都度仕入れられるために定価がなく、値引率を算出す

表 5.1: モデル変数

変数	記号	説明	平均値	標準偏差
$y_{i,t_i}$	$DRTN_{i,t_i}$	購買間隔 (被説明変数)	2.02	1.98
$\mathbf{x}_{i,t_i}$	$CNST_{i,t_i}$	定数: 1	1.00	0.00
	$PURCH_{i,t_i}$	前回購買機会における購買点数	14.30	8.16
	$ITEMR_{i,t_i}$	前回購買商品の日雑品・加工食品比率	0.66	0.21
	$DSCNT_{i,t_i}$	日雑品・加工食品の店舗全体割引率	0.16	0.12
	$INSTM_{i,t_i}$	チラシの掲載商品点数	58.18	55.51
	$\mathbf{z}_i$	$LPAID_i$	平均購買金額/1000 の対数値	0.43
$WORK1_i$		就業形態ダミー (家事専業=1, それ以外=0)	0.30	0.46
$WORK2_i$		就業形態ダミー (パート=1, それ以外=0)	0.55	0.50
$WORK3_i$		就業形態ダミー (フルタイム=1, それ以外=0)	0.11	0.31
$FOOT_i$		来店手段 (徒歩=1, それ以外=0)	0.61	0.49

ることができない。そのため、本モデルで採用する平均割引率は日用雑貨品と加工食品に限定され、店舗全体での平均割引率は 16% である。また、チラシに掲載された商品点数は、一日当たり平均 58.18 点と比較的多い。スーパーマーケットのチラシは、一枚の紙面に商品の写真と値段を数多く掲載するカタログ形式のものが一般的であり、小売業における主要なプロモーション施策の一つである。本モデルには、マーケティング活動を表す指標として、これら値引とチラシに関する変数を用いる。消費者の来店間隔には、直近の購買点数および購買品目にも大きく依存する。生鮮食料品は消費期限が短く、一度の購買量にも限度がある一方、日用雑貨品や加工食品は長期間保存できるため、まとめ買いが可能である。本モデル変数の購買機会当たりの購買点数は 14.3 点であり、その内 66% が日用雑貨品と加工食品が占める。階層モデルを構成する消費者ごとの属性変数は、購買機会当たりの平均購買金額 (千円) の対数値、就業形態、および来店手段ダミーを採用する。モデル期間前のホールドアウトサンプルから算出した全消費者の購買機会当たりの平均購買金額は 1,537 円であり、61% の消費者が店舗から徒歩圏内に居住している。就業形態では、フルタイムの消費者が比較的少ない。しかしながら、実際の消費性向は世帯所得に依存するため、消費者属性の就業形態と一致するとは限らず、本モデルの推定値を解釈するには注意が必要である。通常、年齢と性別を消費者属性として用いることが多いが、経験上、年齢と性別は説明力が低く、就業形態の方が消費者行動の説明に効くことから、本研究では就業形態を採用している。また、就業形態は 4 つの形態 (家事専業、アルバイト・パート、フ

ルタイム、自宅就業・その他)に分類されており、ダミー変数としては自宅就業・その他を基準とした *WORK1*, *WORK2*, *WORK3* の構成にした。ここで、その他とは、学生や年金生活者などが含まれる。また、家事専業は無職であるが、世帯に給与所得者を有することを暗示する。

### 5.5.2 モデル評価

本実証分析では、MCMC の総繰り返し回数 50,000 回、バーンインサンプルを 45,000 回とし、消費者あたり 5,000 サンプルを用いて算出した対数周辺尤度および DIC の比較によりモデルを評価する。4 レジームの各確率分布には、ワイブル分布、対数正規分布、対数ロジスティック分布のいずれかを仮定するため、合計 81 通りの確率分布の組み合わせに対して算出した。表 5.2 には、対数周辺尤度（および DIC）を降順（昇順）に並べたときの上位および下位それぞれ 10 通りの組み合わせを示す。レジーム 1 とレジーム 2 にワイブル分布を仮定するモデルの対数周辺尤度は低く（DIC は高く）、対数正規分布および対数ロジスティック分布を仮定したモデルの評価が良好である。これは、消費者の来店間隔ハザードを単調増加または減少だけで表すのは難しいことを示唆する。対数周辺尤度および DIC のいずれに基づいても、レジーム 1, 2, 3, 4 のそれぞれに、対数ロジスティック分布、対数正規分布、対数正規分布、対数ロジスティック分布を仮定したモデルが採択される。以降では、ここで採択されたモデルに基づいて議論する。表 5.3 には、レジームを仮定しない 1 状態のモデル評価を示す。1 状態モデルの場合、確率分布に対数正規分布、対数ロジスティック分布、ワイブル分布を仮定したモデルの順で良好である。同一の確率分布を仮定した 4 状態モデルと 1 状態モデルの比較では、確率分布が同じであれば、4 状態モデルの方が良好なモデルであることも分かる。なお、81 通りの全パターンに対する 4 状態モデルの対数周辺尤度と DIC の算出結果は付録 C.4 に示す。また、対数周辺尤度と DIC の算出に関しては、それぞれ Newton and Raffery (1994), Spiegelhalter et al. (2002) を参照のこと。

表 5.2: モデル評価 (上段: 上位 10 モデル, 下段: 下位 10 モデル)

(レジーム 1)	(レジーム 2)	(レジーム 3)	(レジーム 4)	対数周辺尤度	DIC
対数ロジ	対数正規	対数正規	対数ロジ	-19,960.52	40,181.10
対数ロジ	対数正規	対数正規	対数正規	-20,174.60	40,594.90
対数正規	対数ロジ	対数ロジ	対数正規	-20,195.41	40,602.67
対数正規	対数ロジ	対数正規	対数正規	-20,205.24	40,571.09
対数正規	対数正規	対数正規	対数正規	-20,209.42	40,728.59
対数正規	対数正規	対数正規	対数ロジ	-20,287.09	40,835.99
対数ロジ	対数正規	対数正規	ワイブル	-20,377.59	40,677.58
対数正規	対数ロジ	ワイブル	対数正規	-20,404.75	41,013.38
対数正規	対数正規	対数正規	ワイブル	-20,444.33	41,172.30
対数正規	対数正規	対数ロジ	対数正規	-20,475.74	41,198.28
(レジーム 1)	(レジーム 2)	(レジーム 3)	(レジーム 4)	対数周辺尤度	DIC
ワイブル	ワイブル	対数正規	対数正規	-22,647.01	45,611.82
ワイブル	ワイブル	対数正規	ワイブル	-22,676.10	45,642.32
ワイブル	ワイブル	対数正規	対数ロジ	-22,695.53	45,644.04
ワイブル	対数ロジ	ワイブル	対数ロジ	-22,713.09	45,628.13
ワイブル	ワイブル	対数ロジ	対数正規	-22,893.35	46,107.90
ワイブル	ワイブル	ワイブル	対数正規	-22,931.24	46,137.21
ワイブル	ワイブル	対数ロジ	対数ロジ	-23,167.58	46,542.79
ワイブル	ワイブル	対数ロジ	ワイブル	-23,172.62	46,610.77
ワイブル	ワイブル	ワイブル	対数ロジ	-23,201.73	46,651.83
ワイブル	ワイブル	ワイブル	ワイブル	-23,297.69	46,693.70

(注) ワイブル: ワイブル分布, 対数正規: 対数正規分布, 対数ロジ: 対数ロジスティック分布  
 (レジーム 1)  $CummM_i \geq \gamma_{cum,i}, InvM_i \geq \gamma_{inv,i}$  (レジーム 2)  $CummM_i < \gamma_{cum,i}, InvM_i \geq \gamma_{inv,i}$   
 (レジーム 3)  $CummM_i < \gamma_{cum,i}, InvM_i < \gamma_{inv,i}$  (レジーム 4)  $CummM_i \geq \gamma_{cum,i}, InvM_i < \gamma_{inv,i}$

表 5.3: 1 状態モデルの評価

	ワイブル分布	対数正規分布	対数ロジスティック分布
対数周辺尤度	-24,722.54	-21,217.48	-22,669.34
DIC	49,543.94	42,739.68	45,321.09

### 5.5.3 回帰パラメータの検証

消費者ごとに推定した回帰パラメータの事後平均分布<sup>2</sup>の基本統計量を表5.4に示す。疑似t値（事後平均/事後標準偏差）にもとづいて判定した、各パラメータ5%有意である消費者の割合を表5.5に示す。階層ベイズの枠組みでは、各レジームの回帰係数は消費者ごとに異質パラメータとして推定され、個別にパラメータ検証が可能となるが、本小節では消費者ごとの事後平均の分布に基づいて議論を進める。なお、消費者別に対しても同様の検証が可能である。まず、来店間隔のベースとなる定数項 $\beta_{i,1}$ についてであるが、心的負荷による心理的な圧迫が同等レベルの状況では、在庫金額が閾値を超えると $\beta_{i,1}$ は増大し、来店間隔は長くなる。この傾向は、心理的に圧迫された状況ほど大きく表れる。一方、在庫金額が同等レベルの状況では、心的負荷が閾値を超えると $\beta_{i,1}$ は減少し、来店間隔は短くなる。心的負荷が高まると、本当に必要なものを、必要なときに購買する傾向が顕在化して来店間隔が縮退する消費者行動の表れである。また、在庫金額が増加する場合、家庭内在庫は増えるために全体的には来店間隔は長くなる傾向にある。しかし、値引係数 $\beta_{i,4}$ に関しては、在庫金額が増加すると係数の符号はマイナスとなり、来店間隔を縮める方向に作用する。家庭内在庫が充分にある状況では、特定の買置き品を購買するのではなく、安価なら余分に購買しておこうとするインセンティブが働いていることを示唆する。消費者固有の前回購買に関連する係数であるが、 $\beta_{i,2}$ および $\beta_{i,3}$ は、心的負荷が高い状況の方が、来店間隔は短くなる傾向を示す。更に、心的負荷が高く、在庫金額が少ない状況では、 $\beta_{i,3}$ の符号はマイナスとなり、来店間隔の縮退が進む。表5.6には、各消費者の購買レジーム推定後に集計したレジームごとの変数の平均値を示す。レジーム1の来店間隔が最も短く1.92日、さらに前回購買点数は最も多く17.7点と、最も少ないレジーム3との差は4点以上ある。心的負荷が高まり、必要なものを、必要なときに購買する状況においては、来店間隔が短くなるため購買点数も少なくなると推測されるかも知れないが、実際には購買点数は多い。その理由として、同じ商品でも大容量のものよりは小パックの使い切り商品等へ移行するような購買商品構成の変化が考えられる。本実証分析の変数では、購買商品に関して生鮮食品と非生鮮食品（日用雑貨品・加工食品）という大きな区別のみでしか表していないが、詳細な商品構成も心理的な状況に依存して変化する。実際に、レジーム1での生鮮食料品の購買割合は、レジーム4よりも平均5%高く、購買商品の構成割合は変化し、使い切り商品を多品種購買していると考えられる。チラシ変数に対する反応であるが、

<sup>2</sup>事後分布にもとづく消費者ごとの平均値の分布を、ここでは事後平均分布と呼ぶ。

在庫金額が高いレベルで心的負荷が大きくなると  $\beta_{i,5}$  は小さくなり、広告による来店間隔は相対的に縮退する傾向を示す。一方、在庫金額が低いレベルにおいて、心的負荷が大きくなると  $\beta_{i,5}$  も大きくなる傾向を示しており、この状況ではチラシ広告の効果は期待できない。しかし、 $\beta_{i,5}$  の符号はすべて正であり、それ自体来店間隔を短縮する直接効果は見られない。その大きな理由は、値引き変数との相関が高いことが考えられる。チラシに掲載する商品は、通常値引き商品であり、本研究での  $\beta_{i,4}$  の推定値は、レジーム 2 以外は負と推定されている。

表 5.4: 事後平均分布の基本統計量

区分	係数	平均値	中央値	最大値	最小値	標準偏差
(レジーム 1)	$\beta_{i,1}^{(1)}$	0.0618	0.0618	0.1115	0.0125	0.0238
	$\beta_{i,2}^{(1)}$	0.0167	0.0169	0.0533	-0.0194	0.0164
	$\beta_{i,3}^{(1)}$	0.0332	0.0325	0.0834	-0.0147	0.0237
	$\beta_{i,4}^{(1)}$	-0.0143	-0.0136	0.0331	-0.0632	0.0229
	$\beta_{i,5}^{(1)}$	0.0013	0.0014	0.0225	-0.0205	0.0091
(レジーム 2)	$\beta_{i,1}^{(2)}$	0.1194	0.1205	0.1684	0.0683	0.0248
	$\beta_{i,2}^{(2)}$	0.0210	0.0208	0.0425	-0.0003	0.0085
	$\beta_{i,3}^{(2)}$	0.0503	0.0500	0.0982	0.0051	0.0219
	$\beta_{i,4}^{(2)}$	-0.0150	-0.0160	0.0340	-0.0635	0.0235
	$\beta_{i,5}^{(2)}$	0.0028	0.0030	0.0103	-0.0048	0.0028
(レジーム 3)	$\beta_{i,1}^{(3)}$	0.1095	0.1096	0.1557	0.0611	0.0224
	$\beta_{i,2}^{(3)}$	0.0312	0.0319	0.0611	-0.0006	0.0137
	$\beta_{i,3}^{(3)}$	0.0874	0.0863	0.1367	0.0398	0.0230
	$\beta_{i,4}^{(3)}$	0.0312	0.0320	0.0802	-0.0203	0.0242
	$\beta_{i,5}^{(3)}$	0.0096	0.0096	0.0305	-0.0115	0.0094
(レジーム 4)	$\beta_{i,1}^{(4)}$	0.0034	0.0043	0.0507	-0.0444	0.0231
	$\beta_{i,2}^{(4)}$	0.0334	0.0331	0.0771	-0.0094	0.0200
	$\beta_{i,3}^{(4)}$	-0.0034	-0.0033	0.0434	-0.0496	0.0221
	$\beta_{i,4}^{(4)}$	0.0128	0.0130	0.0628	-0.0369	0.0243
	$\beta_{i,5}^{(4)}$	0.0181	0.0174	0.0534	-0.0161	0.0158

表 5.5: 5%有意な推定値の割合

パラメータ	レジーム 1	レジーム 2	レジーム 3	レジーム 4
$\beta_{i,1}$	83%	87%	85%	83%
$\beta_{i,2}$	50%	54%	86%	77%
$\beta_{i,3}$	81%	81%	80%	81%
$\beta_{i,4}$	85%	77%	81%	91%
$\beta_{i,5}$	24%	19%	46%	52%
$\phi_i$	96%	89%	93%	88%
心的負荷閾値対数値: $\ln(\gamma_{cum,i})$		100%		
在庫金額閾値対数値: $\ln(\gamma_{inv,i})$		100%		
ロジット変換前構成パラメータ 1: $\alpha_i^{(1)}$		66%		
ロジット変換前構成パラメータ 2: $\alpha_i^{(2)}$		64%		

表 5.6: 購買レジーム推定後の各変数平均値

変数	記号	レジーム 1	レジーム 2	レジーム 3	レジーム 4
$y_i$	$DRTN_i$	1.92	2.23	3.76	3.59
$x_{i,1}$	$CNST_i$	1.00	1.00	1.00	1.00
$x_{i,2}$	$PURCH_i$	17.71	15.86	13.06	13.96
$x_{i,3}$	$ITEMR_i$	0.65	0.67	0.66	0.70
$x_{i,4}$	$DSCNT_i$	0.17	0.17	0.17	0.17
$x_{i,5}$	$INSTM_i$	54.87	55.78	45.75	55.35
占有割合	(%)	12.2	52.0	30.7	5.1

### 5.5.4 閾値パラメータの検証

消費者ごとに推定した心的負荷閾値 ( $\gamma_{cum,i}$ ) と在庫金額閾値 ( $\gamma_{inv,i}$ ) の事後平均分布の基本統計量を表 5.7 に示す。表 5.5 に示す通り、擬似 t-値 (事後平均/事後標準偏差) にもとづいて判定した 5%有意<sup>3</sup> な消費者の割合は 100%であり、閾値は安定的に推定されている。

<sup>3</sup> $\gamma_{cum,i}$ ,  $\gamma_{inv,i}$  および  $\alpha_i^{(k)}$  に関しては、推定に当たって変換をしているため、擬似 t-値を用いた頻度論的検定は意味を有さない。ただし、ここではパラメータの推定値がある値の近傍に統計的な散らばりの範囲内で分布している否かを簡便に評価することを狙いとして擬似 t-値を用いた。厳密に評価するには HPD (Highest Posterior Density) リージョンを用いるべきである。

心的負荷閾値の事後平均の平均値は 32,735 円であり、消費者の一カ月あたりの平均累積購買金額が 42,597 円であることから、月間購買平均金額の 77%を超える辺りで心理的に逼迫した状態へ遷移する。在庫金額閾値の事後平均の平均値は 1,459 円であり、消費者の一日あたりの平均消費量の金額換算値 1,465 円にほぼ一致する。さらに、消費者の購買機会あたりの平均購買金額は 2,957 円であり、2.02 日で完全消費する換算となるが、これは消費者の平均購買間隔 2.02 日に等しい。つまり、世帯消費量の 2 日分程度を購買機会ごとに購入し、これらを完全消費する頃に再来店するのが消費者の平均的な購買行動である。この購買周期から外れた場合、家庭内在庫の観点から、消費者に心理的な変化が生じて来店間隔生成メカニズムに影響を与える。

表 5.7: 事後平均分布の基本統計量

閾値	平均値	中央値	最小値	最大値	標準偏差	歪度	尖度
心的負荷閾値 ( $\gamma_{cum,i}$ )	32,735	29,057	3,777	113,580	19,515	1.14	4.86
在庫金額閾値 ( $\gamma_{inv,i}$ )	1,459	1,353	36	4,782	763	1.14	5.61

心的負荷閾値 ( $\gamma_{cum,i}$ ) および在庫金額閾値 ( $\gamma_{inv,i}$ ) の事後平均の度数分布を、図 5.4 と図 5.5 に示す。在庫金額閾値の方が、裾野が広く尖度が大きい。図 5.6 は、全消費者に対して、横軸に心的負荷閾値 ( $\gamma_{cum,i}$ )、縦軸に在庫金額閾値 ( $\gamma_{inv,i}$ ) とした散布図である。これら変数は高い相関を示し、相関係数は  $\rho = 0.850$  である。また、切片なしの最小二乗法による回帰式は  $\gamma_{inv,i} = 0.042\gamma_{cum,i}$  であり、各消費者の在庫金額閾値は、心的負荷閾値のおよそ 4.2%に相当する。通常、消費者は限られた収入の範囲内で購買行動を繰り返す。ここで推定した各閾値は、消費者ごとの購買行動における局面の変換点を示し、消費者は各購買レジームを遷移しながら最終的な収支が合うよう来店間隔を決定している。

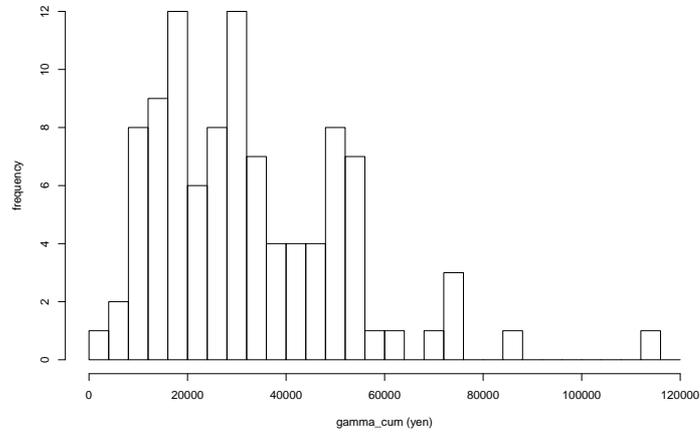


図 5.4: 心的負荷閾値 ( $\gamma_{cum,i}$ ) の事後平均の度数分布

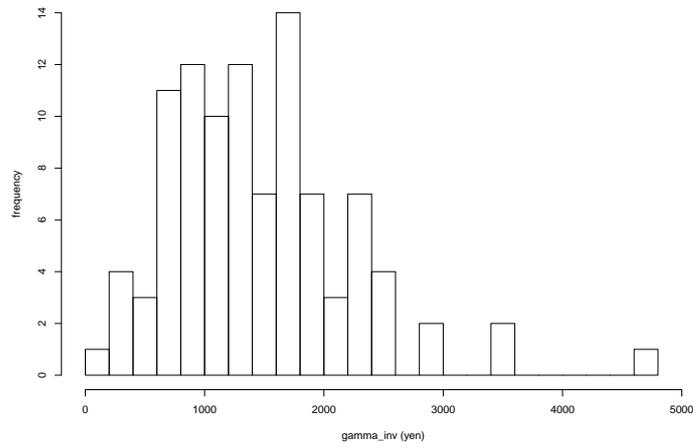


図 5.5: 在庫金額閾値 ( $\gamma_{inv,i}$ ) の事後平均の度数分布

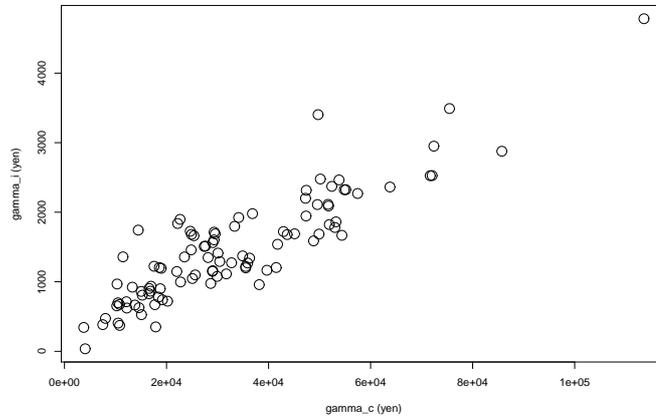


図 5.6: 心的負荷と在庫金額の閾値散布図

### 5.5.5 心的負荷パラメータの検証

本研究では、心的負荷を用いて、月次レベルの来店間隔生成メカニズムの切換点を消費者ごとに推定する。心的負荷は給料日からの累積購買金額で定める消費者の月次の心的変動を、在庫金額は家庭内ストックの金額換算値として日次の心的変動を反映する。ただし、各消費者の給料日は事前情報として設定できないことから、購買データから推定しなければならない。図 5.7 には構成パラメータ  $(\alpha^{*(1)}, \alpha^{*(2)})$  の散布図を示す。図中、 $(1,0)$ ,  $(0,1)$ ,  $(0,0)$  近傍のプロットは、購買期間がそれぞれ 1, 2, 3 のみ、 $\alpha^{*(1)} + \alpha^{*(2)} = 1$  直線上のプロットは購買期間が 1 と 2、 $\alpha^{*(1)}$  軸上は購買期間 2 と 3、 $\alpha^{*(2)}$  軸上は購買期間 3 と 1、図中の三角形内は全購買期間で心的負荷が構成される世帯を表す。

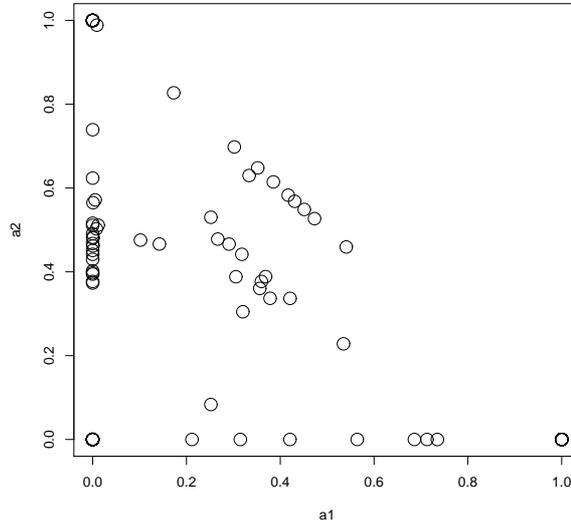


図 5.7: 心的負荷構成パラメータの分布

表 5.8 は構成パラメータの事後平均分布の基本統計量を示す。各パラメータの擬似 t-値 (事後平均/事後標準偏差) を用いて算出した 95% 有意な推定値の割合は表 5.5 の通り 2/3 程度の割合で有意である。表 5.9 には、3 つの代表的給料日を想定した購買期間を用いて推定した、心的負荷構成パラメータの構成パターンと割合を示す。ここで、推定されたパラメータが 1% に満たない場合は切り捨てて算出した。期間 1, 2, 3 は、給料日がそれぞれ 25 日, 5 日, 17 日に対応する。心的負荷が、二つ以上の購買期間から構成されるものは、世帯に二人以上の給与所得者が存在することを示す。本実証分析では、全体の 47% で単独または複数の同一給料日の給与所得者を有する世帯だと推定される。残る 53% の世帯は、パートタイムやアルバイトを含む給料日の異なる給与所得者を含んだ世帯構造を有する。核家族化している現代において、給与所得者が 3 人以上有する世帯が、全体の 17% あるのは若干高く感じるかもしれない。しかし、派遣社員などは給与支給が月二回設定されることも多く、その場合は一人の給与所得者でも二人にカウントされ、二人世帯の場合でも給与所得者が 3 人と見なされることを反映する。

表 5.8: 事後平均分布の基本統計量

構成パラメータ	平均値	中央値	最小値	最大値	標準偏差
心的負荷構成パラメータ 1 ( $\alpha_i^{*(1)}$ )	0.2621	0.0032	0.0000	1.0000	0.3551
心的負荷構成パラメータ 2 ( $\alpha_i^{*(2)}$ )	0.3995	0.4161	0.0000	1.0000	0.3659

表 5.9: 構造パラメータの割合

心的負荷の構成	割合	平均構成比率 ( $\alpha_i^{*(1)} : \alpha_i^{*(2)} : \alpha_i^{*(3)}$ )
購買期間 1 のみ	14%	1.00 : 0.00 : 0.00
購買期間 2 のみ	18%	0.00 : 1.00 : 0.00
購買期間 3 のみ	15%	0.00 : 0.00 : 1.00
購買期間 1 と 2	9%	0.39 : 0.61 : 0.00
購買期間 2 と 3	20%	0.00 : 0.48 : 0.52
購買期間 3 と 1	7%	0.52 : 0.00 : 0.48
全ての購買期間	17%	0.29 : 0.40 : 0.31

### 5.5.6 階層モデルパラメータの検証

推定された階層パラメータにもとづき、消費者間の共通性について検証する。表 5.10 と表 5.11 に階層パラメータの事後平均を示す。表中の括弧内に示した数値は擬似 t-値（事後平均/事後標準偏差）である。閾値パラメータとその他のパラメータの一部で有意な共通性が見られるものの、回帰パラメータに対する有意な共通性はあまり確認されない。その理由の一つとして、実証分析対象の消費者数 100 では不十分だと考えられる。その中でも、擬似 t-値がやや高い係数について、以下に検証する。フルタイムの消費者は、レジーム 1 で値引係数に対してマイナスの影響を与えている。そもそも、心的負荷が逼迫した状況では来店間隔が短くなるが、これはフルタイム属性を有する消費者で共通した傾向である。徒歩圏内に居住の消費者は、レジーム 2 で日雑品・加工食品割合の係数に対してマイナスを示している。家庭内在庫が充分な状況では、必要があれば直ぐにアクセスできるという心理状況を表す。また、家事専門の消費者はレジーム 3 の定数項がプラスであり、慣性的な購買行動を表す。その他のパラメータに対しては、家事専門およびパートの消費者がマイナスに効いており、分布のばらつきを低減させる。閾値パラメータに対する消費者属性

は、ほとんどでプラスで有意に影響しているが、就業形態別による差異は見られない。また、心的負荷構成パラメータに対する消費者属性による有意性は確認されない。

表 5.10: 階層モデル係数の事後平均 (その 1)

変数	係数	<i>LPAID</i> $\delta_1$	<i>WORK1</i> $\delta_2$	<i>WORK2</i> $\delta_3$	<i>WORK3</i> $\delta_4$	<i>FOOT</i> $\delta_5$
$CNST_i^{(1)}$	$\beta_{i,1}^{(1)}$	-0.1806 (-0.6005)	0.1439 (0.8210)	0.1875 (1.1376)	0.0862 (0.3891)	-0.0269 (-0.2344)
$CNST_i^{(2)}$	$\beta_{i,1}^{(2)}$	0.1260 (0.4130)	0.0696 (0.3976)	0.1375 (0.8244)	0.1062 (0.4721)	-0.0696 (-0.6034)
$CNST_i^{(3)}$	$\beta_{i,1}^{(3)}$	-0.1685 (-0.5540)	0.1655 (0.9335)	0.1202 (0.7122)	0.1613 (0.7211)	0.0685 (0.5891)
$CNST_i^{(4)}$	$\beta_{i,1}^{(4)}$	-0.0370 (-0.1223)	0.0585 (0.3305)	0.0129 (0.0773)	0.0435 (0.1921)	-0.0281 (-0.2432)
$PURCH_i^{(1)}$	$\beta_{i,2}^{(1)}$	0.0532 (0.1877)	-0.0280 (-0.1685)	-0.0120 (-0.0758)	-0.0165 (-0.0787)	0.0129 (0.1181)
$PURCH_i^{(2)}$	$\beta_{i,2}^{(2)}$	-0.0030 (-0.0107)	0.0206 (0.1238)	0.0132 (0.0848)	0.0406 (0.1977)	0.0054 (0.0501)
$PURCH_i^{(3)}$	$\beta_{i,2}^{(3)}$	-0.0187 (-0.0656)	0.0399 (0.2356)	0.0338 (0.2129)	0.0311 (0.1449)	0.0013 (0.0117)
$PURCH_i^{(4)}$	$\beta_{i,2}^{(4)}$	-0.0167 (-0.0578)	0.0154 (0.0901)	0.0476 (0.2964)	0.0471 (0.2184)	0.0043 (0.0381)
$ITEMR_i^{(1)}$	$\beta_{i,3}^{(1)}$	-0.0668 (-0.2185)	0.1321 (0.7461)	0.0244 (0.1445)	-0.0039 (-0.0177)	0.0137 (0.1185)
$ITEMR_i^{(2)}$	$\beta_{i,3}^{(2)}$	0.0333 (0.1109)	0.1231 (0.7084)	0.1038 (0.6356)	0.0233 (0.1067)	-0.1007 (-0.9018)
$ITEMR_i^{(3)}$	$\beta_{i,3}^{(3)}$	0.0841 (0.2779)	-0.0284 (-0.1608)	0.0338 (0.2018)	-0.0174 (-0.0780)	0.0643 (0.5497)
$ITEMR_i^{(4)}$	$\beta_{i,3}^{(4)}$	0.0262 (0.0868)	-0.0253 (-0.1435)	0.0119 (0.0724)	0.1116 (0.4978)	-0.0381 (-0.3235)
$DS CNT_i^{(1)}$	$\beta_{i,4}^{(1)}$	0.2112 (0.6725)	-0.0872 (-0.4776)	-0.0621 (-0.3584)	-0.2341 (-1.0143)	-0.0182 (-0.1506)
$DS CNT_i^{(2)}$	$\beta_{i,4}^{(2)}$	0.0851 (0.2880)	-0.0307 (-0.1785)	-0.0343 (-0.2088)	-0.0623 (-0.2828)	-0.0281 (-0.2431)
$DS CNT_i^{(3)}$	$\beta_{i,4}^{(3)}$	0.0693 (0.2313)	0.0322 (0.1845)	-0.0056 (-0.0339)	-0.0235 (-0.1062)	-0.0001 (-0.0005)
$DS CNT_i^{(4)}$	$\beta_{i,4}^{(4)}$	-0.0343 (-0.1109)	0.0707 (0.3903)	0.0816 (0.4803)	-0.1359 (-0.6036)	-0.0390 (-0.3233)

( ) 内数値は擬似 t-値

表 5.11: 階層モデル係数の事後平均 (その 2)

変数	係数	<i>LPAID</i> $\delta_1$	<i>WORK1</i> $\delta_2$	<i>WORK2</i> $\delta_3$	<i>WORK3</i> $\delta_4$	<i>FOOT</i> $\delta_5$
$INSTM_i^{(1)}$	$\beta_{i,5}^{(1)}$	-0.0188 (-0.0661)	0.0194 (0.1187)	0.0123 (0.0790)	0.0480 (0.2258)	-0.0156 (-0.1416)
$INSTM_i^{(2)}$	$\beta_{i,5}^{(2)}$	-0.0007 (-0.0026)	-0.0041 (-0.0246)	0.0005 (0.0032)	0.0273 (0.1307)	0.0021 (0.0193)
$INSTM_i^{(3)}$	$\beta_{i,5}^{(3)}$	0.0380 (0.1336)	0.0124 (0.0744)	0.0085 (0.0546)	-0.1403 (-0.6621)	-0.0030 (-0.0267)
$INSTM_i^{(4)}$	$\beta_{i,5}^{(4)}$	0.0264 (0.0901)	-0.0144 (-0.0858)	-0.0341 (-0.2134)	0.0116 (0.0536)	0.0497 (0.4404)
その他 パラメータ 1	$\ln(\phi_i^{(1)})$	-0.3958 (-1.1995)	-0.2686 (-1.3997)	-0.3035 (-1.6431)	-0.2645 (-1.0882)	0.0361 (0.2843)
その他 パラメータ 2	$\ln(\phi_i^{(2)})$	-0.1642 (-0.4501)	-0.4092 (-1.9447)	-0.4627 (-2.3185)	-0.4524 (-1.7096)	-0.0754 (-0.5443)
その他 パラメータ 3	$\ln(\phi_i^{(3)})$	0.2674 (0.8192)	-0.4592 (-2.4445)	-0.3064 (-1.7234)	-0.1991 (-0.8185)	-0.0641 (-0.5035)
その他 パラメータ 4	$\ln(\phi_i^{(4)})$	0.3510 (1.0591)	-0.2765 (-1.4232)	-0.2981 (-1.6399)	-0.2946 (-1.1948)	-0.0966 (-0.7588)
心的負荷閾値	$\ln(\gamma_{cum,i})$	<b>6.4149</b> (7.4312)	<b>7.0704</b> (13.8667)	<b>7.0309</b> (14.8397)	<b>7.0146</b> (10.9050)	<b>0.7162</b> (2.0967)
在庫金額閾値	$\ln(\gamma_{inv,i})$	<b>5.1256</b> (8.5623)	<b>4.6950</b> (13.3554)	<b>4.7220</b> (14.3504)	<b>4.7108</b> (10.5402)	0.3931 (1.6594)
心的負荷構成 パラメータ 1	$\alpha_i^{(1)}$	14.2748 (0.4483)	-27.9157 (-1.5136)	-19.9226 (-1.1374)	-0.0531 (-0.0023)	21.7405 (1.7772)
心的負荷構成 パラメータ 2	$\alpha_i^{(2)}$	-8.918 (-0.2321)	4.2112 (0.1910)	14.593 (0.6873)	-5.745 (-0.2009)	-10.0511 (-0.6763)

( ) 内数値は擬似 t-値

### 5.5.7 その他のパラメータの検証

本小節では、表 5.12 のその他パラメータの事後平均分布の基本統計量にもとづいて検証する。5.5.2 モデル評価で示した通り、心的負荷の逼迫した状態であるレジーム 1 とレジーム 4 に対しては、対数ロジスティック分布が、心的負荷が緩慢な状態であるレジーム 2 とレジーム 3 には、対数正規分布が採択された。正規分布はロジスティック分布よりも尖度は小さく、分布の裾野は狭いため、ロジスティック分布の方が急峻な変化を反映しやすい。

その性質を踏襲した対数ロジスティック分布が、レジーム 1 とレジーム 4 に採択されたのは、心的負荷が逼迫した状態において、消費者購買の急な変動に対応しやすいことを示唆する。同じ確率分布を有するレジーム 1 とレジーム 4 を比較しても、対数ロジスティック分布の尺度パラメータの平均値はレジーム 1の方が小さく、心的負荷が高まった状態で、さらに在庫金額が閾値を超えると、消費者の購買行動が変動しやすくなる傾向は高まる。一方、心的負荷が緩慢なレジーム 2 とレジーム 3 に対する対数正規分布の分散パラメータは、レジーム 2の方が小さく、心的負荷が緩慢な状態でも在庫金額が閾値を超えると、消費者の来店行動が変動しやすくなる。

表 5.12: 事後平均分布の基本統計量

区分	係数	平均値	中央値	最小値	最大値	標準偏差
(レジーム 1)	$\phi_i^{(1)}$	0.6458	0.6463	0.6764	0.6146	1.0231
(レジーム 2)	$\phi_i^{(2)}$	0.5789	0.5781	0.6081	0.5523	1.0234
(レジーム 3)	$\phi_i^{(3)}$	0.7635	0.7624	0.8038	0.7274	1.0248
(レジーム 4)	$\phi_i^{(4)}$	0.8145	0.8143	0.8611	0.7715	1.0280

### 5.5.8 拡張心理会計と世帯セグメントの来店間隔に関する考察

本小節では、レジームごとに推定された消費者世帯の来店行動について考察する。表 5.13 に示す通り、4つの全来店レジームを占有する消費者世帯の割合が最も多く、全体の 35%を占め、次いでレジーム 1,2,3 を占有する世帯セグメントが 29%，レジーム 2,3 およびレジーム 1,2 のように 2つのレジームのみを占有する世帯セグメントがそれぞれ 16%，12%であり、残りは他の 3つレジームを占有する世帯セグメントである。全体で 15 パターン存在するが、実際に存在するのは、そのうち 6 パターンのみで、レジーム単体で見ればレジーム 2、続いてレジーム 3 の占有率が高い。これらは、心的負荷が軽減された状況を表す。消費者の来店特性により、各レジームにおける購買機会の占有率は異なり、代表的消費者ではレジーム 2 が 52.0%，レジーム 3 が 30.7%と高く、心的負荷が緩慢な状態の割合が 80%以上を占める。レジーム 1 は 12.2%，レジーム 4 は最も低く 5.1%，心的負荷が逼迫した状態は全体の 20%以下である。

表 5.13: 占有レジームパターンごと購買機会の平均占有率

	レジーム 1	レジーム 2	レジーム 3	レジーム 4	全体割合率
レジーム 1, 2 のみ	25.8%	74.2%	-	-	12%
レジーム 2, 3 のみ	-	69.1%	30.9%	-	16%
レジーム 1, 2, 3	10.6%	73.3%	16.1%	-	29%
レジーム 1, 2, 4	43.4%	64.6%	-	1.0%	5%
レジーム 2, 3, 4	-	13.4%	82.7%	3.9%	3%
全 4 レジーム	12.5%	20.0%	53.0%	14.0%	35%
全体平均 (代表的消費者)	12.2%	52.0%	30.7%	5.1%	100%

心的負荷による圧力を常に受けていないレジーム 2,3 のみを占有する世帯セグメントに注目する。表 5.14 がこの世帯セグメントの来店反応特性の事後平均分布の基本統計量である。心的負荷閾値パラメータの値は、その他の世帯セグメントよりも高いことが分かる。心的負荷閾値は、在庫金額閾値パラメータと正の相関を有することから、在庫金額閾値パラメータも値は高くなる。そもそも心的負荷の影響を受けない高所得者セグメントであることを示唆する。次に、全レジームを占有するセグメントとレジーム 1,2,3 のみを占有するセグメントの反応特性を比較する。表 5.15 と表 5.16 に、それぞれの事後平均分布の基本統計量を示す。いずれの場合も、レジーム 1 で値引とチラシ、レジーム 2 では値引により来店間隔を縮小するように作用し、レジーム 3 における説明変数に対する来店効果の符号はすべて正である。全レジームを占有する世帯セグメントでは、レジーム 4 において値引が来店訴求を促す効果が加わるが、双方の世帯セグメントでは大きな反応特性に関する見られない。最後に、レジーム 1,2 のみを占有する世帯セグメントの事後平均分布の基本統計量を表 5.17 示す。多数を占める全レジーム占有セグメントおよびレジーム 1,2,3 占有セグメントの来店特性と比較すると、レジーム 2 では値引による来店訴求効果を示すものの、レジーム 1 ではマーケティング施策に対して無関心であることを示唆している。このことは、各世帯セグメントにおいて、4 つのうちどのレジームを主要レジームとして来店行動を起こしているかにも関連していると考えられる。レジーム 1,2 占有セグメントでは、レジーム 2 の占有率が 74.2% と高く、通常状態のレジームを形成しており、そこから外れたレジーム 1 では、そのセグメント特有の特性を示す。各世帯セグメントは、最も占有率の高いレジームを通常状態のレジームとして位置づけられるが、表 5.18 で例を挙げたように、各消費者世帯レベルでも同様である。このことは、それぞれの来店ハザードと関

連するため、以下にハザード関数特性と合わせて考察する。

表 5.14: レジーム 2,3 を占有する世帯の事後平均分布の基本統計量

区分	係数	平均値	中央値	最小値	最大値	標準偏差
(レジーム 1)	$\beta_{i,1}^{(1)}$	0.0101	0.0461	-0.3645	0.3414	0.1980
	$\beta_{i,2}^{(1)}$	0.0063	0.0219	-0.1867	0.2385	0.1221
	$\beta_{i,3}^{(1)}$	-0.0298	-0.0653	-0.2453	0.3406	0.1468
	$\beta_{i,4}^{(1)}$	-0.0840	-0.0789	-0.4446	0.4492	0.2391
	$\beta_{i,5}^{(1)}$	0.0224	-0.0059	-0.1178	0.1886	0.0873
(レジーム 2)	$\beta_{i,1}^{(2)}$	0.1190	0.1233	-0.2078	0.4808	0.1510
	$\beta_{i,2}^{(2)}$	0.0140	0.0036	-0.0012	0.1177	0.0292
	$\beta_{i,3}^{(2)}$	0.0159	0.0229	-0.3919	0.4468	0.1886
	$\beta_{i,4}^{(2)}$	0.0248	0.0300	-0.3696	0.2982	0.1799
	$\beta_{i,5}^{(2)}$	-0.0006	-0.0001	-0.0098	0.0020	0.0026
(レジーム 3)	$\beta_{i,1}^{(3)}$	0.0540	0.0950	-0.3364	0.3673	0.1818
	$\beta_{i,2}^{(3)}$	0.0494	0.0413	0.0088	0.1463	0.0361
	$\beta_{i,3}^{(3)}$	0.0858	0.0496	-0.2745	0.4350	0.1838
	$\beta_{i,4}^{(3)}$	0.0536	0.0391	-0.1325	0.2284	0.1125
	$\beta_{i,5}^{(3)}$	0.0160	-0.0001	-0.2364	0.2436	0.1039
(レジーム 4)	$\beta_{i,1}^{(4)}$	-0.0638	-0.0937	-0.3234	0.3010	0.1876
	$\beta_{i,2}^{(4)}$	0.0496	0.0337	-0.1176	0.2555	0.1090
	$\beta_{i,3}^{(4)}$	0.0554	0.0694	-0.3247	0.3229	0.1677
	$\beta_{i,4}^{(4)}$	-0.0261	-0.0282	-0.5113	0.4334	0.2296
	$\beta_{i,5}^{(4)}$	0.0181	0.0350	-0.2861	0.3257	0.1596
心的負荷閾値	$\gamma_{cum,i}$	54,900	52,697	22,752	113,581	22,271
在庫金額閾値	$\gamma_{inv,i}$	2,064	1,821	959	4,782	957

表 5.15: 全レジームを占有する世帯の事後平均分布の基本統計量

区分	係数	平均値	中央値	最小値	最大値	標準偏差
(レジーム 1)	$\beta_{i,1}^{(1)}$	0.0712	0.0825	-0.4666	0.4279	0.2296
	$\beta_{i,2}^{(1)}$	0.0129	0.0085	-0.1569	0.2193	0.0529
	$\beta_{i,3}^{(1)}$	0.0819	0.0041	-0.5163	0.5714	0.2570
	$\beta_{i,4}^{(1)}$	-0.0233	-0.0121	-0.6722	0.6819	0.3133
	$\beta_{i,5}^{(1)}$	-0.0013	0.0007	-0.0912	0.0365	0.0186
(レジーム 2)	$\beta_{i,1}^{(2)}$	0.0078	0.0122	-0.3960	0.5115	0.2209
	$\beta_{i,2}^{(2)}$	0.0349	0.0256	-0.0111	0.1929	0.0371
	$\beta_{i,3}^{(2)}$	0.0101	0.0210	-0.4288	0.4240	0.2157
	$\beta_{i,4}^{(2)}$	-0.0123	-0.0315	-0.4214	0.3948	0.1753
	$\beta_{i,5}^{(2)}$	0.0074	0.0000	-0.0633	0.3067	0.0545
(レジーム 3)	$\beta_{i,1}^{(3)}$	0.2130	0.2130	-0.1178	0.6266	0.2028
	$\beta_{i,2}^{(3)}$	0.0511	0.0416	-0.0009	0.2421	0.0486
	$\beta_{i,3}^{(3)}$	0.1708	0.1660	-0.2170	0.5145	0.2141
	$\beta_{i,4}^{(3)}$	0.0300	0.0115	-0.3222	0.6672	0.2440
	$\beta_{i,5}^{(3)}$	0.0017	0.0011	-0.0013	0.0191	0.0035
(レジーム 4)	$\beta_{i,1}^{(4)}$	0.0398	0.0548	-0.5167	0.5382	0.2171
	$\beta_{i,2}^{(4)}$	0.0581	0.0498	-0.0537	0.2262	0.0520
	$\beta_{i,3}^{(4)}$	-0.0255	-0.0116	-0.4765	0.5131	0.2255
	$\beta_{i,4}^{(4)}$	-0.0231	-0.0013	-0.6045	0.6347	0.2735
	$\beta_{i,5}^{(4)}$	0.0036	0.0023	-0.1065	0.1046	0.0273
心的負荷閾値	$\gamma_{cum,i}$	19,707	17,885	3,777	51,747	9,958
在庫金額閾値	$\gamma_{inv,i}$	1,004	904	37	2,089	504

表 5.16: レジーム 1,2,3 を占有する世帯の事後平均分布の基本統計量

区分	係数	平均値	中央値	最小値	最大値	標準偏差
(レジーム 1)	$\beta_{i,1}^{(1)}$	0.0965	0.1042	-0.2761	0.3973	0.1772
	$\beta_{i,2}^{(1)}$	0.0283	0.0289	-0.0563	0.1495	0.0384
	$\beta_{i,3}^{(1)}$	0.0492	0.0104	-0.3013	0.3574	0.1806
	$\beta_{i,4}^{(1)}$	-0.0539	-0.0692	-0.2940	0.2297	0.1376
	$\beta_{i,5}^{(1)}$	-0.0009	-0.0003	-0.1039	0.1040	0.0331
(レジーム 2)	$\beta_{i,1}^{(2)}$	0.1649	0.1306	-0.1040	0.6222	0.1576
	$\beta_{i,2}^{(2)}$	0.0085	0.0059	-0.0073	0.0391	0.0122
	$\beta_{i,3}^{(2)}$	0.1037	0.0520	-0.0617	0.4953	0.1413
	$\beta_{i,4}^{(2)}$	-0.0169	-0.0144	-0.3047	0.3748	0.1619
	$\beta_{i,5}^{(2)}$	0.0001	0.0000	-0.0024	0.0037	0.0012
(レジーム 3)	$\beta_{i,1}^{(3)}$	0.0965	0.1172	-0.3947	0.4490	0.1710
	$\beta_{i,2}^{(3)}$	0.0533	0.0395	-0.1808	0.4510	0.1233
	$\beta_{i,3}^{(3)}$	0.0111	-0.0117	-0.3638	0.2938	0.1629
	$\beta_{i,4}^{(3)}$	0.0603	0.0479	-0.1549	0.3558	0.1322
	$\beta_{i,5}^{(3)}$	0.0400	0.0026	-0.2774	0.3295	0.1303
(レジーム 4)	$\beta_{i,1}^{(4)}$	0.0279	0.0357	-0.3337	0.4914	0.2040
	$\beta_{i,2}^{(4)}$	-0.0030	0.0332	-0.3779	0.3410	0.1687
	$\beta_{i,3}^{(4)}$	-0.0186	0.0092	-0.5668	0.5470	0.1958
	$\beta_{i,4}^{(4)}$	0.0501	0.0611	-0.6937	0.5790	0.2018
	$\beta_{i,5}^{(4)}$	0.0234	-0.0248	-0.1822	0.3943	0.1519
心的負荷閾値	$\gamma_{cum,i}$	40,373	39,676	10,516	75,460	14,837
在庫金額閾値	$\gamma_{inv,i}$	1,717	1,686	406	3,491	601

表 5.17: レジーム 1,2 を占有する世帯の事後平均分布の基本統計量

区分	係数	平均値	中央値	最小値	最大値	標準偏差
(レジーム 1)	$\beta_{i,1}^{(1)}$	0.0278	-0.0233	-0.3376	0.6436	0.2914
	$\beta_{i,2}^{(1)}$	0.0261	0.0215	-0.0006	0.0694	0.0206
	$\beta_{i,3}^{(1)}$	-0.1169	-0.0704	-0.4828	0.1920	0.1975
	$\beta_{i,4}^{(1)}$	0.1833	0.0850	-0.0845	0.6697	0.2405
	$\beta_{i,5}^{(1)}$	0.0008	0.0005	-0.0072	0.0070	0.0034
(レジーム 2)	$\beta_{i,1}^{(2)}$	0.3199	0.3297	-0.0320	0.7312	0.1970
	$\beta_{i,2}^{(2)}$	0.0209	0.0148	-0.0039	0.0694	0.0204
	$\beta_{i,3}^{(2)}$	0.0626	0.1059	-0.1832	0.2841	0.1511
	$\beta_{i,4}^{(2)}$	-0.0746	-0.0771	-0.6109	0.2714	0.2441
	$\beta_{i,5}^{(2)}$	0.0024	0.0014	-0.0006	0.0067	0.0024
(レジーム 3)	$\beta_{i,1}^{(3)}$	-0.1342	-0.0903	-0.4781	0.1453	0.1700
	$\beta_{i,2}^{(3)}$	-0.0314	0.0349	-0.4015	0.2249	0.2101
	$\beta_{i,3}^{(3)}$	0.0184	0.0026	-0.3703	0.4713	0.2685
	$\beta_{i,4}^{(3)}$	0.0199	0.0447	-0.3914	0.4137	0.2212
	$\beta_{i,5}^{(3)}$	-0.0557	0.0156	-0.5365	0.1971	0.2327
(レジーム 4)	$\beta_{i,1}^{(4)}$	-0.1452	-0.0821	-0.6222	0.3317	0.2484
	$\beta_{i,2}^{(4)}$	0.0296	-0.0146	-0.3965	0.3284	0.2114
	$\beta_{i,3}^{(4)}$	0.0396	0.0134	-0.6051	0.6462	0.3570
	$\beta_{i,4}^{(4)}$	0.1020	0.0629	-0.3044	0.6615	0.308
	$\beta_{i,5}^{(4)}$	0.0110	-0.0086	-0.2830	0.1992	0.1403
心的負荷閾値	$\gamma_{cum,i}$	26,390	25,222	11,476	63,793	15,601
在庫金額閾値	$\gamma_{inv,i}$	1,285	1,247	622	2,362	483

本提案モデルの分布パラメータは、構造化されており、購買機会ごとの説明変数に応じて連続的に変動する。これに伴い、各購買レジームのハザード関数も変動し、一意に同定して検証することはできない。ここでは、全消費者世帯の回帰係数および説明変数の平均値から算出したハザードを代表的消費者のハザード関数とし、その他 14 世帯の個別消費者のハザード関数も同様に算出して議論する。表 5.18 に、代表的消費者およびその他個別消費者の各レジームの購買機会の占有率と閾値パラメータを示す。図 5.8 に、消費者 1 と 2、および代表的消費者のハザード関数を示す。消費者によって、ハザード特性にばらつきはあるものの、いずれのハザードも単峰で、前回購買機会からの経過時間とともに増加し、ピークに達すると減少する。中でも、レジーム 1 は経過日数とともに急激に上昇しており、

レジーム1で平均来店間隔が短くなるのと整合的である。レジーム1と3において、代表的消費者と消費者1および2のハザードはおよそ同様な特性を示しているが、レジーム2と4では異質性が大きく、消費者2はレジーム2でのピークは急峻で、消費者1のレジーム4でのハザードは緩慢である。図5.9には、購買機会がレジーム2と3に集中している消費者3および4のハザード関数を示す。これら消費者は、全ての購買機会で心的負荷が緩慢な状態にあり、心的負荷閾値も平均値より高い。心的負荷が緩慢な状況では、在庫金額が閾値を超えると、消費者の来店ハザードは変動し易くなる。図5.10は、購買機会がレジーム1と2に集中している消費者5と6のハザード関数を示す。これら消費者は、ほとんどの購買機会で在庫金額の高い状態にある。このとき、さらに心的負荷も高まると、消費者の来店間隔ハザードは変動し易くなる。図5.11には、レジーム3と4に購買機会が集中している消費者7と8のハザード関数を示す。これら消費者はほとんどの購買機会で在庫金額が低い状態にある。ちなみに、表5.4に見られる通り、レジーム4では、平均的には購買品の日用雑貨・加工食品の占める割合に対して世帯全体で係数の平均値は負であり、日用雑貨・加工食品の購買割合が高くなると、来店間隔は短くなることの表れとも考えられる。つまり、生鮮食品の購買割合が低くなると、来店間隔も短くなり、ハザードも変動し易い。最後に、購買機会がレジーム3または4いずれか一つのレジームに集中している消費者のハザード関数を図5.12に示す。いずれの場合も、ハザード関数は平均的消費者の特性と概ね等しい。このように、消費者の来店ハザードは心的状況によって変化する。消費者によって占有するレジームの割合は異なるが、購買機会がレジーム間を遷移するほどハザード関数も変動的となり、単一レジームに滞留するほどハザードは安定的である。この安定性は、各消費者ごとに推定される定常状態レジームと関連する。4レジームのうち最も占有率の高いレジームが、消費者の定常状態レジームであり、対応するレジームの来店ハザードが最も緩慢である。表5.18で占有率の最も高いレジームが各消費者の定常状態レジームに対応している。購買機会が複数のレジームに属する場合、在庫金額の高低に関わらず、心的負荷が増加すると、消費者の来店ハザードは高まる。在庫金額によって購買レジームが変化する場合、在庫金額の高い状態ほど来店間隔ハザードのピークは急峻である。また、在庫金額と心的負荷による購買間隔ハザードに対する影響度合いの相対比較では、心的負荷による消費者来店間隔への影響の方が支配的であることが分かる。

表 5.18: レジームごと購買機会の占有率と閾値パラメータ

	レジーム 1	レジーム 2	レジーム 3	レジーム 4	$\gamma_{inv,i}$ : 円	$\gamma_{cum,i}$ : 円
代表的消費者 : avg	12.2%	52.0%	30.7%	5.1%	1,459	32,735
消費者 1 : usr1	7.2%	33.7%	55.1%	4.0%	1,077	29,926
消費者 2 : usr2	12.7%	6.9%	53.9%	26.5%	351	17,885
消費者 3 : usr3	0.0%	13.8%	86.2%	0.0%	959	38,170
消費者 4 : usr4	0.0%	39.9%	60.1%	0.0%	1,220	35,521
消費者 5 : usr5	48.5%	51.0%	0.0%	0.5%	1,898	22,659
消費者 6 : usr6	46.8%	53.2%	0.0%	0.0%	1,358	11,476
消費者 7 : usr7	0.6%	0.6%	66.7%	32.1%	780	18,427
消費者 8 : usr8	0.4%	2.3%	82.4%	14.9%	1,798	33,344
消費者 9 : usr9	3.3%	96.7%	0.0%	0.0%	1,690	45,101
消費者 10 : usr10	2.9%	96.7%	0.4%	0.0%	1,722	42,917
消費者 11 : usr11	1.8%	98.2%	0.0%	0.0%	2,363	63,793
消費者 12 : usr12	0.0%	14.0%	86.0%	0.0%	997	22,752
消費者 13 : usr13	0.0%	10.5%	87.4%	2.1%	527	15,092
消費者 14 : usr14	0.6%	6.5%	91.7%	1.2%	1,924	34,137

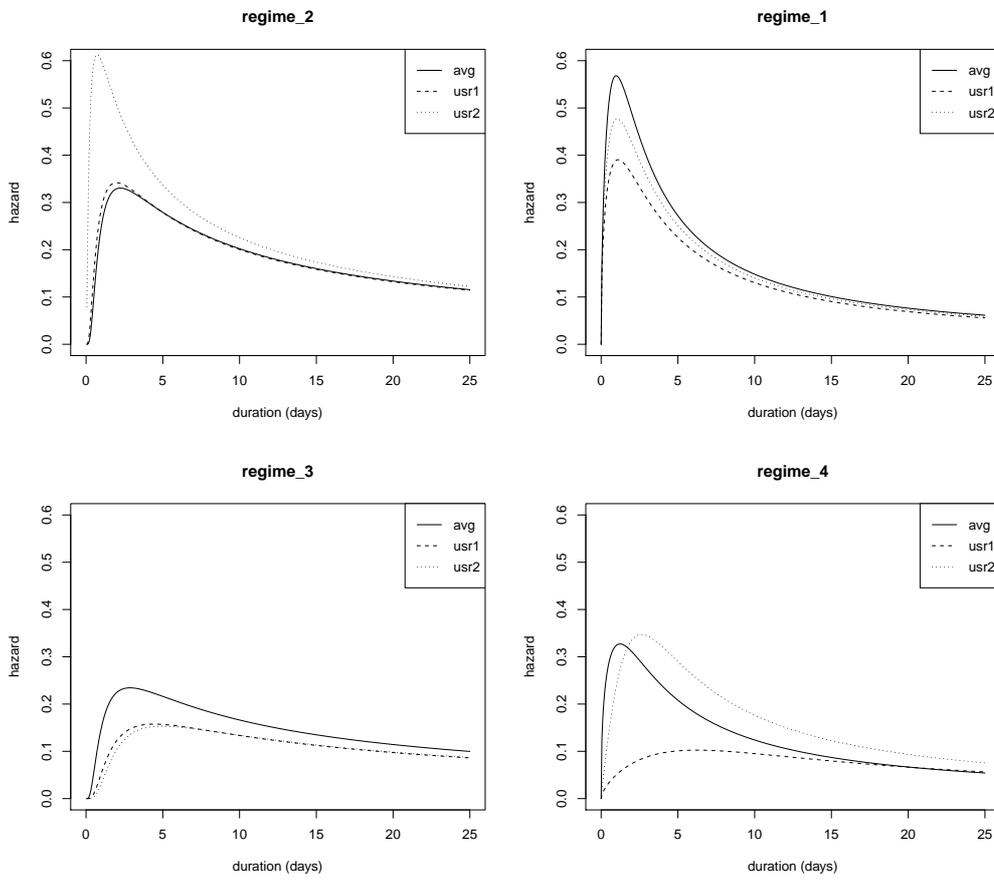


図 5.8: 4つの来店レジームを占有するハザード関数

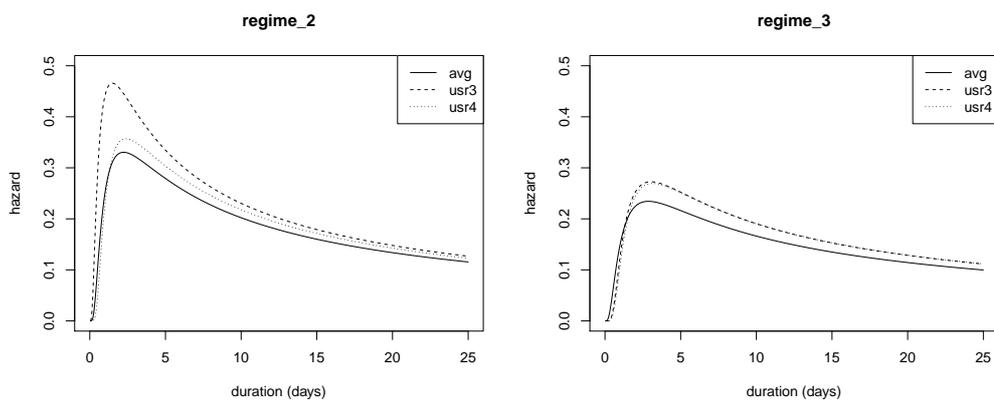


図 5.9: 来店レジーム 2 と 3 に集中するハザード関数

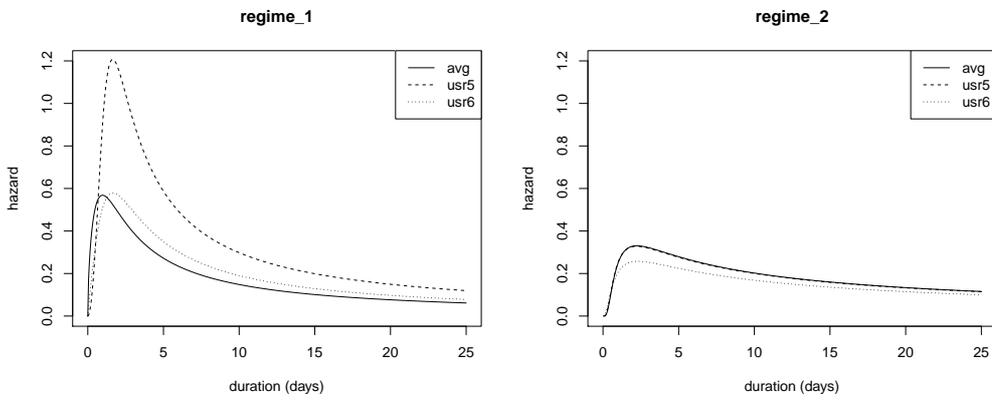


図 5.10: 来店レジーム 1 と 2 に集中するハザード関数

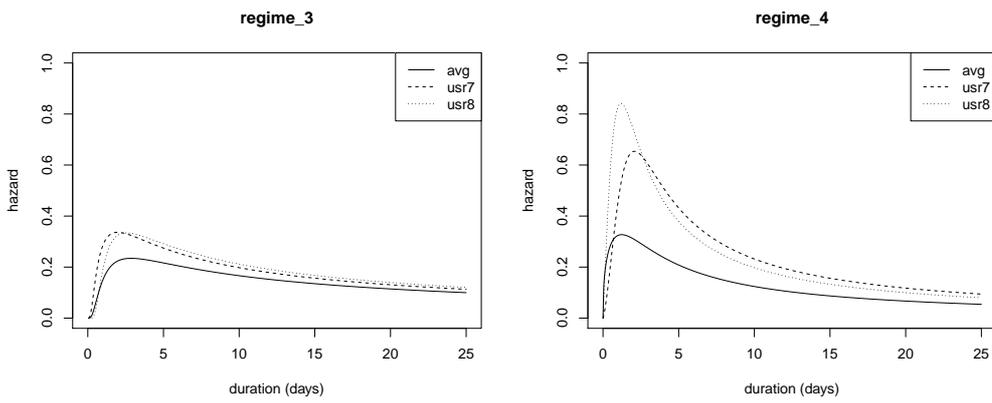


図 5.11: 来店レジーム 3 と 4 に集中するハザード関数

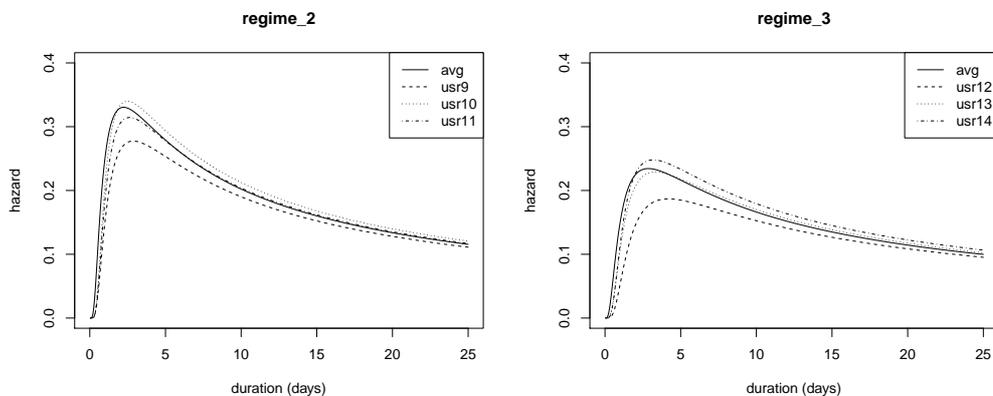


図 5.12: 単一の来店レジームに集中するハザード関数

## 5.6 まとめ

本研究では、消費者の置かれている心的状況を考慮しながら、心的負荷および在庫金額による4つの来店レジームを仮定して、消費者の来店間隔をモデル化した。行動経済学では、心理会計という概念で、消費者の心的状況が消費者行動に影響を与えると論じているが、本モデルでは心的負荷および在庫金額を用いて、この概念を明示的に組み込んだ。小売店舗のID-POSデータを用いた実証分析では、異なる4つの購買レジームの回帰パラメータと切換点を消費者ごとに推定した。その結果、心的負荷が逼迫した状況ではマーケティング施策は効きにくい、在庫金額が高くなり閾値を超えると、マーケティング施策は効果的となる示唆を得た。また、累積購買金額が増加し、心的負荷の高い状況では、消費者の来店間隔は短い。この消費者行動は、一見すると合理的ではないと思われるかもしれない。累積購買金額が増加して心的負荷が高まると、購買は抑えられ、来店間隔は長くなるであろうと考えるからだ。しかし、実際には、消費者は必要なものをこまめに購買するようになり、さらに同一商品でも徳用サイズよりは小分けされたパック商品を好み、結果として来店間隔は短くなる。モデルの確率分布に関しては、心的負荷が逼迫した状況では対数ロジスティック分布を、余裕のある場合には対数正規分布を仮定したモデルが採択され、ワイブル分布はどのレジームにも採択されていない。消費者の来店ハザードは、単調増加または単調減少で表すには限界があり、その形状は単峰であることに起因する。対数ロジスティック分布の裾野は狭く、心的負荷が逼迫した状況では消費者は来店しやすいことを反

映する。心的負荷と在庫金額、および閾値は消費者ごとに異なり、それらに従いレジーム分けされた各購買機会の占有率も異質である。購買機会が複数の購買レジームに属する場合、特定のレジームで来店ハザードが大きく変化するため、マーケティングの観点からは、消費者ごとに変動ポイントを捉えた施策を実施することが望まれる。一方、単一レジームに留まる消費者も存在し、この場合の来店間隔ハザードは安定的で大きな変化は見られない。これら消費者の来店間隔ではランダム性が増加するため、それぞれのマーケティング反応特性に合わせた施策が効果的となる。このように、消費者の心的状況を考慮しながらモデリングすることで、合理的な経済主体を前提とせず、よりフレキシブルな消費行動の理解が可能となる。今後マーケティングが高度化されるにともない、単に ID-POS データなどの観測されたハードファクトデータのみにもとづくマーケティングだけでなく、消費者の置かれた心理的状況の代理変数である心的負荷や在庫金額などのソフトファクターを取込んだマーケティングモデリングの活用が期待される。ただし、心的負荷で推定している構成パラメータの解釈には限界があることは、3.6 で注記した通りである。

本研究に関して、4つの限界が存在する。まずは、商品構成の詳細が記述されないため、消費者の心理的状況の変化により、商品の代替や同じ商品でも個数の異なるパッケージへの買い替えが捉えられないことである。不可欠品を単品で購買することや廉価な代替品（例えば、牛肉ではなく鶏肉、ビールではなく発泡酒など）へのスイッチングは、想定される購買行動の変化ではあるが、このような変化を本モデルでは捉えられない。次に、消費者ごとに異なるモデルの確率分布の推定が出来ない点である。本モデルでは、各購買レジームにワイブル分布、対数正規分布、対数ロジスティック分布のいずれかを仮定し、対数周辺尤度にもとづいて最適な確率分布の組み合わせを選定した。一方、本モデルの分布パラメータを消費者ごとに異質なパラメータとして推定したように、モデルの確率分布も消費者ごとに異質であると仮定することは自然な考え方である。しかし、消費者ごとに異なる確率分布の全組み合わせを評価することは現実的ではない。消費者レベルの確率分布までを同時に推定できるようなモデル手法の開発は今後の課題とする。もう一つは、本モデルでは心的影響要因として、心的負荷と在庫金額の2つの潜在変数を仮定したが、これら要因以外の心理的影響が存在する場合には、推定量の一致性が満たされないことである。また、本研究では、消費者世帯の収入は、毎月の給与所得を前提としているが、年に1または2回の賞与が支給されることも多い。このような臨時的に得られる収入に対する影響は、本モデルでは考慮されていないため、留意しておくべき事項である。最後に、本研究で用い

た ID-POS データは、1つの店舗による消費者の購買履歴であり、複数店舗を買い回る消費者行動を捉えるには限界がある。本分析データでは、消費者の来店を店舗における購買の有無で判断している。スーパーマーケットでは、来店したが何も購入しないことは、通常あまり考えられないが、他の小売店で買い回る行動はあり得る。このような状況を出来るだけ排除するように、データサンプルを集出しているが、買い回りの行動については完全にはカバーされていない。複数店舗を考慮した ID-POS 分析は今後の課題としたい。

## 第6章 結論

### 6.1 本研究の結論

本章では、本研究の結論を示す。まず、第3章、第4章、第5章で記述した各研究テーマの結論を整理する。さらに、これら3つのテーマを統合的に解釈し、実務で想定される本研究の成果の活用方法についても触れる。

#### 6.1.1 各研究テーマの結論

本研究は、小売業における心理会計の消費者行動に対する影響メカニズムを解明することを目的とした。特定商品のブランド選択や購買間隔という消費財メーカーの視点ではなく、小売業の観点から消費者行動を捉えるため、ここでの消費者行動は、各消費者の来店間隔および購買機会あたり購買点数である。これら消費者行動に対する心理会計の影響を、小売業店舗における消費者の購買履歴データを用いて表し、新たな消費者行動モデルの枠組みを構築した。この枠組みを利用し、これまで先例のない、ID-POS データを活用した心理会計と消費者行動の関連性の解明を試みた。まずは、3つの研究テーマの基盤となる、取支バランスの圧力から受ける心理的影響要因として、給料日からの累積購買金額を心的負荷モデルとして定式化した。この心的負荷モデルと購買点数モデルを組み合わせ、本枠組みの検証と購買点数との関連性を解明した。家庭内在庫バランスの圧力から受ける心理的影響要因に在庫金額を加えて、心的影響要因を二次元に拡張した。4つの各レジームに確率分布の異質性を取込み、来店間隔に対して実証した。また、心的負荷の直接効果についても同様に実証分析を行った。

研究テーマ1（第3章）では、ポアソン回帰モデルに心的負荷モデルを組合せて、心理会計と購買点数の関連性を表すモデルを構築し、ID-POS データを用いて実証した。消費者ごとに異なる購買レジーム特性と切換点を推定し、心的状況によって同一消費者でも異なる購買反応を有することを示した。また、心的負荷モデルの構成係数から、各消費者世

帯の給料日も推定可能なことを示した。推定結果にもとづくと、消費者は心的負荷が逼迫した状態では、マーケティング施策に対する消費者反応は鈍くなり、当座のニーズを充たす意識が強く、購買点数の増加傾向が高まる。これは、小分けや少量パックなどの商品の購買が多くなるためだと考えられる。さらに、このときの来店間隔は短くなる。世帯における給与所得者数の違いにより世帯をセグメント化して分析したところ、給与所得者が複数いる世帯の方が、心理会計の影響を強く受け、購買レジーム間で消費者反応の差が大きい。このことは、購買レジームの切り換え頻度に関する。複数の給与所得者を有する世帯では、切り換え頻度は高く、心的負荷からの圧力を意識しやすくなり、消費者反応も敏感となるという消費者に関する新しい知見を得た。

研究テーマ2（第4章）では、研究テーマ1で構築した心的負荷モデルを来店間隔に適用し、心理会計の来店間隔に対する直接効果の影響を含めて、ID-POS データを用いて検証した。推定結果にもとづけば、心的負荷に無関係な世帯セグメントが存在する中、心的負荷による来店間隔への直接効果は、符号は負であり、心的負荷が高まると来店間隔は短くなるように作用する。心的負荷が高まると、マーケティング施策に対する反応が鈍くなり、必要なものを必要な時に購買するといった近視眼的な計画購買の傾向が高まり、来店間隔が短くなる。このとき、確率分布の位置および分散パラメータの値が双方小さくなり、来店間隔は縮退し、瞬時的な来店確率も高まる傾向を示す。また、心的負荷の直接効果と閾値パラメータの関連性を検証したところ、負の相関を示し、閾値が低い消費者ほど心的負荷による直接効果の影響は大きくなるという新たな関係性を得た。

研究テーマ3（第5章）では、心的指標として在庫金額を加え、消費者の心的影響要因を二次元に拡張し、来店間隔について ID-POS データで実証した。消費者ごとに異なる4つの来店レジーム特性と切り換え点を推定し、心的状況によって同一消費者でも異なる来店反応とハザードを有することを示した。また、各レジーム内で同質的に仮定した3つの確率密度分布(ワイブル分布, 対数正規分布, 対数ロジスティック分布)を評価したところ、心的負荷の高い状態では対数ロジスティック分布が、低い状態では対数正規分布が採択された。同じ心的負荷の状態では、在庫金額に変動が生じても確率分布には影響しない。消費者の来店ハザードが、単調増加または単調減少ではなく、単峰であることから、ワイブル分布は採択されない。実証分析の結果にもとづけば、すべての消費者が必ず4つのレジームに来店機会を有するわけではなく、消費者によっては2または3レジームに滞留する場合もある。レジーム間の遷移が頻繁なほど、レジームごとの消費者反応の差が大きい。複

数レジームに購買機会を有する場合、同一消費者の来店ハザードで比較すると、心的負荷および在庫金額の高いレジームの方が、来店ハザードのピークは高く、来店行動が活性化されていることを示唆する知見を得た。

### 6.1.2 3つの研究テーマの統合的解釈

本研究で取り組んだ、3つの研究テーマの検証結果にもとづいて、小売業における心理会計の消費者行動に対する影響メカニズムの統合的解釈を述べる。収支バランスの圧力に起因する心的負荷および家庭内在庫バランスからの圧力による在庫金額を、心理的影響因子とした心理会計モデルを消費者行動モデルと組合せて、これらの関連性を検証した。本枠組みを用いることで、消費者ごとの切換点閾値、購買機会占有率、世帯給与所得者数などの新しい分析切り口を得た。心的負荷が高まり、切換点閾値を超えると、購買点数は微増し、来店間隔は短くなる傾向を示す。この場合、消費者の購買行動は近視眼的となり、必要なものを必要な時に購買行動を起こす傾向が高まり、計画購買率は増加する傾向にある。在庫金額に関しても同様で、在庫量が閾値以上のレベルのある場合、購買点数は微増かつ来店間隔は短くなる傾向がある。しかしながら、チラシに関するマーケティング変数に対する反応は、心的負荷が逼迫した状況では鈍感となるが、在庫金額が十分な状況では敏感となる。伝統的経済学の観点からは、消費者の心的状況に関わらず、自身の効用を最大化するために、反応には差が出ないはずであるが、心理会計のものとは差が生じる。また、心的負荷と在庫金額を同時に考慮した場合、心的負荷による影響の方が支配的である。心的負荷による来店間隔への直接的影響としては、ほとんどの消費者で負の相関を有し、心的負荷が高まるほど来店間隔は短くなる傾向がある。直接効果の影響度合いは、心的負荷が逼迫した状況の方が、それが緩慢な場合よりも高い。このことは、プロスペクト理論が示す、消費者はネガティブな状況ほど敏感であるというのと整合的である。また、レジーム間で占有率のばらつきが大きいほど、世帯あたり給与所得者数が多いほど、心理会計による消費者行動のギャップは大きくなる。消費者は心理的影響要因で振り分けられるレジーム間を頻繁に遷移するほど、レジーム間のギャップは増大するということを意味する。この解釈として、消費者は心的負荷の閾値（プロスペクト理論の参照点に相当）近傍を前後することで、心的状況の変化を意識するようになり、購買行動に反映されやすくなることを示唆する。全ての消費者がレジーム間を常に遷移しているとは限らず、消費者ごとに滞留しやすいレジームを有する。この定常状態レジームから別のレジームへ遷移する際に、

一見非合理的とも思えるような消費行動が生じやすい。本研究では、消費者の購買行動が心理会計の影響を受けて変化することを実証した。実際に、消費者が購買または来店行動レジーム上を遷移するように仕向けることは、マーケティング施策としてある程度可能である。各消費者の特性に合致したマーケティングを実施することで、小売業に対して効果的な活動をプランすることができる。

本研究の成果を実務に応用して、来店あたり購買点数を向上させ、各消費者の来店間隔を縮小させることを考える。ID-POS データにもとづいて、各消費者世帯の心的負荷および在庫金額を推定し、購買機会ごとにこれら指標を更新し、消費者ごとの心的状況が把握できる。消費者との接点は、全消費者で共通のチラシと店舗内でのディスプレイ、および各消費者へのダイレクトメールなどであるが、心的負荷に余裕がある場合には、値引きが効果的であるため、値引き商品を告知するメッセージを発信する。一方、心的負荷が逼迫した状態では、値引きよりも少量または小分けされたような商品のバラエティを増やしたメッセージを発信する。店舗では、様々な心的状況にある消費者が混在するため、店内では各々に向けた施策をすることは難しい。そこで、通常商品、値引き商品、小分け商品が分かるよう、明確なディスプレイ戦略を思案する。チラシ構成もディスプレイ戦略と同様に、値引き商品と小分け商品を織り交ぜて発行する。また、当日来店する消費者の心的負荷および在庫金額を予測し、小分け商品の種類や陳列方法を時間帯などで変化させることも効果的だと考えられる。さらに、時点ごとに消費者の属するレジームに応じたマーケティング戦略をダイナミックに変化させ、小売店舗全体で安定的に売り上げが維持するような運営も将来的には可能であろう。例えば、値引をあまり実施しなくても売れる状況であれば、値引率を調整して下げたり、全体的に売上が期待できない状況であれば、チラシや値引を強化することで、安定的な売上を確保できる。これは、価格戦略と併せてダイナミックプライシングにもつながる。

## 6.2 本研究の学術的貢献

本研究の主要な学術的貢献は以下の4つにまとめられる。

### ■ 1. 心理的影響要因の構造モデリングの提案と検証

本研究では、心理会計の消費者行動に対する影響を、心的負荷という新たな概念で表し、心的状況に応じた消費者行動が ID-POS データを用いてモデル化できることを示した。心

理会計を定量的に扱い、消費者レベルでモデル化したのは、本研究が初めてであり、ID-POS データに消費者の心的状況という潜在情報を取込んだ分析の枠組みを提供した。これにより、消費者は自己の効用を最大化するよう意思決定するという伝統的経済学の基本原理に反する行動も説明できるようになり、小売業における消費者行動の理解を深めるのに貢献した。また、本モデルにより、消費者ごとの給料日推定も可能となり、通常取得できない消費者属性の推定方法を示した。さらに、本モデリングの枠組みは、家庭内在庫など他の潜在指標により多次元化が可能であり、消費者の心的状況を多面的に区分し、異なる消費者反応を検証することができた。

#### ■ 2. 心理会計の消費者異質性の検証

従来から利用されている階層ベイズの枠組みに、心的負荷モデルを組み合わせることで、消費者の心的状況に対応した消費者反応の異質性を推定することが可能となった。また、心的負荷モデルの枠組みを利用することで、収支バランスの圧力からの逼迫度という消費者レベルの心的状況を軸とした、新しい消費者セグメンテーションの視点を導入することができた。同様に、心的負荷モデルから推定される世帯あたりの給与所得者数にもとづく世帯セグメンテーション、心的状況の切換点レベルによる消費者セグメンテーション、心的状況で振り分けられたレジームの占有率による消費者セグメンテーションなど、これまでにない新しい消費者理解のための切り口が提示できた。

#### ■ 3. 心理会計と消費者購買点数の関連性の検証

従来の購買点数モデルでは、ポアソン回帰モデルのレートパラメータに構造を導入することで、消費者異質性を表した。本研究では、従来の枠組みに、心的負荷モデルを組み合わせることで、心理会計と消費者購買点数の関連性を実証するための新しいモデリング方を提案した。これにより、消費者ごとの購買点数と心理会計の関連性を、初めて定量的に検証することが可能となった。これまでの心理会計に関する実証分析は、調査データを用いた定点評価によるものがほとんどで、ID-POS データを活用した実証を行ったのは本研究が初めてである。また、調査データによる定点分析とは異なり、心的負荷モデルにより支出バランスの圧力が構造化されているため、将来の異なる状況に対する予測モデルとしても活用が可能であることは、本研究による学術的貢献に値するところである。

#### ■ 4. 心理会計と消費者来店間隔の関連性の検証

来店間隔を扱う時点間隔モデルでは、比例ハザードモデル、加法リスクハザードモデル、

加速故障モデルなど、時点間隔を表す確率分布に応じて、多様な枠組みが議論されているものの、明確な結論には至っていない。これらモデルの主眼である、消費者異質性と共変量効果に関しては、確率分布のパラメータを構造化することで取り込むのが通常の手法である。本研究では、これら枠組みに、心的負荷モデルを組み合わせることで、心理会計と消費者来店間隔の関連性を実証するための新しいモデリング方式を提案した。また、時点間隔の確率分布について、心理会計と関連して算出した来店レジームのそれぞれに、ワイブル分布、対数正規分布、対数ロジスティック分布を仮定して評価したところ、心的負荷が逼迫した状態では対数ロジスティック分布、緩慢な状態では対数正規分布が採択され、レジームごとに確率分布も異なるという新しい知見を得た。さらに、心的負荷の直接効果は、そもそも心的負荷に反応しにくい世帯セグメントが存在するものの、心的負荷が逼迫した状況で来店間隔には負に作用することを検証した。また、購買点数モデルと同様に、来店間隔モデルも、調査データによる定点分析とは異なり、将来の異なる状況に対する予測モデルとしても活用が可能であることは、本研究による学術的貢献に値するところである。

### 6.3 本研究で残された課題

本研究で残された課題は以下の通り大別して3点ある。

#### ■ 1. 心的負荷のキャリーオーバー効果を考慮した構造化モデリング

宮津・佐藤(2015)は、ID-POS データを用いて、消費者の心的状況を心的負荷という新しい概念でモデル化した。心的負荷モデルは、各消費者の給料日を起点とした累積購買金額として表す。毎月の給料日ごとに累積購買金額はリセットされ、ゼロとなることを前提にモデル化された。通常、スーパーマーケットなどの小売店舗における毎月の購買金額には、大きな増減は見られないものの、翌月に対する心的負荷のキャリーオーバー効果を考慮することで、心的負荷モデルの高度化が期待できる。支出過多である月の翌月は、給料日直後の心的負荷はゼロではなく、キャリーオーバー分先取りされ、正の値から始まる。逆に、出費を抑えた月の翌月は、給料日直前でも比較的余裕があり、その分を持ち越して、心的負荷が負の値から始まるといった効果を取込むことが考えられる。さらに、本研究の心的負荷モデルは、累積購買金額の線形モデルとして構築されているが、金融経済学で仮定する効用関数は、収穫逦減特性を呈する非線形モデルであることが多い。心的負荷モデルにも、消費者の知覚効果を非線形に表すことで、消費者の心的影響を効果的に捉えることも

可能であろう。このように、心的負荷モデルの高度化のための改善は、今後の取り組むべき課題である。

## ■ 2. クレジットカードやプリペイドカードを利用する場合の心的負荷モデリング

心的負荷モデルに関連した、もう一つの課題は、現金以外で支払う場合に心的負荷をどのように扱うべきかという問題である。消費者購買と同時に実効的な支出が生じないクレジットカード決済のような場合、収支バランスの圧力という観点からは、心的負荷の上昇が異なる特性を有するのは、Soster et al. (2010) が異時点間の心理会計について実証した通りである。実際のクレジットカード決済の場合、少額のサインレス決済の場合を除き、支払い承認と消費者の署名を行い、購買に伴う支出の認識はある。しかしながら、このような異時点間の心理会計に関して、通常心理会計とは異なる考慮が必要とされる。また、プリペイドカード支払いの場合、決済承認や支払い確認のための署名等も必要ない。少額の場合は、金額表示さえもなく決済されることさえある。このように、消費者購買に対しての支払い手段に応じて、心的負荷の構成パラメータの重みも異なることが考えられる。特に、本研究で構築した心的負荷モデルをオンラインショッピングに適用する場合、支払い手段はクレジットカードやプリペイドカードによる電子決済となるため、実証分析の際には、この点に注意する必要がある。現金以外の支払いにおける心的負荷モデルを拡張することは、今後取り組むべき課題として挙げられる。

## ■ 3. 同一レジームにおける確率分布の消費者異質性モデリング

宮津・佐藤 (2019) は、消費者ごとに心的負荷および在庫金額と二つ閾値で分けられるレジームに対して異なる確率分布を与えて実証した。ただし、確率分布はレジーム固有のものとして、消費者間で同質であると仮定している。しかしながら、消費者異質性の観点から、同一レジームでも消費者が異なれば、確率分布も異質であるとするのは、ごく自然な考え方である。本研究の3つ目の課題として挙げるのは、同一レジームに対する確率分布の消費者異質性モデルの構築である。非集計データを用いた購買点数モデルの場合、ポアソン分布を仮定する以外に選択肢はほとんどないが、来店間隔モデルでは、確率分布には複数の分布が選択可能である。消費者によっては、その来店行動が全くの無記憶で指数分布の特性を示すものもあるかも知れない。また、ある条件の下では、単調増加または単調減少の来店ハザードを有する消費者も中には存在するかもしれない。このように、各レジームの確率分布の消費者異質性を推定することは、消費者をより深く理解するためには必須であり、今後の課題として解明したい。

## 謝辞

本論文は、筆者が筑波大学大学院ビジネス科学研究科企業科学専攻博士後期課程に在学中の成果をまとめたものである。同大学ビジネスサイエンス系教授佐藤忠彦先生には主指導教員としてご指導いただいた。途中であきらめることなく本研究を完遂させることができたのは佐藤先生による終始親身なご指導の賜物であり、ここに深く感謝の意を表す。同ビジネスサイエンス系教授西尾チヅル先生、並びに、同ビジネスサイエンス系教授牧本直樹先生には副指導教員として多くのご助言を頂戴するとともに本論文の細部にわたってご指導をいただいた。ここに感謝申し上げたい。また、前・統計数理研究所所長樋口知之先生（現在、中央大学理工学部教授）、東北大学教授照井伸彦先生、東京大学教授阿部誠先生、慶応義塾大学教授中妻照雄先生、慶応義塾大学教授星野崇宏先生、筑波大学准教授伴正隆先生、法政大学准教授長谷川翔平先生、メリーランド大学教授 P.K.Kannan 先生からは、学会やワークショップなど様々な場面において本研究に関する大変有益なご助言をいただいた。ここに深く御礼を申し上げる。

令和元年六月

宮津 和弘

## 参考文献

- Aalen, O. (1978), "Nonparametric Inference for a Family of Counting Processes," *The Annals of Statistics*, 6 (4), pp.701-726.
- Allenby, G.M., Leone, R.P., and Jen, L. (1999). "A Dynamic Model of Purchase Timing with Application to Direct Marketing," *Journal of the American of Statistical Association*, 94 (446), pp.365-347.
- Barberis, N. and Huang, M. (2001). "Mental Accounting, Loss Aversion, and Individual Stock Returns," *The Journal of Finance*, 56 (4), pp.1247-1292.
- Benartzi, S. and Thaler, R.H. (1999). "risk Aversion or Myopia? Choices in Repeated Gambles and Retirement Investments," *Management Science*, 45 (3), pp.364-381.
- Bermudez, L. and Karlis, D. (2011). "Bayesian Multivariate Poisson Models for Insurance Ratemaking," *Mathematics and Economics*, 48 (2), pp.226-236.
- Brentnall, A.R., Crowder, M.J. and Hand, D.J. (2010). "Likelihood-ratio Changepoint Features for Consumer-behaviour Models," *Journal of the Operational Research Society*, 61 (3), pp.462-472.
- Brentnall, A.R., Crowder, M.J. and Hand, D.J. (2008). "A Statistical Model for the Temporal Pattern of Individual Automated Teller Machine Withdrawals," *Appl. Statist*, 57 (1), pp.43-59.
- Brockett, P.L., Golden L.L. and Panjer, H.H. (1996). "Flexible Purchase Frequency Modeling," *Journal of Marketing Research*, 33 (1), pp.94-107.
- Bronnenberg, B.J., Rossi, P.E. and Vilcassim, N.J. (2005). "Structural Medeling and Policy Simulation," *Journal of Marketing Research*, 42 (1), pp.22-26.
- Bucklin, R.E. and Lattin, J.M. (1991). "A Two-stage Model of Purchase Incidence and Brand Choice," *Marketing Science*, 10 (1), pp.24-39
- Bruda, M., Harding, M. and Hausman, J. (2012). "A Poisson Mixture Model of Discrete Choice," *Journal of Econometrics*, 166 (2), pp.184-203.
- Cameron, A.C. and Trivedi, P.K. (1986). "Econometric Models Based on Count Data: Com-

parisons and Applications of Some estimators and Tests,” *Journal of Applied econometrics*, 1 (1), pp.29-53.

Carlin, B.P., Gelfand, A.E. and Smith, A.F.M. (1992). “Hierarchical Bayesian Analysis of Change-point Problems,” *Appl. Statist.*, 41 (2), pp.389-405.

Chatfield, C., Ehrenberg A.S.C. and Goodhardt, G.J. (1966). “Progress on a simplified Model of Stationary Purchasing Behaviour,” Discussion Paper Part 3.

Chen, J. and Gupta, A.K. (2010). *Parametric Statistical Change Point Analysis with Applications to Genetics, Medicine, and Finance*, Birkh’user

Chen, C.W.S. and Lee, J.C. (1995). “Bayesian Inference of Threshold Autoregressive Models,” *Journal of Time Series Analysis*, 16 (5), pp.483-492.

Chin Choy, J.H. and Broemeling, L.D. (1980). “Some Bayesian Inferences for a Changing Linear Model,” *Technometrics*, 22 (1), pp.71-78.

Chintagunta, P., Erdem, T., Rossi, P.E. and Wedel, M. (2006). “Structural Modeling in Marketing: Review and Assessment,” *Marketing Science*, 25 (6), pp.604-614.

Chintagunta, P. and Prasad, A. (1998). “An Empirical Investigation of the “Dynamic McFadden” Model of Purchase Timing and Brand Choice: Implications for Market Structure,” *Journal of Business & Economic Statistics*, 16 (1), pp.2-12.

Cooil, B. (1991). “Using Medical Malpractice Data to Predict the Frequency of Claims: A Study of Poisson Process Models with Random Effects,” *Journal of the American Statistical Association*, 86 (414), pp.285-295.

Cox, D.R. (1972). “Regression Models and Life-tables,” *Journal of the Royal Statistical Society*, 43 (2), pp.187-220.

Dippold, K. and Hruschka, H. (2013). “A Parsimonious Multivariate Poisson Model for Market Basket Analysis,” *Review Management Science*, 7 (4), pp.393-415.

Ehrenberg, A.S.C. (1959). “The Pattern of Consumer Purchases,” *Journal of the Royal Statistical Society*, 8 (1), pp.26-41.

Erat, S. and Bhaskaran, S.R. (2012). “Consumer Mental Account and Implications to Selling Base Products and Add-ons,” *Marketing Science*, 31 (3), pp.801-818.

Erdem, T., Amaldoss, W., Che, H., Hutchinson, W., Katz, M., Keane, M., Meyer, R. and Reiss, P. (2005). “Theory-driven Choice Models,” *Marketing Letters*, 14 (3/4), pp.225-237.

- Ferreira, P. (1975). "A Bayesian Analysis of a Switching Regression Model: Known Number of Regimes," *Journal of the American Statistical Association*, 70 (350), pp.370-374.
- Fader, P., Hardie, B.G.S. and Huang C-Y. (2004). "A dynamic Change-point Model for New Product Sales Forecasting," *Marketing Science*, 23 (1), pp.50-65.
- Fong, D.K.H. and DeSarbo, W.S. (2007). "A Bayesian Methodology for Simultaneously Detecting and Estimating Regime Change Points and Variable Selection in Multiple Regression Models," *Quant. Market Econ.*, 5 (4), pp.427-453.
- George, E.I. and McCulloch, R.E. (1993). "Variable Selection via Gibbs Sampling," *Journal of the American Statistical Association*, 88 (423), pp.881-889.
- Geweke, J. and Terui, N. (1993). "Bayesian Threshold Autoregressive Models for Nonlinear Time Series," *Journal of Time Series Analysis*, 14 (5), pp.441-454.
- Gordon, K. and Smith, A.F. (1990). "Modeling and Monitoring Biomedical Time Series," *Journal of the American Statistical Association*, 85 (410), pp.328-337.
- Gonul, F. and Srinivasan, K. (1996). "Estimating the Impact of Consumer Expectations of Coupons on Purchase Behavior: A Dynamic Structural Model," *Marketing Science*, 15 (3), pp.262-279.
- Gonul, F. and Srinivasan, K. (1993). "Consumer Purchase Behavior in a Frequently Bought Product Category: Estimation Issues and Managerial Insights from a Hazard Function Model with Heterogeneity," *Journal of the American Statistical Association*, 88 (424), pp. 1219-1227.
- Gratton, L. and Scott, A. (2011). *The Shift: The Future of work Is Already Here*, Parpercollins Pub Ltd. 『ライフシフト (100年時代の人生戦略)』(訳)池村千秋, 東洋経済.
- Greene, W. (1998). "Sample Selection in Credit-scoring Models," *Japan and the World Economy*, 10 (3), pp.299-316.
- Grinblatt, M. and Han, B. (2005). "Prospect Theory, Mental Accounting and Momentum," *Journal of Financial economics*, 78 (2), pp.311-339.
- Gupta, S. and Cooper, L.G. (1992). "The Discounting of Discounts and Promotion Threshold," *Journal of Consumer Research*, 19 (3), pp.401-411,
- Gupta, S. (1991), "Stochastic Models of Interpurchase Time with Time-dependent Covariates," *Journal of Marketing Research*, 28 (1), pp.1-15.
- Gupta, S. (1988). "Impact of Sales Promotions on When, What, and How Much to Buy,"

*Journal of Marketing Research*, 25 (4), pp.342-355.

Hamilton, J.D. (1989). "A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle," *Econometrica*, 57 (2), pp.357-384.

Helion, C. and Gilovich, T. (2014). "Gift Cards and Mental Accounting: Green-lighting Hedonic Spending," *Journal of Behavioral Decision Making*, 27 (4), pp.386-393.

Helsen, K. and Schmittlein, D.C. (1993). "Analyzing Duration Times in Marketing: Evidence for the Effectiveness of Hazard Rate Models," *Marketing Science*, 11 (4), pp.359-414.

Inman, J.J., Russell, S.W. and Ferraro, R. (2009). "The Interplay among Category Characteristics, Customer Characteristics, and Customer Activities on In-store Decision Making," *Journal of Marketing*, 73 (5), pp.19-29.

Jain, D.C. and Vilcassim, N.J. (1991). "Investigating Household Purchase Timing Decisions: A Conditional Hazard Function Approach," *Marketing Science*, 10 (1), pp.1-23.

Jeuland, A.P., Bass, F.M. and Wright, G.P. (1980). "A Multibrand Stochastic Model Compounding Heterogeneous Erlang Timing and Multinomial Choice Processes," *Operations Research*, 28 (2), pp.255-277.

Kahneman, D. and Tversky, A. (1979). "Prospect Theory: An Analysis of Decision under Risk," *Econometrica*, 47 (2), pp.263-291.

Kalyanaram, G. and Little, J.D.C. (1994). "An Empirical Analysis of Latitude of Price Acceptance in Consumer Packaged Good," *Journal of Consumer Research*, 21 (3), pp.408-418.

Karlis, D. and Xekalaki, E. (2005). "Mixed Poisson Distribution," *International Statistical Review*, 73 (1), pp.35-58.

Kim, C-J. and Nelson, C.R. (1999). *State-space Models with Regime Switching: Classical and Gibbs-sampling Approaches with Applications*, MIT Press.

Koch, A.K. and Nafziger, J. (2016). "Goals and Bracketing under Mental Accounting," *Journal of Economic Theory*, 162, pp.305-351.

Lambert, D.. (1992). "Zero-inflated Poisson Regression, With an Application to Defects in Manufacturing," *American Statistical Association and the American Society for Quality Control*, 34 (1), pp.1-14.

Langer, T. and Weber, M. (2001). "Prospect Theory, Mental Accounting, and Differences in Aggregated and Segregated Evaluation of Lottery Portfolios," *Management Science*, 47 (5),

pp.716-733.

Lee, A.H., Wang, K., Scott, J.A., Yau, K.K.W. and McLachlan, G.J. (2006). "Multi-level Zero-inflated Poisson Regression Modeling of Correlated Count Data with Excess Zeros," *Statistical Methods in Medical Research*, 15 (1), pp.47-61.

Lord, D., Washington, S.P. and Ivan J.N. (2005). "Poisson-gamma and Zero-nflated Regression Models of Motor Vehicle Crashes: Balancing Statistical Fit and Theory," *Accident Analysis and Prevention*, 37 (1), pp.35-40.

Lucas Jr., R.E. (1976). "Econometric Policy Evaluation: A Critique," Carnegie-Rochester Conference Series on Public Policy, 1 (1), pp.19-46,

Manchanda, P., Ansari, A. and Gupta, S. (1999). "The "Shopping Basket Purchase": A Model for Multicategory Purchase Incidence Decision," *Marketing Science*, 18 (2), pp.95-114.

Miyatsu, K. and Sato, T. (2018). "Modeling the Heterogeneous Mental Accounting Impacts of Inter-shopping Duration," *Communications in Computer and Information Science*, 949, pp.1-16.

Morgan, C.J., Lenzenweger, M.F., Bubin, D.B. and Levy D.L. (2013). "A Hierarchical Finite Mixture Model that Accommodates Zero-inflated Counts, Non-independence, and Heterogeneity," *Statistics in Medicine*, 33 (13), pp.2238-2250.

Morrison, D.G. and Schmittlein, D.C. (1988). "Generalizing the NBD Model for Customer Purchases: What Are the Implications and Is It Worth the Effort?," *American Statistical Association*, 6 (2), pp.145-166.

Neftci, S.N. (1984). "Are Economic Time Series Asymmetric over the Business Cycle?," *Journal of Political Economy*, 92 (21), pp.307-328.

Osborne, M. (2011). "Consumer Learning, Switching Costs, and Heterogeneity: A Structural Examination," *Quantitative Marketing and Economics*, 9 (1), pp.25-70.

Park, S. and Gupta, S. (2011) "A Regime-switching Model of Cyclical Category Buying," *Marketing Science*, 30 (3), pp.469-480.

Prentice, R. and Kalbfleisch, J.D. (1979). "Hazard Rate Model with Covariates," *Biometrics*, 35 (1), pp.25-39.

Prelec, D. and Loewenstein, G. (1998), "The Red and the Black: Mental Accounting of Savings and Debt," *Marketing Science*, 17 (1), pp.4-27.

Quandt, R.E. (1972). "A New Approach to Estimating Switching Regressions," *Journal of the*

*American Statistical Association*, 67 (338), pp.306-310.

Ramaswamy, V., Anderson, E.W. and DeSarbo, W.S. (1994). "A Disaggregate Negative Binomial Regression Procedure for Count Data Analysis," *Management Science*, 40 (3), pp.405-417.

Rossi, P.E., Allenby, G.M. and McCulloch, R. (2005). *Bayesian Statistics and Marketing*, Wiley.

Schweidel, D.A. and Fader, P.S. (2009). "Dynamic Changepoint Revisited: An Evolving Process Model of New Product Sales," *International Journal of Research in Marketing*, 26 (2), pp.119-124.

Seetharaman, P.B. (2004). "The Additive Risk Model for Purchase Timing," *Marketing Science*, 23 (2), pp.234-242.

Seetharaman, P.B. and Chintagunta, P.K. (2003). "The Proportional Hazard Model for Purchase Timing: A Comparison of Alternative Specifications," *Journal of Business & Economic Statistics*, 21 (3), pp.368-382.

Shafir, E. and Thaler, R.H. (2006) "Invest now, Drink Later, Spend Never: On The Mental Accounting of Delayed Consumption," *Journal of Economic Psychology*, 27 (5), pp.694-712.

Shonkwiler, J.S. and Harris, T.R. (1996). "Rural Retail Business Thresholds and Interdependencies," *Journal of Regional Science*, 36 (4), pp.617-630.

Sichel, H.S. (1982). "Repeated-buying and the Generalized Inverse Gaussian-Poisson Distribution," *Royal Statistical Society*, 31 (3), pp.193-204.

Soman, D. (2001). "The Mental Accounting of Sunk Time Costs: Why Time Is Not Like Money," *Journal of Behavioral Decision Making*, 14 (3), pp.169-185.

Soster, R.L., Monga, A. and Bearden, W.O. (2010). "Tracking Cost of Time and Money: How Accounting Periods Affect Mental Accounting," *Journal of Consumer Research*, 37 (4), pp.712-721.

Stilley, K.M., Inman, J.J. and Wakefield, K.L. (2010). "Planning to Make Unplanned Purchase? The Role of In-store Slack in Budget Deviation," *Journal of Consumer Research*, 37 (2), pp.264-268.

Terui, N. and Dahana, W.D. (2006a). "Estimating Heterogeneous Price Thresholds," *marketing Science*, 25 (4), pp.384-391.

Terui, N. and Dahana, W.D. (2006b). "Price Customization Using Price Thresholds Estimated

from Scanner Panel Data,” *Journal of Interactive Marketing*, 20 (3/4), pp.58-70.

Terui, N. and Ban, M. (2008). “Modeling Heterogeneous Effective Advertising Stock Using Single-source Data,” *Quantitative Marketing and Economics*, 6 (4), pp.415-438.

Thaler, R. (1980). “Toward A Positive Theory of Consumer Choice,” *Journal of Economic Behavior and Organization*, 1 (1), pp.39-60.

Thaler, R.H. (1985). “Mental Accounting and Consumer Choice,” *Marketing Science*, 27 (1), pp.15-25.

Thaler, R.H. (1999). “Mental Accounting Matters,” *Journal of Behavioral Decision Making*, 12 (3), pp.183-206.

Thaler, R.H. (2008). “Mental Accounting and Consumer Choice: Anatomy of a Failure,” *Marketing Science*, 27 (1), pp.12-14.

Vakratsas, D. and Bass, F.M. (2002). “The Relationship between Purchase Regularity and Propensity to Accelerate,” *Journal of Retailing*, 78 (2), pp.119-129.

Vilcassim, N.J. and Jain, D.C. (1991). “Modeling Purchase-timing and Brand-switching Behavior Incorporating Explanatory Variables and Unobserved Heterogeneity,” *Journal of Marketing Research*, 28 (1), pp.29-41.

Wedel, M., DeSarbo, W.S., Bult, J.R. and Ramaswamy, V. (1993). “A Latent Class Poisson Regression Model for Heterogeneous Count Data,” *Journal of Applied Econometrics*, 8 (4), pp.397-411.

加藤弘貴, 木島豊希 (2017) 「小売り業態構造の現状分析と将来予測 (食品小売り市場を中心として)」, 『流通情報』, 526, pp.6-13.

小嶋外弘 (1986) 価格の心理 (消費者は何を購入決定の”モノサシ”にするのか), ダイヤモンド社.

小西葉子 (2006) 「存続時間分析による美容院顧客の来店確率予測」, 『統計数理』, 54 (2), pp.445-459.

熊倉雅仁 (2016) 「小売り業態の変革の理論的考察 (チャンネル革新がもたらすオムニチャンネル業態)」, 『高千穂論叢』, 51 (3), pp.47-74.

佐藤忠彦 (2015) マーケティングの統計モデル, 朝倉書店.

佐藤忠彦, 樋口知之 (2013) ビッグデータ時代のマーケティング (ベイジアンモデリングの活用), 講談社.

- 佐藤忠彦, 樋口知之, 北川源四郎 (2005) 「マルコフ切換モデルによる観測されない非価格プロモーション実施の有無の統計的推定法」, 『日本応用数理学会論文誌』, 15 (4), pp.29-62.
- 里村卓也 (2010) R で学ぶデータサイエンス 13 マーケティングモデル, 共立出版.
- 宮津和弘, 佐藤忠彦 (2019) 「心理会計の影響を考慮した来店間隔の統計モデル」, 『日本統計学会誌』, 48 (2), pp.113-146.
- 宮津和弘, 佐藤忠彦 (2015) 「心理的財布と購買行動の関係性のモデル化」, 『応用統計学』, 44 (3), pp.161-182.
- 照井信彦 (2008) ベイズモデリングによるマーケティング分析, 東京電機大学出版局.
- 山田浩喜, 佐藤忠彦 (2016) 「百貨店顧客の来店回数生起メカニズムの構造異質性の解析」, 『行動計量学』, 43 (1), pp.1-16.
- 和合肇 (2005) ベイズ計量経済分析 (マルコフ連鎖モンテカルロ法とその応用), 東洋経済新報社.

## 付録A 第3章の付録

### A.1 分布パラメータの構造化

ポアソン分布のレートパラメータは、消費者を識別する添え字  $i$  を有し、レジームごとに異なる消費者の評価関数を表現する。分布パラメータの構造化において、消費者  $i$  の購買機会  $t_i$  に対するレジーム  $k$  の回帰係数を  $\beta_i^{(k)} = (\beta_{i,1}^{(k)}, \beta_{i,2}^{(k)}, \dots, \beta_{i,p_k}^{(k)})^t$ ,  $k = 1, 2$  によりレジームを区別する。各レジーム回帰係数の次元  $p_k$  は、説明変数  $\mathbf{x}_{i,t_i} = (x_{i,t_i,1}, x_{i,t_i,2}, \dots, x_{i,t_i,p_k})^t$  の次元と同一であり、本モデルの実証分析データでは  $p_1 = p_2 = 6$  である。(以降、特に明記のない限り、 $\beta_i$  のように添え字  $k$  のないものは、2 レジームのいずれかの次元  $p_k$  の回帰係数を指すものとする。) ポアソン分布の確率密度関数を (A.1) 式に示す。ポアソン分布のレートパラメータは、時点ごとの説明変数  $\mathbf{x}_{i,t_i}$  と回帰係数  $\beta_i$  の対数線形変換  $\ln(\lambda_{i,t_i}) = \mathbf{x}_{i,t_i}^t \beta_i$  で構造化され、非負制約を有して  $\lambda_{i,t_i} > 0$  となる。回帰係数  $\beta_i$  は消費者  $i$  ごとに固定なパラメータであるが、説明変数  $\mathbf{x}_{i,t_i}$  は時点によって異なるため、レートパラメータ  $\lambda_{i,t_i}$  は時点ごとに変化する。

$$f(y_{i,t_i}) = \frac{(\lambda_{i,t_i})^{y_{i,t_i}} \exp(-\lambda_{i,t_i})}{y_{i,t_i}!} \quad (\text{A.1})$$

### A.2 推定アルゴリズム

本付録には、提案モデルを推定するためのアルゴリズムを示す。パラメータ推定にマルコフ連鎖モンテカルロ法 (MCMC) を用いる。具体的には、 $\Theta, \mathcal{A}$  のサンプリングにはランダムウォーク M-H 法を、 $\Delta_\theta, \Delta_\alpha, \Sigma_\theta, \Sigma_\alpha$  のサンプリングにはギブスサンプリングをそれぞれ用いる。

1. 初期値  $\theta_i^{(0)}, \alpha_i^{(0)}$  を設定する。
2.  $r = 1, 2, \dots$  について、次を繰り返す。

(a)  $i = 1, 2, \dots, H$  について, 次を繰り返す.

i. 新しい候補  $\theta_i$  を,  $\theta_i^{(r-1)}$  が与えられたもとの,  $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \sigma_{RW_\theta}^2 \mathbf{I})$  をサンプリングし,  $\theta_i = \theta_i^{(r-1)} + \mathbf{w}$  に従い発生させる. ただし,  $\sigma_{RW_\theta}^2 = 0.01$

ii. 次の採択確率を計算する.

$$a_i^\theta(\theta_i, \theta_i^{(r-1)}) = \min \left\{ \frac{p(\mathbf{y}_i | \theta_i, \boldsymbol{\alpha}_i, \mathbf{x}_i) p(\theta_i | \Delta_\theta, \Sigma_\theta, \mathbf{z}_i)}{p(\mathbf{y}_i | \theta_i^{(r-1)}, \boldsymbol{\alpha}_i, \mathbf{x}_i) p(\theta_i^{(r-1)} | \Delta_\theta, \Sigma_\theta, \mathbf{z}_i)}, 1 \right\}$$

iii. 一様乱数  $u \sim \mathcal{U}(0, 1)$  をサンプリングして, 次の通りに確率的選択を行う.

$$\theta_i^{(r)} = \begin{cases} \theta_i & u < a_i^\theta \\ \theta_i^{(r-1)} & \text{上記以外} \end{cases}$$

iv. 新しい候補  $\alpha_i$  を,  $\alpha_i^{(r-1)}$  が与えられたもとの,  $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \sigma_{RW_\alpha}^2 \mathbf{I})$  をサンプリングし,  $\alpha_i = \alpha_i^{(r-1)} + \mathbf{w}$  に従い発生させる. ただし,  $\sigma_{RW_\alpha}^2 = 0.1$

v. 次の採択確率を計算する.

$$a_i^\alpha(\alpha_i, \alpha_i^{(r-1)}) = \min \left\{ \frac{p(\mathbf{y}_i | \theta_i, \alpha_i, \mathbf{x}_i) p(\alpha_i | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i)}{p(\mathbf{y}_i | \theta_i, \alpha_i^{(r-1)}, \mathbf{x}_i) p(\alpha_i^{(r-1)} | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i)}, 1 \right\}$$

vi. 一様乱数  $u \sim \mathcal{U}(0, 1)$  をサンプリングして, 次の通りに確率的選択を行う.

$$\alpha_i^{(r)} = \begin{cases} \alpha_i & u < a_i^\alpha \\ \alpha_i^{(r-1)} & \text{上記以外} \end{cases}$$

(b)  $\delta_\theta = \text{vec}(\Delta_\theta), \Sigma_\theta$  を次の通りに発生させる.

i.  $\delta_\theta^{(r)} \sim \mathcal{N}(\tilde{\delta}_\theta, \Sigma_\theta \otimes (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\theta)^{-1})$

ii.  $\Sigma_\theta^{(r)} \sim I\mathcal{W}(v_{\theta,0} + H, \mathbf{V}_{\theta,0} + \mathbf{S}_\theta)$

$$\text{但し, } \tilde{\delta}_\theta = \text{vec}(\tilde{\Delta}_\theta), \tilde{\Delta}_\theta = (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\theta)^{-1} (\mathbf{Z}'\mathbf{Z} \hat{\Delta}_\theta + \mathbf{A}_\theta \bar{\Delta}_\theta),$$

$$\hat{\Delta}_\theta = (\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\Theta, \mathbf{S}_\theta = \sum_{i=1}^H (\theta_i - \bar{\theta}_i)(\theta_i - \bar{\theta}_i)'$$

(c)  $\delta_\alpha = \text{vec}(\Delta_\alpha), \Sigma_\alpha$  を次の通りに発生させる.

i.  $\delta_\alpha^{(r)} \sim \mathcal{N}(\tilde{\delta}_\alpha, \Sigma_\alpha \otimes (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\alpha)^{-1})$

ii.  $\Sigma_\alpha^{(r)} \sim I\mathcal{W}(v_{\alpha,0} + H, \mathbf{V}_{\alpha,0} + \mathbf{S}_\alpha)$

$$\text{但し, } \tilde{\delta}_\alpha = \text{vec}(\tilde{\Delta}_\alpha), \tilde{\Delta}_\alpha = (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\alpha)^{-1} (\mathbf{Z}'\mathbf{Z} \hat{\Delta}_\alpha + \mathbf{A}_\alpha \bar{\Delta}_\alpha),$$

$$\hat{\Delta}_\alpha = (\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\mathcal{A}, \mathbf{S}_\alpha = \sum_{i=1}^H (\alpha_i - \bar{\alpha}_i)(\alpha_i - \bar{\alpha}_i)'$$

3. 十分に大きな  $r$  に対して,  $\theta_i^{(r)}, \alpha_i^{(r)}, \delta_\theta^{(r)}, \Sigma_\theta^{(r)}, \delta_\alpha^{(r)}, \Sigma_\alpha^{(r)}$  ( $r = N, N+1, \dots$ ) を記憶する. 但し, 緩慢な事前分布を表現するために, 照井 (2008) と同様, 事前分布として次の通り設定した.  $\tilde{\delta}_\theta = \text{vec}(\tilde{\Delta}_\theta) = \mathbf{0}, \tilde{\delta}_\alpha = \text{vec}(\tilde{\Delta}_\alpha) = \mathbf{0}, \mathbf{A}_\theta = 0.001\mathbf{I}, \mathbf{A}_\alpha = 0.001\mathbf{I}, v_{\theta,0} = 17, v_{\alpha,0} = 6,$

$\mathbf{V}_{\theta,0} = v_{\theta,0}\mathbf{I}, \mathbf{V}_{\alpha,0} = v_{\alpha,0}\mathbf{I}$ . なお, ベイズ統計に関する理論については, Rossi et al. (2005), 和合 (2005), 照井 (2008), 里村 (2010), 佐藤・樋口 (2013), 佐藤 (2015) などを参考のこと.

### A.3 推定用Rプログラム

```
##### mental_accounting_items.R #####
library(MASS)
library(MCMCpack)
library(bayesm)
set.seed(555)

##### data formatting for bayesian estimation #####
dataZ <- read.csv("HBPoisson_Z1KV5B.csv")
datayX <- read.csv("HBPoisson_yX1KV7.csv")

nvar1 <- 6; nvar2 <- 6; nzet <- 5; nace <- 2; ngam <- 1
nall <- nvar1+nvar2+ngam

nhh <- 1000
nobs <- dataZ[1:nhh,2]
Z <- as.matrix(dataZ[1:nhh,3:(2+nzet)])

hhdata <- NULL
nob0 <- 1; nob1 <- nobs[1]

for (i in 1:nhh) {

  X <- as.matrix(datayX[nob0:nob1,3:(nvar1+2)])
  y <- as.matrix(datayX[nob0:nob1,2])
  cumm1<- as.matrix(datayX[nob0:nob1,10])
  cumm2<- as.matrix(datayX[nob0:nob1,11])
  cumm3<- as.matrix(datayX[nob0:nob1,12])

  hhdata[[i]]<- list(y=y,X=X,cumm1=cumm1,cumm2=cumm2,cumm3=cumm3)
  nob0<- nob1+1
  nob1<- nob0+nobs[i+1]-1
}

##### poisson likelihood function #####
loglike <- function(y,X,beta) {
  ll <- y*(X%*%beta)-exp(X%*%beta)-log(factorial(y))
  sum(ll)
}

##### bayesian parameters #####
R <- 10000

ace0 <- c(0.35,0.35)
gamma00 <- matrix(rep(0,nhh),nhh,1)
```

```

for (i in 1:nhh) {
  gamma00[i] <- mean(hhdata[[i]]$cumml)
}

s      <- 0.0001
A      <- 0.001
nu     <- nall+4
V      <- nu*diag(c(rep(1, nall - 1), 0.5))
ADelta <- A*diag(nzet)
Deltabar <- matrix(rep(0, nzet*nall), nzet, nall)

sa     <- 0.01
Aa     <- 0.001
nua    <- nace+4
Vace   <- nua*diag(rep(1, nace))
ADeltace <- A*diag(nzet)
Deltabace <- matrix(rep(0, nzet*nace), nzet, nace)

oldbetas <- matrix(double(nhh*(nvar1+nvar2)), nhh, nvar1+nvar2)
oldgamma <- gamma00
oldlgm   <- log(oldgamma)
oldtheta <- cbind(oldbetas, oldlgm)

ace1    <- matrix(ace0[1], nhh)
ace2    <- matrix(ace0[2], nhh)
oldaces <- cbind(ace1, ace2)
lac1    <- log(ace1/(1-ace1-ace2))
lac2    <- log(ace2/(1-ace1-ace2))
oldlacs <- cbind(lac1, lac2)

oldV    <- diag(nall)
oldVi   <- diag(nall)
oldDelta <- matrix(double(nzet*nall), nzet, nall)

oldVace <- diag(nace)
oldVacei <- diag(nace)
oldDeltace <- matrix(double(nzet*nace), nzet, nace)

thetadraw <- array(double(floor(R)*nhh*nall), dim=c(floor(R), nhh, nall))
betadraw <- array(double(floor(R)*nhh*(nvar1+nvar2)), dim=c(floor(R), nhh, nvar1+nvar2))
gammadraw <- array(double(floor(R)*nhh*ngam), dim=c(floor(R), nhh, ngam))
regidraw <- array(double(floor(R)*nhh*2), dim=c(floor(R), nhh, 2))
acceptdraw <- array(double(floor(R)*nhh*2), dim=c(floor(R), nhh, 1))
acedraw <- array(double(floor(R)*nhh*nace), dim=c(floor(R), nhh, nace))
llhall <- array(double(floor(R)*1), dim=c(floor(R), 1))

```

```

cnt10 <- 0; cnt20 <- 0
for (i in 1:nhh) {
  recs <- nobs[i]
  cumm <- hhdata[[i]]$cumm1

  for (j in 1:recs) {
    if (cumm[j]>=gamma00[i]) {
      cnt10 <- cnt10+1
    } else {
      cnt20 <- cnt20+1
    }
  }

  regi_init[i,1:2] <- c(cnt10, cnt20)
  cnt10 <- 0; cnt20 <- 0
}

##### mcmc loop starts #####
for (iter in 1:R) {

  llh <- 0
  sV <- s*V; sVace <- sa*Vace
  root <- t(chol(sV)); roota <- t(chol(sVace))

##### nnh loop starts #####
  for (i in 1:nhh) {

    recs <- nobs[i]
    yy <- hhdata[[i]]$y
    XX <- hhdata[[i]]$X
    cumm1 <- hhdata[[i]]$cumm1
    cumm2 <- hhdata[[i]]$cumm2
    cumm3 <- hhdata[[i]]$cumm3

    thetad <- oldtheta[i, 1:nall]
    betad1 <- thetad[1:nvar1]
    betad2 <- thetad[(nvar1+1):(nvar1+nvar2)]
    lgmd <- thetad[nvar1+nvar2+1]

    thetan <- thetad+root%%rnorm(nall)
    betan1 <- thetan[1:nvar1]
    betan2 <- thetan[(nvar1+1):(nvar1+nvar2)]
    lgmn <- thetan[nvar1+nvar2+1]

    gammad <- exp(lgmd); gamman <- exp(lgmn)

    lacd <- oldlacs[i, 1:2]
    lacd1 <- lacd[1]; lacd2 <- lacd[2]
    aced1 <- exp(lacd1)/(1+exp(lacd1)+exp(lacd2))
  }
}

```

```

aced2 <- exp(lacd2)/(1+exp(lacd1)+exp(lacd2))

lacn <- lacd+roota%%rnorm(nace)
lacn1 <- lacn[1]; lacn2 <- lacn[2]
acen1 <- exp(lacn1)/(1+exp(lacn1)+exp(lacn2))
acen2 <- exp(lacn2)/(1+exp(lacn1)+exp(lacn2))

cummd <- aced1*cumm1+aced2*cumm2+(1-aced1-aced2)*cumm3
cummn <- acen1*cumm1+acen2*cumm2+(1-acen1-acen2)*cumm3

##### regime data grouping for theta #####

cnt1d <- 0; cnt2d <- 0; cnt1n <- 0; cnt2n <- 0

y1d <- NULL; X1d <- NULL; y2d <- NULL; X2d <- NULL
y1n <- NULL; X1n <- NULL; y2n <- NULL; X2n <- NULL

for (j in 1:recs) {
  if (cummd[j]>=gammad) {
    y1d <- rbind(y1d,yy[j])
    X1d <- rbind(X1d,XX[j,1:nvar1])
    cnt1d <- cnt1d+1
  } else {
    y2d <- rbind(y2d,yy[j])
    X2d <- rbind(X2d,XX[j,1:nvar2])
    cnt2d <- cnt2d+1
  }
  if (cummd[j]>=gamman) {
    y1n <- rbind(y1n,yy[j])
    X1n <- rbind(X1n,XX[j,1:nvar1])
    cnt1n <- cnt1n+1
  } else {
    y2n <- rbind(y2n,yy[j])
    X2n <- rbind(X2n,XX[j,1:nvar2])
    cnt2n <- cnt2n+1
  }
}

##### stochastic parameter selection for theta #####

logold1 <- 0; logold2 <- 0; logoldk <- 0
lognew1 <- 0; lognew2 <- 0; lognewk <- 0

logsum <- 0
alpha <- NULL

lognewk <- -0.5*(t(thetan)-Z[i,]%%oldDelta)%%oldVi%%(thetan-t(Z[i,]%%oldDelta))
logoldk <- -0.5*(t(thetad)-Z[i,]%%oldDelta)%%oldVi%%(thetad-t(Z[i,]%%oldDelta))

```

```

if (cnt1d>0) {
  logold1 <- loglike(y1d,X1d,betad1)
} else {
  logold1 <- 0
}
if (cnt2d>0) {
  logold2 <- loglike(y2d,X2d,betad2)
} else {
  logold2 <- 0
}
if (cnt1n>0) {
  lognew1 <- loglike(y1n,X1n,betan1)
} else {
  lognew1 <- 0
}
if (cnt2n>0) {
  lognew2 <- loglike(y2n,X2n,betan2)
} else {
  lognew2 <- 0
}
logsum <- lognew1+lognew2+lognewk-logold1-logold2-logoldk
alpha <- exp(logsum)

if (alpha=="NaN")
  alpha=-1

u <- runif(1)

if (u < alpha) {
  oldtheta[i,] <- thetan
  gammad <- gamman
  betad1 <- betan1
  betad2 <- betan2
  regi[i,1:2] <- c(cnt1n , cnt2n)
  accept[i,1] <- 1
} else {
  reject[i,1] <- reject[i,1]+1
  regi[i,1:2] <- c(cnt1d , cnt2d)
  accept[i,1] <- 0
}

##### regime data grouping for alpha #####

cnt1da <- 0; cnt2da <- 0; cnt1na <- 0; cnt2na <- 0

y1da <- NULL; X1da <- NULL; y2da <- NULL; X2da <- NULL
y1na <- NULL; X1na <- NULL; y2na <- NULL; X2na <- NULL

```

```

for (j in 1:reccs) {
  if (cummd[j]>=gammad) {
    y1da <- rbind(y1da,yy[j])
    X1da <- rbind(X1da,XX[j,1:nvar1])
    cnt1da <- cnt1da+1
  } else {
    y2da <- rbind(y2da,yy[j])
    X2da <- rbind(X2da,XX[j,1:nvar2])
    cnt2da <- cnt2da+1
  }
  if (cummn[j]>=gammad) {
    y1na <- rbind(y1na,yy[j])
    X1na <- rbind(X1na,XX[j,1:nvar1])
    cnt1na <- cnt1na+1
  } else {
    y2na <- rbind(y2na,yy[j])
    X2na <- rbind(X2na,XX[j,1:nvar2])
    cnt2na <- cnt2na+1
  }
}

##### stochastic parameter selection for alpha #####

logold1a <- 0; logold2a <- 0; logoldka <- 0
lognew1a <- 0; lognew2a <- 0; lognewka <- 0

logsuma <- 0
alphace <- NULL

lognewka <- -0.5*(t(lacd)-Z[i,]%%oldDeltace)%%oldVacei%%(lacd-t(Z[i,]%%oldDeltace))
logoldka <- -0.5*(t(lacn)-Z[i,]%%oldDeltace)%%oldVacei%%(lacn-t(Z[i,]%%oldDeltace))

if (cnt1da>0) {
  logold1a <- loglike(y1da,X1da,betad1)
} else {
  logold1a <- 0
}
if (cnt2da>0) {
  logold2a <- loglike(y2da,X2da,betad2)
} else {
  logold2a <- 0
}
if (cnt1na>0) {
  lognew1a <- loglike(y1na,X1na,betad1)
} else {
  lognew1a <- 0
}

```

```

if (cnt2na > 0) {
  lognew2a <- loglike(y2na, X2na, betad2)
} else {
  lognew2a <- 0
}
logsuma <- lognew1a + lognew2a + lognewka - logold1a - logold2a - logoldka
alphace <- exp(logsuma)

if (alphace == "NaN")
  alphace == -1

u <- runif(1)

if (u < alphace) {
  oldlacs[i,] <- lacn
  regi[i,1:2] <- c(cnt1na, cnt2na)
} else {
  rejecta[i,1] <- rejecta[i,1] + 1
  regi[i,1:2] <- c(cnt1da, cnt2da)
}

} ##### nhh loop end #####

##### loglikelihood for all households #####

for (i in 1:nhh) {

  recs <- nobs[i]
  yy <- hhdata[[i]]$y
  XX <- hhdata[[i]]$X
  cumm1 <- hhdata[[i]]$cumm1
  cumm2 <- hhdata[[i]]$cumm2
  cumm3 <- hhdata[[i]]$cumm3

  theta <- oldtheta[i, 1:nall]
  beta1 <- theta[1:nvar1]
  beta2 <- theta[(nvar1+1):(nvar1+nvar2)]
  lgm <- theta[nvar1+nvar2+1]
  gamma <- exp(lgm)

  lac <- oldlacs[i, 1:2]
  lac1 <- lac[1]
  lac2 <- lac[2]
  ace1 <- exp(lac1)/(1+exp(lac1)+exp(lac2))
  ace2 <- exp(lac2)/(1+exp(lac1)+exp(lac2))

  cumm <- ace1*cumm1+ace2*cumm2+(1-ace1-ace2)*cumm3

```

```

##### regime data grouping for beta #####

cnt1 <- 0; cnt2 <- 0

y1 <- NULL; X1 <- NULL
y2 <- NULL; X2 <- NULL

for (j in 1:recs) {
  if (cumm[j]>=gamma) {
    y1 <- rbind(y1,yy[j])
    X1 <- rbind(X1,XX[j,1:nvar1])
    cnt1 <- cnt1+1
  } else {
    y2 <- rbind(y2,yy[j])
    X2 <- rbind(X2,XX[j,1:nvar2])
    cnt2 <- cnt2+1
  }
}

##### stochastic parameter selection for beta #####

llh1 <- 0; llh2 <- 0; llh <- 0

if (cnt1>0) {
  llh1 <- loglike2(y1,X1,beta1)
} else {
  llh1 <- 0
}
if (cnt2>0) {
  llh2 <- loglike2(y2,X2,beta2)
} else {
  llh2 <- 0
}
llh <- llh+llh1+llh2
}

##### rmultireg(oldtheta,Z,Deltabar,ADelta,nu,V) #####

nth = nrow(oldtheta)
mth = ncol(oldtheta)
kth = ncol(Z)
RAth = chol(ADelta)
Wth = rbind(Z,RAth)
Zth = rbind(oldtheta,RAth%%Deltabar)
IRth = backsolve(chol(crossprod(Wth)),diag(kth))
Btildeth = crossprod(t(IRth))%%crossprod(Wth,Zth)
Sth = crossprod(Zth-Wth%%Btildeth)

```

```

rwouth      = rwishart(nu+nth , chol2inv( chol(V+Sth)))
Bth         = Btildeth+IRth%%matrix( rnorm( mth*kth ) , ncol=mth)%%t( rwouth$CI)
oldDelta    <- Bth
oldV        <- rwouth$IW
oldVi       <- solve( oldV)

##### rmultireg( oldlacs ,Z, Deltabace , ADeltace , nua ,Vace) #####

nac         = nrow( oldlacs )
mac         = ncol( oldlacs )
kac         = ncol( Z)
RAce        = chol( ADeltace )
Wac         = rbind( Z,RAce)
Zac         = rbind( oldlacs ,RAce%%Deltabace )
IRac        = backsolve( chol( crossprod( Wac)) , diag( kac ))
Btildace    = crossprod( t( IRac))%%crossprod( Wac, Zac)
Sac         = crossprod( Zac-Wac%%Btildace )
rwouac      = rwishart( nua+nac , chol2inv( chol( Vace+Sac)))
Bac         = Btildace+IRac%%matrix( rnorm( mac*kac ) , ncol=mac)%%t( rwouac$CI)
oldDeltace  <- Bac
oldVace     <- rwouac$IW
oldVacei    <- solve( oldVace)

##### store estimated results /draws #####

mkeep<- iter

lgmkeep     <- oldtheta [, (nvar1+nvar2+1)]
gammakeep   <- exp( lgmkeep)

lackeep1    <- oldlacs [,1]
lackeep2    <- oldlacs [,2]
acekeep1    <- exp( lackeep1)/(1+exp( lackeep1)+exp( lackeep2))
acekeep2    <- exp( lackeep2)/(1+exp( lackeep1)+exp( lackeep2))

thetadraw   [mkeep, ,] <- oldtheta [, ,]
betadraw    [mkeep, ,] <- oldtheta [, 1:(nvar1+nvar2)]
gammadraw   [mkeep, ,] <- gammakeep
acedraw     [mkeep, ,] <- cbind( acekeep1 , acekeep2)
regidraw    [mkeep, ,] <- regi [, ,]
acceptdraw  [mkeep, ,] <- accept [, ,]
llhall      [mkeep, ] <- llh

} ##### mcmc loop end of mental_accounting_items.R #####

```

## 付録B 第4章の付録

### B.1 分布パラメータの構造化

対数正規分布の各分布パラメータは、消費者を識別する添え字  $i$  を有し、レジームごとに異なる消費者の評価関数を表現する。分布パラメータの構造化において、消費者  $i$  の購買機会  $t_i$  に対するレジーム  $k$  の回帰係数を  $\beta_i^{(k)} = (\beta_{i,1}^{(k)}, \beta_{i,2}^{(k)}, \dots, \beta_{i,p_k}^{(k)})'$ ,  $k = 1, 2$  によりレジームを区別する。各レジーム回帰係数の次元  $p_k$  は、説明変数  $\mathbf{x}_{i,t_i} = (x_{i,t_i,1}, x_{i,t_i,2}, \dots, x_{i,t_i,p_k})'$  の次元と同一であり、本モデルの実証分析データでは  $p_1 = 6$ ,  $p_2 = 5$  である。(以降、特に明記のない限り、 $\beta_i$  のように添え字のないものは、2 レジームのいずれかの次元  $p_k$  の回帰係数を指すものとする。) 対数正規分布の確率密度関数を (B.1) 式に示す。対数正規分布は、観測値  $y_{i,t_i}$  の対数値が正規分布に従う分布関数である。消費者  $i$  ごとに固定とする分散パラメータ  $\sigma_i^2$  は非負制約を有するが、時点ごとの説明変数  $\mathbf{x}_{i,t_i}$  と回帰係数  $\beta_i$  の線形変換  $\mu_{i,t_i} = \mathbf{x}_{i,t_i}'\beta_i$  で構造化する位置パラメータ  $\mu_{i,t_i}$  には制約はないため、 $\sigma_i > 0$ ,  $\mu_{i,t_i}$  は全ての実数となる。回帰係数  $\beta_i$  は消費者  $i$  ごとに固定なパラメータであるが、説明変数  $\mathbf{x}_{i,t_i}$  は時点によって異なるため、位置パラメータ  $\mu_{i,t_i}$  は時点ごとに変化する。

$$f(y_{i,t_i}) = \frac{1}{\sqrt{2\pi}\sigma_i y_{i,t_i}} \exp\left[-\frac{1}{2}\left(\frac{\ln(y_{i,t_i}) - \mu_{i,t_i}}{\sigma_i}\right)^2\right] \quad (\text{B.1})$$

### B.2 推定アルゴリズム

本付録には、提案モデルを推定するためのアルゴリズムを示す。パラメータ推定にマルコフ連鎖モンテカルロ法 (MCMC) を用いる。具体的には、 $\Phi, \mathcal{A}$  のサンプリングにはランダムウォーク M-H 法を、 $\sigma^{2(1)}, \sigma^{2(2)}$  および  $\Delta_\phi, \Delta_\alpha, \Sigma_\phi, \Sigma_\alpha$  のサンプリングにはギブスサンプリングをそれぞれ用いる。

1. 初期値  $\phi_i^{(0)}, \alpha_i^{(0)}$  を設定する。

2.  $r = 1, 2, \dots$  について, 次を繰り返す.

(a)  $i = 1, 2, \dots, H$  について, 次を繰り返す.

i. 新しい候補  $\phi_i$  を,  $\phi_i^{(r-1)}$  が与えられたもとで,  $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \sigma_{RW_\phi}^2 \mathbf{I})$  をサンプリングし,  $\phi_i = \phi_i^{(r-1)} + \mathbf{w}$  に従い発生させる. ただし,  $\sigma_{RW_\phi}^2 = 0.001$

ii. 次の採択確率を計算する.

$$a_i^\phi(\phi_i, \phi_i^{(r-1)}) = \min \left\{ \frac{p(\mathbf{y}_i | \phi_i, \boldsymbol{\alpha}_i, \mathbf{x}_i) p(\phi_i | \boldsymbol{\Delta}_\phi, \boldsymbol{\Sigma}_\phi, \mathbf{z}_i)}{p(\mathbf{y}_i | \phi_i^{(r-1)}, \boldsymbol{\alpha}_i, \mathbf{x}_i) p(\phi_i^{(r-1)} | \boldsymbol{\Delta}_\phi, \boldsymbol{\Sigma}_\phi, \mathbf{z}_i)}, 1 \right\}$$

iii. 一様乱数  $u \sim \mathcal{U}(0, 1)$  をサンプリングして, 次の通りに確率的選択を行う.

$$\phi_i^{(r)} = \begin{cases} \phi_i & u < a_i^\phi \\ \phi_i^{(r-1)} & \text{上記以外} \end{cases}$$

iv. 新しい候補  $\boldsymbol{\alpha}_i$  を,  $\boldsymbol{\alpha}_i^{(r-1)}$  が与えられたもとで,  $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \sigma_{RW_\alpha}^2 \mathbf{I})$  をサンプリングし,  $\boldsymbol{\alpha}_i = \boldsymbol{\alpha}_i^{(r-1)} + \mathbf{w}$  に従い発生させる. ただし,  $\sigma_{RW_\alpha}^2 = 0.01$

v. 次の採択確率を計算する.

$$a_i^\alpha(\boldsymbol{\alpha}_i, \boldsymbol{\alpha}_i^{(r-1)}) = \min \left\{ \frac{p(\mathbf{y}_i | \phi_i, \boldsymbol{\alpha}_i, \mathbf{x}_i) p(\boldsymbol{\alpha}_i | \boldsymbol{\Delta}_\alpha, \boldsymbol{\Sigma}_\alpha, \mathbf{z}_i)}{p(\mathbf{y}_i | \phi_i, \boldsymbol{\alpha}_i^{(r-1)}, \mathbf{x}_i) p(\boldsymbol{\alpha}_i^{(r-1)} | \boldsymbol{\Delta}_\alpha, \boldsymbol{\Sigma}_\alpha, \mathbf{z}_i)}, 1 \right\}$$

vi. 一様乱数  $u \sim \mathcal{U}(0, 1)$  をサンプリングして, 次の通りに確率的選択を行う.

$$\boldsymbol{\alpha}_i^{(r)} = \begin{cases} \boldsymbol{\alpha}_i & u < a_i^\alpha \\ \boldsymbol{\alpha}_i^{(r-1)} & \text{上記以外} \end{cases}$$

vii.  $\sigma_i^{2(1)}$  を次の通りに発生させる.

$$\sigma_i^{2(1)} \sim \text{IG}(v_i^{(1)}/2, v_i S_i^{(1)}/2)$$

$$\text{但し, } v_i^{(1)} = v_0 + n_i^{(1)}, \quad v_i S_i^{(1)} = v_0 S_0 + \sum_{i=1}^{n_i^{(1)}} (\ln(y_i^{(1)}) - z_i^t \boldsymbol{\beta}_i^{(1)})^2$$

viii.  $\sigma_i^{2(2)}$  を次の通りに発生させる.

$$\sigma_i^{2(2)} \sim \text{IG}(v_i^{(2)}/2, v_i S_i^{(2)}/2)$$

$$\text{但し, } v_i^{(2)} = v_0 + n_i^{(2)}, \quad v_i S_i^{(2)} = v_0 S_0 + \sum_{i=1}^{n_i^{(2)}} (\ln(y_i^{(2)}) - z_i^t \boldsymbol{\beta}_i^{(2)})^2$$

(b)  $\boldsymbol{\delta}_\phi = \text{vec}(\boldsymbol{\Delta}_\phi), \boldsymbol{\Sigma}_\phi$  を次の通りに発生させる.

i.  $\boldsymbol{\delta}_\phi^{(r)} \sim \mathcal{N}(\tilde{\boldsymbol{\delta}}_\phi, \boldsymbol{\Sigma}_\phi \otimes (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\phi)^{-1})$

ii.  $\boldsymbol{\Sigma}_\phi^{(r)} \sim \text{IW}(\nu_{\phi,0} + H, \mathbf{V}_{\phi,0} + \mathbf{S}_\phi)$

$$\text{但し, } \tilde{\boldsymbol{\delta}}_\phi = \text{vec}(\tilde{\boldsymbol{\Delta}}_\phi), \quad \tilde{\boldsymbol{\Delta}}_\phi = (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\phi)^{-1} (\mathbf{Z}'\mathbf{Z} \hat{\boldsymbol{\Delta}}_\phi + \mathbf{A}_\phi \bar{\boldsymbol{\Delta}}_\phi),$$

$$\hat{\boldsymbol{\Delta}}_\phi = (\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\boldsymbol{\Phi}, \quad \mathbf{S}_\phi = \sum_{i=1}^H (\phi_i - \bar{\phi}_i)(\phi_i - \bar{\phi}_i)'$$

(c)  $\boldsymbol{\delta}_\alpha = \text{vec}(\boldsymbol{\Delta}_\alpha), \boldsymbol{\Sigma}_\alpha$  を次の通りに発生させる.

$$\text{i. } \delta_\alpha^{(r)} \sim \mathcal{N}(\tilde{\delta}_\alpha, \Sigma_\alpha \otimes (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\alpha)^{-1})$$

$$\text{ii. } \Sigma_\alpha^{(r)} \sim \mathcal{IW}(\nu_{\alpha,0} + H, \mathbf{V}_{\alpha,0} + \mathbf{S}_\alpha)$$

$$\text{但し, } \tilde{\delta}_\alpha = \text{vec}(\tilde{\mathbf{\Delta}}_\alpha), \quad \tilde{\mathbf{\Delta}}_\alpha = (\mathbf{Z}'\mathbf{Z} + \mathbf{A}_\alpha)^{-1}(\mathbf{Z}'\mathbf{Z}\hat{\mathbf{\Delta}}_\alpha + \mathbf{A}_\alpha\bar{\mathbf{\Delta}}_\alpha),$$

$$\hat{\mathbf{\Delta}}_\alpha = (\mathbf{Z}'\mathbf{Z})^{-1}\mathbf{Z}'\mathcal{A}, \quad \mathbf{S}_\alpha = \sum_{i=1}^H (\alpha_i - \bar{\alpha}_i)(\alpha_i - \bar{\alpha}_i)'$$

3. 十分に大きな  $r$  に対して,  $\phi_i^{(r)}, \alpha_i^{(r)}, \delta_\phi^{(r)}, \Sigma_\phi^{(r)}, \delta_\alpha^{(r)}, \Sigma_\alpha^{(r)}$  ( $r = N, N+1, \dots$ ) を記憶する. 但し, 緩慢な事前分布を表現するために, 照井 (2008) と同様, 事前分布として次の通り設定した.  $\nu_0 = 100, S_0 = 0, \bar{\delta}_\phi = \text{vec}(\bar{\mathbf{\Delta}}_\phi) = \mathbf{0}, \bar{\delta}_\alpha = \text{vec}(\bar{\mathbf{\Delta}}_\alpha) = \mathbf{0}, \mathbf{A}_\phi = 0.001\mathbf{I}, \mathbf{A}_\alpha = 0.001\mathbf{I}, \nu_{\phi,0} = 16, \nu_{\alpha,0} = 6, \mathbf{V}_{\phi,0} = \nu_{\phi,0}\mathbf{I}, \mathbf{V}_{\alpha,0} = \nu_{\alpha,0}\mathbf{I}$ . なお, ベイズ統計に関する理論については, Rossi et al. (2005), 和合 (2005), 照井 (2008), 里村 (2010), 佐藤・樋口 (2013), 佐藤 (2015) などを参考のこと.

### B.3 推定用Rプログラム

```
##### mental_accounting_duration2.R #####
library(MASS)
library(MCMCpack)
library(bayesm)
set.seed(555)

##### data formatting for bayesian estimation #####
dataZ1 <- read.csv("HBPD665_dataZ.csv")
dataZ2 <- read.csv("inv0consZ.csv")
datayX <- read.csv("HBPD675_datayX.csv")
dataZ <- cbind(dataZ1, dataZ2)

nvar5 <- 5; nvar6 <- 6; nsgm <- 2; ngam <- 1; nzet <- 5; nace <- 2
nall <- nvar5+nvar6+ngam

nhh <- 100
nobs <- dataZ[1:nhh,2]

Z <- as.matrix(dataZ[1:nhh,3:(2+nzet)])

hhdata <- NULL
nob0 <- 1
nob1 <- nobs[1]

for (i in 1:nhh) {

  X <- as.matrix(datayX[nob0:nob1,3:7])
  y <- as.matrix(datayX[nob0:nob1,2])
  cumm1 <- as.matrix(datayX[nob0:nob1,9])
  cumm2 <- as.matrix(datayX[nob0:nob1,10])
  cumm3 <- as.matrix(datayX[nob0:nob1,11])

  hhdata[[i]] <- list(y=y, X=X, cumm1=cumm1, cumm2=cumm2, cumm3=cumm3)
  nob0 <- nob1+1
  nob1 <- nob0+nobs[i+1]-1
}

##### log-normal: LN5 #####
LN5 <- function(y, X, beta) {
  ll <- -0.5*log(2*pi)-log(y)-log(sqrt(exp(beta[6])))
  -0.5*((1/exp(beta[6]))*(log(y)-X%%beta[1:5])^2
  sum(ll)
}
```

```

##### log-normal: LN6 #####
LN6 <- function(y,X,beta) {
  ll <- -0.5*log(2*pi)-log(y)-log(exp(beta[7]))
      -0.5*((1/exp(beta[7]))^2)*(log(y)-X%*%beta[1:6])^2
  sum(ll)
}

##### bayesian parameters #####

R      <- 50000

ace0   <- c(0.333,0.333)
gamma0c <- matrix(rep(0,nhh),nhh,1)

for (i in 1:nhh) {
  gamma0c[i] <- mean(hhdata[[i]]$scumm1)
}

s      <- 0.000001
A      <- 0.001
nu     <- nall+4
V      <- nu*diag(rep(1,nall))
ADelta <- A*diag(nzet)
Deltabar <- matrix(rep(0,nzet*nall),nzet,nall)

v0 <- 100
S0 <- 100

sa     <- 0.0001
Aa     <- 0.001
nua    <- nace+4
Vace   <- nua*diag(rep(1,nace))
ADeltace <- Aa*diag(nzet)
Deltabace <- matrix(rep(0,nzet*nace),nzet,nace)

oldtheta <- matrix(rep(0,nhh*nall),nhh,nall)
oldgammac <- gamma0c
oldlgmc <- log(oldgammac)
oldtheta[,12] <- oldlgmc

oldlsgm <- matrix(rep(0,nhh*nsgm),nhh,nsgm)

ace1   <- matrix(ace0[1],nhh)
ace2   <- matrix(ace0[2],nhh)
oldaces <- cbind(ace1,ace2)
lac1   <- log(ace1/(1-ace1-ace2))
lac2   <- log(ace2/(1-ace1-ace2))
oldlacs <- cbind(lac1,lac2)

```

```

oldV      <- diag(nall)
oldVi     <- diag(nall)
oldDelta  <- matrix(double(nzet*nall),nzet,nall)

oldVg     <- diag(nsgm)
oldVgi    <- diag(nsgm)
oldDeltag <- matrix(double(nzet*nsgm),nzet,nsgm)

oldVace   <- diag(nace)
oldVacei  <- diag(nace)
oldDeltace <- matrix(double(nzet*nace),nzet,nace)

thetadraw <- array(double(floor(R)*nhh*nall),dim=c(floor(R),nhh,nall))
gamacdraw <- array(double(floor(R)*nhh*1),dim=c(floor(R),nhh,1))
lgmcdraw  <- array(double(floor(R)*nhh*1),dim=c(floor(R),nhh,1))
sigmadraw <- array(double(floor(R)*nhh*nsgm),dim=c(floor(R),nhh,nsgm))
lsgmdraw  <- array(double(floor(R)*nhh*nsgm),dim=c(floor(R),nhh,nsgm))
acedraw   <- array(double(floor(R)*nhh*nace),dim=c(floor(R),nhh,nace))
lacadraw  <- array(double(floor(R)*nhh*nace),dim=c(floor(R),nhh,nace))
llhall    <- array(double(floor(R)*1),dim=c(floor(R),1))
deltadraw <- array(double(floor(R)*nzet*nall),dim=c(floor(R),nzet,nall))
deltadrawa <- array(double(floor(R)*nzet*nace),dim=c(floor(R),nzet,nace))
deltadrawg <- array(double(floor(R)*nzet*nace),dim=c(floor(R),nzet,nsgm))
reject    <- array(0,dim=c(floor(R),3))
count     <- array(0,dim=c(floor(R),2))

##### mcmc loop starts #####

for (iter in 1:R) {

  llh <- 0; cnt <-c(0,0)
  sV <- s*V; sVace <- sa*Vace
  root <- t(chol(sV)); roota <- t(chol(sVace))

  ##### nnh loop starts #####

  for (i in 1:nhh) {

    rees <- nobs[i]
    yy <- hhdata[[i]]$y
    XX <- hhdata[[i]]$X
    inv <- hhdata[[i]]$inv
    cumm1 <- hhdata[[i]]$cumm1
    cumm2 <- hhdata[[i]]$cumm2
    cumm3 <- hhdata[[i]]$cumm3

    XX[,5] <- sqrt(XX[,5])

```

```

thetad <- oldtheta[i,1:nall]
betad1 <- thetad[1:nvar6]
betad2 <- thetad[(nvar6+1):(nvar5+nvar6)]
lgmcd <- thetad[nall]
gamacd <- exp(lgmcd)
thetan <- thetad+root%%norm(nall)
betan1 <- thetan[1:nvar6]
betan2 <- thetan[(nvar6+1):(nvar5+nvar6)]
lgmcn <- thetan[nall]
gamacn <- exp(lgmcn)

lsgmd <- oldlsgm[i,1:2]

lacd <- oldlacs[i,1:2]
lacd1 <- oldlacs[i,1]
lacd2 <- oldlacs[i,2]
aced1 <- exp(lacd1)/(1+exp(lacd1)+exp(lacd2))
aced2 <- exp(lacd2)/(1+exp(lacd1)+exp(lacd2))
lacn <- lacd+roota%%norm(nace)
lacn1 <- lacn[1]
lacn2 <- lacn[2]
acen1 <- exp(lacn1)/(1+exp(lacn1)+exp(lacn2))
acen2 <- exp(lacn2)/(1+exp(lacn1)+exp(lacn2))

cummd <- aced1*cumm1+aced2*cumm2+(1-aced1-aced2)*cumm3
cummn <- acen1*cumm1+acen2*cumm2+(1-acen1-acen2)*cumm3

lcumd <- log((cummd/1000)+0.0001)
lcumn <- log((cummn/1000)+0.0001)

Xycd <- cbind(yy,XX,cummd,lcumd)
Xycn <- cbind(yy,XX,cummn,lcumn)

##### regime data grouping for theta

cnt1d <- 0; cnt2d <- 0
cnt1n <- 0; cnt2n <- 0

y1d <- NULL; y2d <- NULL; X1d <- NULL; X2d <- NULL
y1n <- NULL; y2n <- NULL; X1n <- NULL; X2n <- NULL

##### stochastic parameter selection for theta #####

y1d <- subset(Xycd,Xycd[,7]>=gamacd,select=c(1))
X1d <- subset(Xycd,Xycd[,7]>=gamacd,select=c(2,3,4,5,6,8))
cnt1d <- nrow(y1d)

```

```

y2d <- subset(Xycd,Xycd[,7]< gamacd,select=c(1))
X2d <- subset(Xycd,Xycd[,7]< gamacd,select=c(2,3,4,5,6))
cnt2d <- nrow(y2d)

y1n <- subset(Xycd,Xycd[,7]>=gamacn,select=c(1))
X1n <- subset(Xycd,Xycd[,7]>=gamacn,select=c(2,3,4,5,6,8))
cnt1n <- nrow(y1n)

y2n <- subset(Xycd,Xycd[,7]< gamacn,select=c(1))
X2n <- subset(Xycd,Xycd[,7]< gamacn,select=c(2,3,4,5,6))
cnt2n <- nrow(y2n)

betad1 <- c(betad1[1:6],lsgmd[1])
betad2 <- c(betad2[1:5],lsgmd[2])

betan1 <- c(betan1[1:6],lsgmd[1])
betan2 <- c(betan2[1:5],lsgmd[2])

logold1 <- 0; logold2 <- 0; logoldk <- 0
lognew1 <- 0; lognew2 <- 0; lognewk <- 0

logsum <- 0
alpha <- NULL

lognewk <- -0.5*(t(thetan)-Z[i,]%%oldDelta)%%oldVi%%(thetan-t(Z[i,]%%oldDelta))
logoldk <- -0.5*(t(thetad)-Z[i,]%%oldDelta)%%oldVi%%(thetad-t(Z[i,]%%oldDelta))

if (cnt1d>0) {
  logold1 <- LN6(y1d,X1d,betad1)
} else {
  logold1 <- 0
}
if (cnt2d>0) {
  logold2 <- LN5(y2d,X2d,betad2)
} else {
  logold2 <- 0
}
if (cnt1n>0) {
  lognew1 <- LN6(y1n,X1n,betan1)
} else {
  lognew1 <- 0
}
if (cnt2n>0) {
  lognew2 <- LN5(y2n,X2n,betan2)
} else {
  lognew2 <- 0
}

```

```

logsum      <- lognew1+lognew2+lognewk-logold1-logold2-logoldk
alpha       <- exp(logsum)

if (alpha=="NaN")
  alpha=-1

u <- runif(1)

if (u < alpha) {
  oldtheta[i,] <- thetan
  betad1      <- betan1
  betad2      <- betan2
  lgmcd       <- lgmcn
  gamacd      <- gamacn
} else {
  reject[iter,1] <- reject[iter,1]+1
}

##### regime data grouping for sigma #####

cnt1dg <- 0; cnt2dg <- 0

y1dg   <- NULL; y2dg   <- NULL; X1dg   <- NULL; X2dg   <- NULL

y1dg   <- subset(Xycd,Xycd[,7]>=gamacd,select=c(1))
X1dg   <- subset(Xycd,Xycd[,7]>=gamacd,select=c(2,3,4,5,6,8))
cnt1dg <- nrow(y1dg)

y2dg   <- subset(Xycd,Xycd[,7]< gamacd,select=c(1))
X2dg   <- subset(Xycd,Xycd[,7]< gamacd,select=c(2,3,4,5,6))
cnt2dg <- nrow(y2dg)

n1     <- cnt1dg
cp1    <- crossprod(log(y1dg)-X1dg%*%betad1[1:6])
v1     <- v0+n1
S1     <- v0*S0+cp1
sgm1   <- rinvgamma(1,v1/2,S1/2)
lsgmd1 <- log(sgm1)

n2     <- cnt2dg
cp2    <- crossprod(log(y2dg)-X2dg%*%betad2[1:5])
v2     <- v0+n2
S2     <- v0*S0+cp2
sgm2   <- rinvgamma(1,v2/2,S2/2)
lsgmd2 <- log(sgm2)

oldlsgm[i,1:2] <- c(lsgmd1,lsgmd2)

```

```

##### regime data grouping for alpha #####

cnt1da <- 0; cnt2da <- 0; cnt1na <- 0; cnt2na <- 0

y1da <- NULL; y2da <- NULL; X1da <- NULL; X2da <- NULL
y1na <- NULL; y2na <- NULL; X1na <- NULL; X2na <- NULL

y1da <- subset(Xycd,Xycd[,7]>=gamacd,select=c(1))
X1da <- subset(Xycd,Xycd[,7]>=gamacd,select=c(2,3,4,5,6,8))
cnt1da <- nrow(y1da)

y2da <- subset(Xycd,Xycd[,7]<gamacd,select=c(1))
X2da <- subset(Xycd,Xycd[,7]<gamacd,select=c(2,3,4,5,6))
cnt2da <- nrow(y2da)

y1na <- subset(Xycn,Xycn[,7]>=gamacd,select=c(1))
X1na <- subset(Xycn,Xycn[,7]>=gamacd,select=c(2,3,4,5,6,8))
cnt1na <- nrow(y1na)

y2na <- subset(Xycn,Xycn[,7]<gamacd,select=c(1))
X2na <- subset(Xycn,Xycn[,7]<gamacd,select=c(2,3,4,5,6))
cnt2na <- nrow(y2na)

logold1a <- 0; logold2a <- 0; logoldka <- 0
lognew1a <- 0; lognew2a <- 0; lognewka <- 0

logsuma <- 0
alphace <- NULL

lognewka <- -0.5*(t(lacd)-Z[i,]**oldDeltace)**oldVacei**(lacd-t(Z[i,]**oldDeltace))
logoldka <- -0.5*(t(lacn)-Z[i,]**oldDeltace)**oldVacei**(lacn-t(Z[i,]**oldDeltace))

if (cnt1da>0) {
  logold1a <- LN6(y1da,X1da,betad1)
} else {
  logold1a <- 0
}
if (cnt2da>0) {
  logold2a <- LN5(y2da,X2da,betad2)
} else {
  logold2a <- 0
}
if (cnt1na>0) {
  lognew1a <- LN6(y1na,X1na,betad1)
} else {
  lognew1a <- 0
}
if (cnt2na>0) {

```

```

lognew2a <- LN5(y2na , X2na , betad2)
} else {
lognew2a <- 0
}

logsuma <- lognew1a+lognew2a+lognewka-logold1a-logold2a-logoldka
alphace <- exp(logsuma)

if ( alphace=="NaN")
alphace=-1

u <- runif(1)

if (u < alphace) {
oldlacs[i,] <- lacn
logold1 <- lognew1a
logold2 <- lognew2a
cnt <- cnt+c(cnt1na , cnt2na)
} else {
reject[iter ,3] <- reject[iter ,3]+1
cnt <- cnt+c(cnt1da , cnt2da)
}
llh <- llh+logold1+logold2

}##### nhh loop end #####

##### rmultireg (oldtheta , Z, Deltabar , ADelta , nu , V) #####
nth = nrow (oldtheta )
mth = ncol (oldtheta )
kth = ncol (Z)
RAth = chol (ADelta)
Wth = rbind (Z, RAth)
Zth = rbind (oldtheta , RAth%%Deltabar)
IRth = backsolve (chol (crossprod (Wth)) , diag (kth))
Btildeth = crossprod (t (IRth))%%crossprod (Wth, Zth)
Sth = crossprod (Zth-Wth%%Btildeth)
rwouth = rwishart (nu+nth , chol2inv (chol (V+Sth)))
Bth = Btildeth+IRth%%matrix (rnorm (mth*kth) , ncol=mth)%%t (rwouth$CI)
oldDelta <- Bth
oldV <- rwouth$IW
oldVi <- solve (oldV)

##### rmultireg (oldlacs , Z, Deltabace , ADeltace , nua , Vace) #####
nac = nrow (oldlacs)
mac = ncol (oldlacs)
kac = ncol (Z)
RAce = chol (ADeltace)
Wac = rbind (Z, RAce)

```

```

Zac      = rbind( oldlacs ,RAce%%Deltabace )
IRac     = backsolve( chol( crossprod( Wac ) ) , diag( kac ) )
Btildace = crossprod( t( IRac ) ) %% crossprod( Wac , Zac )
Sac      = crossprod( Zac - Wac ) %% Btildace )
rwouac   = rwishart( nua+nac , chol2inv( chol( Vace+Sac ) ) )
Bac      = Btildace+IRac%%matrix( rnorm( mac*kac ) , ncol=mac ) %% t( rwouac$CI )
oldDeltace <- Bac
oldVace   <- rwouac$IW
oldVacei  <- solve( oldVace )

##### store estimated results/draws #####

mkeep <- iter

lackeep1 <- oldlacs [,1]
lackeep2 <- oldlacs [,2]
acekeep1 <- exp( lackeep1 ) / ( 1 + exp( lackeep1 ) + exp( lackeep2 ) )
acekeep2 <- exp( lackeep2 ) / ( 1 + exp( lackeep1 ) + exp( lackeep2 ) )

count    [mkeep, ] <- cnt/171188
thetadraw [mkeep, ] <- oldtheta [, ]
lgmcdraw [mkeep, ] <- oldtheta [,12]
gamacdrow [mkeep, ] <- exp( oldtheta [,12] )
lsgmdraw [mkeep, ] <- oldlsgm
sigmadraw [mkeep, ] <- exp( oldlsgm )

acedraw   [mkeep, ] <- cbind( acekeep1 , acekeep2 )
lacdrow   [mkeep, ] <- cbind( lackeep1 , lackeep2 )
llhall    [mkeep, ] <- llh
deltadraw [mkeep, ] <- oldDelta [, ]
deltadrawa [mkeep, ] <- oldDeltace [, ]
deltadrawg [mkeep, ] <- oldDeltag [, ]

} ### mcmc loop end of mental_accounting_duration1.R ###

```

## 付録C 第5章の付録

### C.1 分布パラメータの構造化

本研究では、 $y_{i,t_i}$  が非負連続データである点を考慮し、各レジームの確率密度関数には、ワイブル分布、対数正規分布、対数ロジスティック分布のいずれかの分布を仮定する。指数分布は、ワイブル分布で形状パラメータが1となる特別な場合として捉え、ワイブル分布に含める。また、各レジームで分布が同一であるとは限らない。各分布パラメータは、消費者を識別する添え字  $i$  を有し、レジームごとに異なる消費者の評価関数を表現する。分布パラメータの構造化において、消費者  $i$  のレジーム  $k$  の回帰係数を  $\beta_i^{(k)} = (\beta_{i,1}^{(k)}, \beta_{i,2}^{(k)}, \dots, \beta_{i,p_k}^{(k)})^t$ ,  $k = 1, 2, 3, 4$  によりレジームを区別する。各レジーム回帰係数の次元  $p_k$  は、説明変数  $\mathbf{x}_{i,t_i} = (x_{i,t_i,1}, x_{i,t_i,2}, \dots, x_{i,t_i,p_k})^t$  の次元と同一であり、本研究の実証分析では  $k$  の値に関わらず  $p_k = 5$  である。(以降、特に明記のない限り、 $\beta_i$  のように添字 ( $k$ ) が無いものは、4 レジームいずれかの次元  $p_k$  の回帰係数をさすものとする。) 以下に、各分布パラメータの構造化について説明する。

#### C.1.1 ワイブル分布

ワイブル分布の確率密度関数を (C.1) 式に示す。尺度パラメータ  $\xi_{i,t_i}$  は非負制約を有することから、レジームの説明変数  $\mathbf{x}_{i,t_i}$  と回帰係数  $\beta_i$  の対数線形変換で構造化し、 $\ln(\tau_{i,t_i}) = \mathbf{x}_{i,t_i}^t \beta_i$  とする。ここで、回帰係数  $\beta_i$  は消費者  $i$  ごとに固定なパラメータであるが、説明変数  $\mathbf{x}_{i,t_i}$  は時点にも依存して異なるため、尺度パラメータ  $\tau_{i,t_i}$  は時点ごとに変化する。形状パラメータ  $\kappa_i$  も非負制約を有するため、 $\tau_{i,t_i} > 0$ ,  $\kappa_i > 0$  となる。この分布パラメータベクトルは  $\theta_{i,t_i} = (\tau_{i,t_i}, \kappa_i)^t$  である。

$$f(y_{i,t_i}) = \frac{\kappa_i}{\tau_{i,t_i}} \left( \frac{y_{i,t_i}}{\tau_{i,t_i}} \right)^{\kappa_i - 1} \exp \left[ - \left( \frac{y_{i,t_i}}{\tau_{i,t_i}} \right)^{\kappa_i} \right] \quad (\text{C.1})$$

指数分布は、ワイブル分布の特別なケースであり、(C.1) 式で  $\kappa_i = 1$  の場合に相当する。このとき、指数分布の確率密度関数は (C.2) 式に示すように簡略化される。

$$f(y_{i,t_i}) = \frac{1}{\tau_{i,t_i}} \exp \left[ - \left( \frac{y_{i,t_i}}{\tau_{i,t_i}} \right) \right] \quad (\text{C.2})$$

### C.1.2 対数正規分布

対数正規分布の確率密度関数を (C.3) 式に示す。対数正規分布は、観測値  $y_{i,t_i}$  の対数値が正規分布に従う分布関数である。消費者  $i$  ごとに固定とする分散パラメータ  $\sigma_i^2$  は非負制約を有するが、時点ごとの説明変数  $\mathbf{x}_{i,t_i}$  と回帰係数  $\beta_i$  の線形変換  $\mu_{i,t_i} = \mathbf{x}_{i,t_i}' \beta_{ln,i}$  で構造化する位置パラメータ  $\mu_{i,t_i}$  には制約はないため、 $\sigma_i > 0$ 、 $\mu_{i,t_i}$  は全ての実数となる。回帰係数  $\beta_i$  は消費者  $i$  ごとに固定なパラメータであるが、説明変数  $\mathbf{x}_{i,t_i}$  は時点によって異なるため、位置パラメータ  $\mu_{i,t_i}$  は時点ごとに変化する。この分布パラメータベクトルは  $\theta_{i,t_i} = (\mu_{i,t_i}, \sigma_i^2)'$  である。

$$f(y_{i,t_i}) = \frac{1}{\sqrt{2\pi}\sigma_i y_{i,t_i}} \exp \left[ - \frac{1}{2} \left( \frac{\ln(y_{i,t_i}) - \mu_{i,t_i}}{\sigma_i} \right)^2 \right] \quad (\text{C.3})$$

### C.1.3 対数ロジスティック分布

対数ロジスティック分布の確率密度関数を (C.4) 式に示す。対数ロジスティック分布は、観測値  $y_{i,t_i}$  の対数値がロジスティック分布に従う分布関数である。消費者  $i$  ごとに固定である尺度パラメータ  $s_i$  は非負制約を有するが、時点ごとの説明変数  $\mathbf{x}_{i,t_i}$  と回帰係数  $\beta_i$  の線形変換  $\eta_{i,t_i} = \mathbf{x}_{i,t_i}' \beta_{ln,i}$  で構造化する位置パラメータ  $\eta_{i,t_i}$  には制約はないため、 $s_i > 0$ 、 $\eta_{i,t_i}$  は全ての実数となる。回帰係数  $\beta_i$  は消費者  $i$  ごとに固定なパラメータであるが、説明変数  $\mathbf{x}_{i,t_i}$  は時点によって異なるため、位置パラメータ  $\eta_{i,t_i}$  は時点ごとに変化する。この分布パラメータベクトルは  $\theta_{i,t_i} = (\eta_{i,t_i}, s_i)'$  である。

$$f(y_{i,t_i}) = \frac{\exp \left[ - \left( \frac{\ln(y_{i,t_i}) - \eta_{i,t_i}}{s_i} \right) \right]}{s_i y_{i,t_i} \left( 1 + \exp \left[ - \left( \frac{\ln(y_{i,t_i}) - \eta_{i,t_i}}{s_i} \right) \right] \right)^2} \quad (\text{C.4})$$

ちなみに、対数ロジスティック分布の確率密度関数を (C.5) 式のように表記することもあるが、これは (C.4) 式において、 $\alpha = e^\mu, \beta = 1/s$  とした場合に同一である。但し、この場合

は  $\alpha > 0$  の制約条件が課される．本研究では，対数ロジスティック分布の密度関数は，(C.4) 式の形式で表すものとする．

$$f(y_{i,t_i}) = \frac{(\beta/\alpha)(y_{i,t_i}/\alpha)^{\beta-1}}{\{1 + (y_{i,t_i}/\alpha)^\beta\}^2} \quad (\text{C.5})$$

## C.2 推定アルゴリズム

本付録には，提案モデルを推定するためのアルゴリズムを示す．パラメータ推定にマルコフ連鎖モンテカルロ法 (MCMC) を用いる．具体的には， $\Psi, \mathcal{A}$  のサンプリングにはランダムウォーク M-H 法を， $\Delta_\psi, \Delta_\alpha, \Sigma_\psi, \Sigma_\alpha$  のサンプリングにはギブスサンプリングをそれぞれ用いる．

1. 初期値  $\psi_i^{(0)}, \alpha_i^{(0)}$  を設定する．
2.  $r = 1, 2, \dots$  について，次を繰り返す．
  - (a)  $i = 1, 2, \dots, H$  について，次を繰り返す．
    - i. 新しい候補  $\psi_i$  を， $\psi_i^{(r-1)}$  が与えられたもとの  $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \sigma_{RW_\psi}^2 \mathbf{I})$  をサンプリングし， $\psi_i = \psi_i^{(r-1)} + \mathbf{w}$  に従い発生させる．ただし， $\sigma_{RW_\psi}^2 = 0.001$
    - ii. 次の採択確率を計算する．
$$a_i^\psi(\psi_i, \psi_i^{(r-1)}) = \min \left\{ \frac{p(\mathbf{y}_i | \psi_i, \alpha_i, \mathbf{x}_i) p(\psi_i | \Delta_\psi, \Sigma_\psi, \mathbf{z}_i)}{p(\mathbf{y}_i | \psi_i^{(r-1)}, \alpha_i, \mathbf{x}_i) p(\psi_i^{(r-1)} | \Delta_\psi, \Sigma_\psi, \mathbf{z}_i)}, 1 \right\}$$
    - iii. 一様乱数  $u \sim \mathcal{U}(0, 1)$  をサンプリングして，次の通りに確率的選択を行う．
$$\psi_i^{(r)} = \begin{cases} \psi_i & u < a_i^\psi \\ \psi_i^{(r-1)} & \text{上記以外} \end{cases}$$
    - iv. 新しい候補  $\alpha_i$  を， $\alpha_i^{(r-1)}$  が与えられたもとの  $\mathbf{w} \sim \mathcal{N}(\mathbf{0}, \sigma_{RW_\alpha}^2 \mathbf{I})$  をサンプリングし， $\alpha_i = \alpha_i^{(r-1)} + \mathbf{w}$  に従い発生させる．ただし， $\sigma_{RW_\alpha}^2 = 0.01$
    - v. 次の採択確率を計算する．
$$a_i^\alpha(\alpha_i, \alpha_i^{(r-1)}) = \min \left\{ \frac{p(\mathbf{y}_i | \psi_i, \alpha_i, \mathbf{x}_i) p(\alpha_i | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i)}{p(\mathbf{y}_i | \psi_i, \alpha_i^{(r-1)}, \mathbf{x}_i) p(\alpha_i^{(r-1)} | \Delta_\alpha, \Sigma_\alpha, \mathbf{z}_i)}, 1 \right\}$$
    - vi. 一様乱数  $u \sim \mathcal{U}(0, 1)$  をサンプリングして，次の通りに確率的選択を行う．
$$\alpha_i^{(r)} = \begin{cases} \alpha_i & u < a_i^\alpha \\ \alpha_i^{(r-1)} & \text{上記以外} \end{cases}$$

(b)  $\delta_\psi = \text{vec}(\Delta_\psi)$ ,  $\Sigma_\psi$  を次の通りに発生させる.

i.  $\delta_\psi^{(r)} \sim \mathcal{N}(\tilde{\delta}_\psi, \Sigma_\psi \otimes (\mathbf{Z}^t \mathbf{Z} + \mathbf{A}_\psi)^{-1})$

ii.  $\Sigma_\psi^{(r)} \sim \text{IW}(u_{\psi,0} + H, \mathbf{V}_{\psi,0} + \mathbf{S}_\psi)$

但し,  $\tilde{\delta}_\psi = \text{vec}(\tilde{\Delta}_\psi)$ ,  $\tilde{\Delta}_\psi = (\mathbf{Z}^t \mathbf{Z} + \mathbf{A}_\psi)^{-1} (\mathbf{Z}^t \mathbf{Z} \hat{\Delta}_\psi + \mathbf{A}_\psi \bar{\Delta}_\psi)$ ,  $\hat{\Delta}_\psi = (\mathbf{Z}^t \mathbf{Z})^{-1} \mathbf{Z}^t \Psi$

$\mathbf{S}_\psi = \sum_{i=1}^H (\psi_i - \bar{\psi}_i)(\psi_i - \bar{\psi}_i)^t \Psi = (\psi_1, \psi_2, \dots, \psi_H)$

(c)  $\delta_\alpha = \text{vec}(\Delta_\alpha)$ ,  $\Sigma_\alpha$  を次の通りに発生させる.

i.  $\delta_\alpha^{(r)} \sim \mathcal{N}(\tilde{\delta}_\alpha, \Sigma_\alpha \otimes (\mathbf{Z}^t \mathbf{Z} + \mathbf{A}_\alpha)^{-1})$

ii.  $\Sigma_\alpha^{(r)} \sim \text{IW}(u_{\alpha,0} + H, \mathbf{V}_{\alpha,0} + \mathbf{S}_\alpha)$

但し,  $\tilde{\delta}_\alpha = \text{vec}(\tilde{\Delta}_\alpha)$ ,  $\tilde{\Delta}_\alpha = (\mathbf{Z}^t \mathbf{Z} + \mathbf{A}_\alpha)^{-1} (\mathbf{Z}^t \mathbf{Z} \hat{\Delta}_\alpha + \mathbf{A}_\alpha \bar{\Delta}_\alpha)$ ,  $\hat{\Delta}_\alpha = (\mathbf{Z}^t \mathbf{Z})^{-1} \mathbf{Z}^t \mathcal{A}$ ,

$\mathbf{S}_\alpha = \sum_{i=1}^H (\alpha_i - \bar{\alpha}_i)(\alpha_i - \bar{\alpha}_i)^t$ ,  $\mathcal{A} = (\alpha_1, \alpha_2, \dots, \alpha_H)$

3. 十分に大きな  $r$  に対して,  $\psi_i^{(r)}, \alpha_i^{(r)}, \delta_\psi^{(r)}, \Sigma_\psi^{(r)}, \delta_\alpha^{(r)}, \Sigma_\alpha^{(r)}$  ( $r = N, N+1, \dots$ ) を記憶する. 但し, 緩慢な事前分布を表現するために, 照井 (2008) と同様, 事前分布として次の通り設定した.  $\tilde{\delta}_\psi = \mathbf{0}, \tilde{\delta}_\alpha = \mathbf{0}$ ,  $\mathbf{A}_\psi = 0.001\mathbf{I}, \mathbf{A}_\alpha = 0.001\mathbf{I}$ ,  $u_{\psi,0} = 30, u_{\alpha,0} = 6$ ,  $\mathbf{V}_{\psi,0} = u_{\psi,0}\mathbf{I}, \mathbf{V}_{\alpha,0} = u_{\alpha,0}\mathbf{I}$ . なお, ベイズ統計に関する理論については, Rossi et al. (2005), 和合 (2005), 照井 (2008), 里村 (2010), 佐藤・樋口 (2013), 佐藤 (2015) などを参考のこと.

### C.3 推定用Rプログラム

```
##### mental_accounting_duration2.R #####
library(MASS)
library(MCMCpack)
library(bayesm)
set.seed(555)

##### data formatting for bayesian estimation
dataZ1 <- read.csv("HBPD665_dataZ.csv")
dataZ2 <- read.csv("inv0consZ.csv")
datayX <- read.csv("HBPD675_datayX.csv")
datayXS <- read.csv("HBPD655_datayXS.csv")
paid_1x <- read.csv("paid_1x.csv")
inv_tbl <- read.csv("inv_table.csv")
dataZ <- cbind(dataZ1, dataZ2)

nvar <- 5; nsgm1 <- 1; nsgm2 <- 1; nsgm3 <- 1; nsgm4 <- 1
nzet <- 5; nace <- 2; ngam <- 2
nall <- 4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+ngam

nhh <- 100
nobs <- dataZ[1:nhh,2]
inv0 <- inv_tbl[,3]
cons <- inv_tbl[,2]
paid_1 <- paid_1x[,2]

nob0 <- 1; nob1 <- nobs[1]
kt <- nrow(datayX)

dataInv <- array(double(kt), dim=c(kt,1))
for (i in 1:nhh) {
  recs <- nobs[i]
  consume <- cons[i]
  dataInv[nob0] <- inv0[i]

  for (j in 2:recs) {
    inv_t <- dataInv[nob0-1+j-1]+ paid_1[nob0-1+j]-consume*datayX[nob0-1+j,2]
    if (inv_t < 0) {
      dataInv[nob0-1+j] <- 0
    } else {
      dataInv[nob0-1+j] <- inv_t
    }
  }
  nob0 <- nob1+1
  nob1 <- nob0+nobs[i+1]-1
}
}
```

```

Z    <- as.matrix(dataZ[1:nhh,3:(2+nzet)])

hhdata <- NULL
nob0  <- 1; nob1  <- nobs[1]

for (i in 1:nhh) {
  inv   <- as.matrix(dataInv[nob0:nob1,1])
  X     <- as.matrix(datayX[nob0:nob1,3:7])
  y     <- as.matrix(datayX[nob0:nob1,2])
  cumm1 <- as.matrix(datayX[nob0:nob1,9])
  cumm2 <- as.matrix(datayX[nob0:nob1,10])
  cumm3 <- as.matrix(datayX[nob0:nob1,11])

  hhdata[[i]] <- list(y=y,X=X,cumm1=cumm1,cumm2=cumm2,cumm3=cumm3,inv=inv)
  nob0 <- nob1+1
  nob1 <- nob0+nobs[i+1]-1
}

##### log-normal: LN #####
LN5 <- function(y,X,beta) {
  ll <- -0.5*log(2*pi)-log(y)-log(exp(beta[6]))-0.5*((1/exp(beta[6]))^2)*(log(y)
    -X%%beta[1:5])^2
  sum(ll)
}

##### log-logistic: LL #####
LL5 <- function(y,X,beta) {
  ll <- -log(y)-log(exp(beta[6]))-(1/exp(beta[6]))*(log(y)-X%%beta[1:5])
    -2*log(1+exp(-(1/exp(beta[6]))*(log(y)-X%%beta[1:5])))
  sum(ll)
}

##### weibull: WE #####
WE5 <- function(y,X,beta) {
  ll <- -(exp(beta[6]))*(X%%beta[1:5])+log(exp(beta[6]))+(exp(beta[6])-1)*log(y)
    -(y/exp(X%%beta[1:5]))^exp(beta[6])
  sum(ll)
}

##### bayesian parameters #####
R    <- 50000

ace0  <- c(0.333,0.333)
gamma0c <- matrix(rep(0,nhh),nhh,1)
gamma0i <- matrix(rep(0,nhh),nhh,1)

```

```

for (i in 1:nhh) {
  gamma0c[i] <- mean(hhdata[[i]]$cumml)
  gamma0i[i] <- dataZ[i,9]
}

s      <- 0.000001
A      <- 0.001
nu     <- nall+4
dcnt   <- rep(1, nall-2)
V      <- nu*diag(c(dcnt,0.5,0.5))
ADelta <- A*diag(nzet)
Deltabar <- matrix(rep(0, nzet*nall), nzet, nall)

sa     <- 0.0001
Aa     <- 0.001
nua    <- nace+4
Vace   <- nua*diag(rep(1, nace))
ADeltace <- A*diag(nzet)
Deltabace <- matrix(rep(0, nzet*nace), nzet, nace)

oldbetas <- matrix(double(nhh*(nall-2)), nhh, (nall-2))
oldgammac <- gamma0c
oldgammai <- gamma0i
oldlgmc <- log(oldgammac)
oldlgmi <- log(oldgammai)
oldtheta <- cbind(oldbetas, oldlgmc, oldlgmi)

ace1 <- matrix(ace0[1], nhh)
ace2 <- matrix(ace0[2], nhh)
oldaces <- cbind(ace1, ace2)
lac1 <- log(ace1/(1-ace1-ace2))
lac2 <- log(ace2/(1-ace1-ace2))
oldlacs <- cbind(lac1, lac2)

oldV <- diag(nall)
oldVi <- diag(nall)
oldDelta <- matrix(double(nzet*nall), nzet, nall)

oldVace <- diag(nace)
oldVacei <- diag(nace)
oldDeltace <- matrix(double(nzet*nace), nzet, nace)

thetadraw <- array(double(floor(R)*nhh*nall), dim=c(floor(R), nhh, nall))
gamacdraw <- array(double(floor(R)*nhh*1), dim=c(floor(R), nhh, 1))
gamaidraw <- array(double(floor(R)*nhh*1), dim=c(floor(R), nhh, 1))
acedraw <- array(double(floor(R)*nhh*nace), dim=c(floor(R), nhh, nace))
lacdraw <- array(double(floor(R)*nhh*nace), dim=c(floor(R), nhh, nace))
llhall <- array(double(floor(R)*1), dim=c(floor(R), 1))

```

```

deltadraw <- array(double(floor(R)*nzet*nall),dim=c(floor(R),nzet,nall))
deltadraw2 <- array(double(floor(R)*nzet*nace),dim=c(floor(R),nzet,nace))
reject <- array(0,dim=c(floor(R),2))
count <- array(0,dim=c(floor(R),4))

##### mcmc loop starts #####

for (iter in 1:R) {

  llh <- 0; cnt <-c(0,0,0,0)
  sV <- s*V; sVace <- sa*Vace
  root <- t(chol(sV)); roota <- t(chol(sVace))

##### nnh loop starts #####

for (i in 1:nhh) {

  recs <- nobs[i]
  yy <- hhdata[[i]]$y
  XX <- hhdata[[i]]$X
  inv <- hhdata[[i]]$inv
  cumm1 <- hhdata[[i]]$cumm1
  cumm2 <- hhdata[[i]]$cumm2
  cumm3 <- hhdata[[i]]$cumm3

  thetad <- oldtheta[i,1:nall]
  betad1 <- thetad[1:(1*nvar+nsgm1)]
  betad2 <- thetad[(1*nvar+nsgm1+1):(2*nvar+nsgm1+nsgm2)]
  betad3 <- thetad[(2*nvar+nsgm1+nsgm2+1):(3*nvar+nsgm1+nsgm2+nsgm3)]
  betad4 <- thetad[(3*nvar+nsgm1+nsgm2+nsgm3+1):(4*nvar+nsgm1+nsgm2+nsgm3+nsgm4)]
  lgmcd <- thetad[4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+1]
  lgmid <- thetad[4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+2]

  thetan <- thetad+root%*%ernorm(nall)

  betan1 <- thetan[1:(1*nvar+nsgm1)]
  betan2 <- thetan[(1*nvar+nsgm1+1):(2*nvar+nsgm1+nsgm2)]
  betan3 <- thetan[(2*nvar+nsgm1+nsgm2+1):(3*nvar+nsgm1+nsgm2+nsgm3)]
  betan4 <- thetan[(3*nvar+nsgm1+nsgm2+nsgm3+1):(4*nvar+nsgm1+nsgm2+nsgm3+nsgm4)]
  lgmcn <- thetan[4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+1]
  lgmin <- thetan[4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+2]

  gamacd <- exp(lgmcd)
  gamaid <- exp(lgmid)
  gamacn <- exp(lgmcn)
  gamain <- exp(lgmin)

  lacd <- oldlacs[i,1:2]

```

```

lacd1 <- oldlacs[i,1]
lacd2 <- oldlacs[i,2]
aced1 <- exp(lacd1)/(1+exp(lacd1)+exp(lacd2))
aced2 <- exp(lacd2)/(1+exp(lacd1)+exp(lacd2))

lacn <- lacd+roota%*%rnorm(nace)

lacn1 <- lacn[1]
lacn2 <- lacn[2]
acen1 <- exp(lacn1)/(1+exp(lacn1)+exp(lacn2))
acen2 <- exp(lacn2)/(1+exp(lacn1)+exp(lacn2))

cummd <- aced1*cumm1+aced2*cumm2+(1-aced1-aced2)*cumm3
cummn <- acen1*cumm1+acen2*cumm2+(1-acen1-acen2)*cumm3

##### regime data grouping for theta #####

cnt1d <- 0; cnt2d <- 0; cnt3d <- 0; cnt4d <- 0
cnt1n <- 0; cnt2n <- 0; cnt3n <- 0; cnt4n <- 0

y1d <- NULL; y2d <- NULL; y3d <- NULL; y4d <- NULL
y1n <- NULL; y2n <- NULL; y3n <- NULL; y4n <- NULL
X1d <- NULL; X2d <- NULL; X3d <- NULL; X4d <- NULL
X1n <- NULL; X2n <- NULL; X3n <- NULL; X4n <- NULL

Xycd <- cbind(yy,XX,cummd,inv)
Xycn <- cbind(yy,XX,cummn,inv)

y1d <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]>=gamaid,select=c(1))
X1d <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]>=gamaid,select=c(2,3,4,5,6))
cnt1d <- nrow(y1d)

y2d <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]>=gamaid,select=c(1))
X2d <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]>=gamaid,select=c(2,3,4,5,6))
cnt2d <- nrow(y2d)

y3d <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]<gamaid,select=c(1))
X3d <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]<gamaid,select=c(2,3,4,5,6))
cnt3d <- nrow(y3d)

y4d <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]<gamaid,select=c(1))
X4d <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]<gamaid,select=c(2,3,4,5,6))
cnt4d <- nrow(y4d)

y1n <- subset(Xycd,Xycd[,7]>=gamacn & Xycd[,8]>=gamain,select=c(1))
X1n <- subset(Xycd,Xycd[,7]>=gamacn & Xycd[,8]>=gamain,select=c(2,3,4,5,6))
cnt1n <- nrow(y1n)

```

```

y2n <- subset(Xycd,Xycd[,7]<gamacn & Xycd[,8]>=gamain , select=c(1))
X2n <- subset(Xycd,Xycd[,7]<gamacn & Xycd[,8]>=gamain , select=c(2,3,4,5,6))
cnt2n <- nrow(y2n)

y3n <- subset(Xycd,Xycd[,7]<gamacn & Xycd[,8]<gamain , select=c(1))
X3n <- subset(Xycd,Xycd[,7]<gamacn & Xycd[,8]<gamain , select=c(2,3,4,5,6))
cnt3n <- nrow(y3n)

y4n <- subset(Xycd,Xycd[,7]>=gamacn & Xycd[,8]<gamain , select=c(1))
X4n <- subset(Xycd,Xycd[,7]>=gamacn & Xycd[,8]<gamain , select=c(2,3,4,5,6))
cnt4n <- nrow(y4n)

##### stochastic parameter selection for theta #####

logold1 <- 0; logold2 <- 0; logold3 <- 0; logold4 <- 0; logoldk <- 0
lognew1 <- 0; lognew2 <- 0; lognew3 <- 0; lognew4 <- 0; lognewk <- 0

logsum <- 0
alpha <- NULL

lognewk <- -0.5*(t(thetan)-Z[i,]**oldDelta)**oldVi*(thetan-t(Z[i,]**oldDelta))
logoldk <- -0.5*(t(thetad)-Z[i,]**oldDelta)**oldVi*(thetad-t(Z[i,]**oldDelta))

if (cnt1d>0) {
  logold1 <- LL5(y1d,X1d,betad1)
} else {
  logold1 <- 0
}
if (cnt2d>0) {
  logold2 <- LN5(y2d,X2d,betad2)
} else {
  logold2 <- 0
}
if (cnt3d>0) {
  logold3 <- LN5(y3d,X3d,betad3)
} else {
  logold3 <- 0
}
if (cnt4d>0) {
  logold4 <- LL5(y4d,X4d,betad4)
} else {
  logold4 <- 0
}

if (cnt1n>0) {
  lognew1 <- LL5(y1n,X1n,betan1)
} else {
  lognew1 <- 0
}

```

```

}
if (cnt2n>0) {
  lognew2 <- LN5(y2n,X2n,betan2)
} else {
  lognew2 <- 0
}
if (cnt3n>0) {
  lognew3 <- LN5(y3n,X3n,betan3)
} else {
  lognew3 <- 0
}
if (cnt4n>0) {
  lognew4 <- LL5(y4n,X4n,betan4)
} else {
  lognew4 <- 0
}

logsum <- (lognew1+lognew2+lognew3+lognew4+lognewk)
          -(logold1+logold2+logold3+logold4+logoldk)
alpha <- exp(logsum)

if (alpha=="NaN")
  alpha=-1

u <- runif(1)

if (u < alpha) {
  oldtheta[i,] <- thetan
  gamacd <- gamacn
  gamaid <- gamain
  betad1 <- betan1
  betad2 <- betan2
  betad3 <- betan3
  betad4 <- betan4
} else {
  reject[iter,1] <- reject[iter,1]+1
}

##### regime data grouping for alpha #####

cnt1da <- 0; cnt2da <- 0; cnt3da <- 0; cnt4da <- 0
cnt1na <- 0; cnt2na <- 0; cnt3na <- 0; cnt4na <- 0

y1da <- NULL; y2da <- NULL; y3da <- NULL; y4da <- NULL
y1na <- NULL; y2na <- NULL; y3na <- NULL; y4na <- NULL
X1da <- NULL; X2da <- NULL; X3da <- NULL; X4da <- NULL
X1na <- NULL; X2na <- NULL; X3na <- NULL; X4na <- NULL

```

```

y1da <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]>=gamaid , select=c(1))
X1da <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]>=gamaid , select=c(2,3,4,5,6))
cnt1da <- nrow(y1da)

y2da <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]>=gamaid , select=c(1))
X2da <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]>=gamaid , select=c(2,3,4,5,6))
cnt2da <- nrow(y2da)

y3da <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]<gamaid , select=c(1))
X3da <- subset(Xycd,Xycd[,7]<gamacd & Xycd[,8]<gamaid , select=c(2,3,4,5,6))
cnt3da <- nrow(y3da)

y4da <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]<gamaid , select=c(1))
X4da <- subset(Xycd,Xycd[,7]>=gamacd & Xycd[,8]<gamaid , select=c(2,3,4,5,6))
cnt4da <- nrow(y4da)

y1na <- subset(Xycn,Xycn[,7]>=gamacd & Xycn[,8]>=gamaid , select=c(1))
X1na <- subset(Xycn,Xycn[,7]>=gamacd & Xycn[,8]>=gamaid , select=c(2,3,4,5,6))
cnt1na <- nrow(y1na)

y2na <- subset(Xycn,Xycn[,7]<gamacd & Xycn[,8]>=gamaid , select=c(1))
X2na <- subset(Xycn,Xycn[,7]<gamacd & Xycn[,8]>=gamaid , select=c(2,3,4,5,6))
cnt2na <- nrow(y2na)

y3na <- subset(Xycn,Xycn[,7]<gamacd & Xycn[,8]<gamaid , select=c(1))
X3na <- subset(Xycn,Xycn[,7]<gamacd & Xycn[,8]<gamaid , select=c(2,3,4,5,6))
cnt3na <- nrow(y3na)

y4na <- subset(Xycn,Xycn[,7]>=gamacd & Xycn[,8]<gamaid , select=c(1))
X4na <- subset(Xycn,Xycn[,7]>=gamacd & Xycn[,8]<gamaid , select=c(2,3,4,5,6))
cnt4na <- nrow(y4na)

##### stochastic parameter selection for alpha #####
logold1a <- 0; logold2a <- 0; logold3a <- 0; logold4a <- 0; logoldka <- 0
lognew1a <- 0; lognew2a <- 0; lognew3a <- 0; lognew4a <- 0; lognewka <- 0

logsuma <- 0
alphace <- NULL

lognewka <- -0.5*(t(lacd)-Z[i,]%%oldDeltace)%%oldVacei%%(lacd-t(Z[i,]%%oldDeltace))
logoldka <- -0.5*(t(lacn)-Z[i,]%%oldDeltace)%%oldVacei%%(lacn-t(Z[i,]%%oldDeltace))

if (cnt1da>0) {
  logold1a <- LL5(y1da,X1da,betad1)
} else {
  logold1a <- 0
}

```

```

if (cnt2da>0) {
  logold2a <- LN5(y2da ,X2da ,betad2)
} else {
  logold2a <- 0
}
if (cnt3da>0) {
  logold3a <- LN5(y3da ,X3da ,betad3)
} else {
  logold3a <- 0
}
if (cnt4da>0) {
  logold4a <- LL5(y4da ,X4da ,betad4)
} else {
  logold4a <- 0
}

if (cnt1na>0) {
  lognew1a <- LL5(y1na ,X1na ,betad1)
} else {
  lognew1a <- 0
}
if (cnt2na>0) {
  lognew2a <- LN5(y2na ,X2na ,betad2)
} else {
  lognew2a <- 0
}
if (cnt3na>0) {
  lognew3a <- LN5(y3na ,X3na ,betad3)
} else {
  lognew3a <- 0
}
if (cnt4na>0) {
  lognew4a <- LL5(y4na ,X4na ,betad4)
} else {
  lognew4a <- 0
}

logsuma <- (lognew1a+lognew2a+lognew3a+lognew4a+lognewka)
          -(logold1a+logold2a+logold3a+logold4a+logoldka)
alphace <- exp(logsuma)

if (alphace=="NaN")
  alphace=-1

u <- runif(1)

if (u < alphace) {
  oldlacs[i ,] <- lacn

```

```

logold1      <- lognew1a
logold2      <- lognew2a
logold3      <- lognew3a
logold4      <- lognew4a
  cnt        <- cnt+c(cnt1na ,cnt2na ,cnt3na ,cnt4na)
} else {
  reject[iter ,2] <- reject[iter ,2]+1
  logold1      <- logold1a
  logold2      <- logold2a
  logold3      <- logold3a
  logold4      <- logold4a
  cnt          <- cnt+c(cnt1da ,cnt2da ,cnt3da ,cnt4da)
}
llh <- llh+logold1+logold2+logold3+logold4

} ##### nhh loop end #####

##### rmultireg ( oldtheta ,Z, Deltabar ,ADelta ,nu ,V) #####
nth      = nrow ( oldtheta )
mth      = ncol ( oldtheta )
kth      = ncol ( Z )
RAth     = chol ( ADelta )
Wth      = rbind ( Z, RAth )
Zth      = rbind ( oldtheta ,RAth%%Deltabar )
IRth     = backsolve ( chol ( crossprod ( Wth ) ) , diag ( kth ) )
Btildeth = crossprod ( t ( IRth ) ) %% crossprod ( Wth , Zth )
Sth      = crossprod ( Zth - Wth %% Btildeth )
rwouth   = rwishart ( nu + nth , chol2inv ( chol ( V + Sth ) ) )
Bth      = Btildeth + IRth %% matrix ( rnorm ( mth * kth ) , ncol = mth ) %% t ( rwouth $ CI )
oldDelta <- Bth
oldV     <- rwouth $ IW
oldVi    <- solve ( oldV )

##### rmultireg ( oldlacs ,Z, Deltabace ,ADeltace ,nua ,Vace) #####
nac      = nrow ( oldlacs )
mac      = ncol ( oldlacs )
kac      = ncol ( Z )
RAce     = chol ( ADeltace )
Wac      = rbind ( Z, RAce )
Zac      = rbind ( oldlacs ,RAce%%Deltabace )
IRac     = backsolve ( chol ( crossprod ( Wac ) ) , diag ( kac ) )
Btildace = crossprod ( t ( IRac ) ) %% crossprod ( Wac , Zac )
Sac      = crossprod ( Zac - Wac %% Btildace )
rwouac   = rwishart ( nua + nac , chol2inv ( chol ( Vace + Sac ) ) )
Bac      = Btildace + IRac %% matrix ( rnorm ( mac * kac ) , ncol = mac ) %% t ( rwouac $ CI )
oldDeltace <- Bac
oldVace   <- rwouac $ IW
oldVacei  <- solve ( oldVace )

```

```

##### store estimated results/draws #####

mkeep <- iter

  lgmckeeper <- oldtheta[,4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+1]
  lgmikeep <- oldtheta[,4*nvar+nsgm1+nsgm2+nsgm3+nsgm4+2]
  gamackeeper <- exp(lgmckeeper)
  gamaikeep <- exp(lgmikeep)

  lackeeper1 <- oldlacs[,1]
  lackeeper2 <- oldlacs[,2]
  acekeeper1 <- exp(lackeeper1)/(1+exp(lackeeper1)+exp(lackeeper2))
  acekeeper2 <- exp(lackeeper2)/(1+exp(lackeeper1)+exp(lackeeper2))

  count [mkeep, ] <- cnt/171188
  thetadraw [mkeep, ] <- oldtheta[, ]
  gamacdraw [mkeep, ] <- gamackeeper
  gamaidraw [mkeep, ] <- gamaikeep
  acedraw [mkeep, ] <- cbind(acekeeper1, acekeeper2)
  lacdraw [mkeep, ] <- cbind(lackeeper1, lackeeper2)
  llhall [mkeep, ] <- llh
  deltadraw [mkeep, ] <- oldDelta[, ]
  deltadraw2 [mkeep, ] <- oldDeltace[, ]

} ### mcmc loop end of mental_accounting_duration2.R ###

```

## C.4 対数周辺尤度およびDICによるモデル評価

(レゾーム1)	(レゾーム2)	(レゾーム3)	(レゾーム4)	対数周辺尤度	DIC	(レゾーム1)	(レゾーム2)	(レゾーム3)	(レゾーム4)	対数周辺尤度	DIC
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-23,297.69	46,693.70	対数正規分布	対数正規分布	対数正規分布	対数正規分布	-20,287.09	40,835.99
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	22,931.24	46,137.21	対数正規分布	対数正規分布	対数正規分布	ワイブル分布	-20,774.24	41,804.60
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-23,201.73	46,651.83	対数正規分布	対数正規分布	対数正規分布	ワイブル分布	-20,475.74	41,198.28
ワイブル分布	ワイブル分布	対数正規分布	ワイブル分布	45,642.32	45,642.32	対数正規分布	対数正規分布	対数正規分布	対数正規分布	-20,740.19	41,754.09
ワイブル分布	ワイブル分布	対数正規分布	対数正規分布	-22,647.01	45,611.82	対数正規分布	対数正規分布	ワイブル分布	ワイブル分布	-20,713.38	41,713.54
ワイブル分布	ワイブル分布	対数正規分布	対数正規分布	22,695.53	45,644.04	対数正規分布	対数正規分布	ワイブル分布	対数正規分布	-20,404.75	41,013.38
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-23,172.62	46,610.77	対数正規分布	対数正規分布	ワイブル分布	ワイブル分布	-20,738.49	41,678.37
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-22,893.35	46,107.90	対数正規分布	対数正規分布	対数正規分布	ワイブル分布	-20,569.84	41,364.07
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-23,167.58	46,342.79	対数正規分布	対数正規分布	対数正規分布	対数正規分布	-20,205.24	40,571.09
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,554.72	43,395.96	対数正規分布	対数正規分布	対数正規分布	ワイブル分布	-20,535.08	41,231.44
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	21,341.17	42,991.21	対数正規分布	対数正規分布	対数正規分布	ワイブル分布	-20,660.93	41,505.11
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-21,357.38	42,689.60	対数正規分布	対数正規分布	ワイブル分布	ワイブル分布	-20,195.41	40,602.67
ワイブル分布	ワイブル分布	対数正規分布	ワイブル分布	-21,051.24	42,335.07	対数正規分布	対数正規分布	ワイブル分布	ワイブル分布	-20,513.76	41,198.07
ワイブル分布	ワイブル分布	対数正規分布	対数正規分布	-20,955.83	42,214.57	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-23,141.75	46,586.49
ワイブル分布	ワイブル分布	対数正規分布	対数正規分布	-20,796.66	41,829.82	対数正規分布	ワイブル分布	ワイブル分布	対数正規分布	-22,789.57	45,831.88
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,673.87	43,580.61	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,945.88	45,908.16
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-21,135.02	42,927.62	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,658.06	45,558.31
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-21,214.53	42,634.09	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-22,431.81	45,129.69
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	45,435.46	45,435.46	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-22,442.74	44,823.42
ワイブル分布	ワイブル分布	対数正規分布	対数正規分布	-22,217.60	44,716.06	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,875.86	45,963.62
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,713.09	45,628.13	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,638.37	45,531.45
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,179.41	44,598.94	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,915.46	45,883.85
ワイブル分布	ワイブル分布	対数正規分布	対数正規分布	-22,096.24	44,458.81	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,854.96	41,985.74
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,177.55	44,249.33	対数正規分布	ワイブル分布	ワイブル分布	対数正規分布	-20,611.55	41,471.97
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,483.91	45,193.73	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,690.50	41,595.23
ワイブル分布	ワイブル分布	ワイブル分布	対数正規分布	-22,193.68	44,647.78	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-20,377.59	40,677.58
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-22,449.49	45,104.88	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-20,174.60	40,594.90
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,595.51	43,489.97	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-19,960.52	40,181.10
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,300.73	42,949.19	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,765.76	41,786.50
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,789.87	43,808.24	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,582.08	41,453.44
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,319.47	42,919.41	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,534.87	41,372.04
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,897.21	42,010.01	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,725.59	43,675.81
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,297.31	42,888.44	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,294.57	42,411.39
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,573.73	43,332.19	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,583.84	43,258.21
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,135.06	42,510.33	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,215.76	42,614.23
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,560.65	43,365.50	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-21,047.53	42,270.59
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,986.85	42,108.35	対数正規分布	ワイブル分布	対数正規分布	ワイブル分布	-20,876.71	40,283.31
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,662.96	41,674.96	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,524.29	43,167.45
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,444.33	41,792.42	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,110.99	42,392.09
ワイブル分布	ワイブル分布	ワイブル分布	ワイブル分布	-20,209.42	40,728.59	対数正規分布	ワイブル分布	ワイブル分布	ワイブル分布	-21,392.83	42,938.04

(注) 対数正規分布：対数ロジスティック分布