

消費者選好の動的変化の可視化と消費者ポジショニング

長谷川 翔平*・照井 伸彦†

Visualization of Dynamic Consumer Preference and Consumer Positioning

Shohei Hasegawa* and Nobuhiko Terui†

本研究では購買・消費経験から生じる消費者の選好の動的変化のモデル化を行う。提案するモデルは、ブランド切片に動的因子構造をもつブランド選択モデルであり、その因子構造における因子負荷量は時間不変のブランドポジション、因子スコアは時間とともに変化する消費者の選好ベクトルをそれぞれ表す。本論文では、この2つの量を同一の多次元マップ上に落とし込み、ブランドポジションと消費者選好の動的に変化の様子を同時にマッピングする動的ジョイント・スペース・マップを提案する。また動的選好ベクトルの分散に消費者異質性を導入することにより、因子構造から導かれた属性に対して消費者ごとの分散の大きさによって消費者のポジショニングを行い、選好が動的に変化しやすいバラエティーを求める消費者や変化しないロイヤルな消費者を属性ごとに判断し分類することができる。

In this paper, we explore dynamics of consumer's preference induced by the experience of consuming purchased brands. We propose heterogeneous choice models with dynamic factor structure in the brand intercepts, whose covariance matrix at each time is decomposed into time invariant factor loadings for the brand positioning and time dependent factor scores for consumer's preference direction. Then our proposed models make it possible to trace changing of consumer's preference directions at the purchase occasion and visualize them as well as brand positioning in the form of dynamic joint space map. The heterogeneous treatments on preference variance expressing latent variety seek attitude allow us for positioning consumers on lower dimensional space defined by the factor scores.

キーワード: ブランドポジショニング, 消費経験, 動的因子モデル, ジョイント・スペース・マップ, 市場構造.

1. はじめに

1.1 ジョイント・スペース・マップとは

マーケティング戦略を策定する際には同一製品市場における自社ブランドと他社ブランドの競合関係を理解することが重要である。競合関係の理解には、消費者が頭の中で自社ブランドを競合他社に対してどのように位置づけているのか把握することが必要となる。

* 東北大学大学院経済学研究科博士課程.

† 東北大学大学院経済学研究科.

また、ある製品市場に複数のブランドを投入している企業は自社ブランド同士の競合関係にも注意を向ける必要がある。このような同一製品市場におけるブランド間の競合関係を理解するための分析モデルとしては、知覚マップ（プロダクトマップ）が最も代表的なものである。

知覚マップは消費者のブランドに関するイメージ調査などのアンケートデータから作成され、多次元のマップ上で類似した性質を持つブランドは近くに、異なる性質を持つブランドは遠くにマッピングされる。しかしマップ上で、あるブランドが他のブランドと離れてマッピングされ、競争関係になく差別化されていたとしても、そのブランドに対する消費者のニーズがなければ市場でシェアを獲得することはできない。そこで消費者のニーズとしての選好を知覚マップ上に同時にマッピングするジョイント・スペース・マップという手法が使われる。

ジョイント・スペース・マップを作成するには外的分析と内的分析の2種類の方法がある。外的分析は知覚マップを既知として、別に調査されたブランド選好順序データから推定された消費者の選好をマップ上に追加する。つまり外的分析では知覚マップを推定するデータと消費者の選好を推定するデータの2種類が必要となる。一方の内的分析は一種類のデータから知覚マップと消費者の選好を同時に推定する方法である。内的分析では主に消費者パネルデータ（スキャンパネルデータ）というブランド選択データが用いられる。

消費者パネルデータは、消費者の性別・年齢などの属性とその消費者の購買製品・購買時の価格・プロモーションの有無などの購買履歴が記録されたデータである。このデータは、家庭に機器を設置して購買した製品のバーコードをスキャンしてもらうホームスキャン方式と、スーパーマーケットなどの会員カードとPOSレジデータを組み合わせたストアスキャン方式によって収集されるものがある。ホームスキャン方式では、複数店舗での購買行動に対応することができ、その家計について詳細なデータを得ることができる。他方、ストアスキャン方式では会員カードを持つ店舗にしか対応できないが、コストが少なく、より大規模なデータを容易に収集することが可能である。このようにして集められた消費者パネルデータを用いたブランド選択モデルはGuadagni and Little (1983)などに始まり、多くの研究論文が発表されている。その中でジョイント・スペース・マップモデルも展開されてきた。

1.2 先行研究レビュー

ブランド選択モデルを利用してジョイント・スペース・マップを描く分析手法は、Elrod (1988)により初めて提案された。Elrodは論文中で、これをチョイスマップと呼んでいる。このモデルは、ブランド選択モデルにおける効用関数のブランド切片に因子構造を仮定することでマップ上でのブランドポジションと市場全体の選好として代表的消費者の選好ベクト

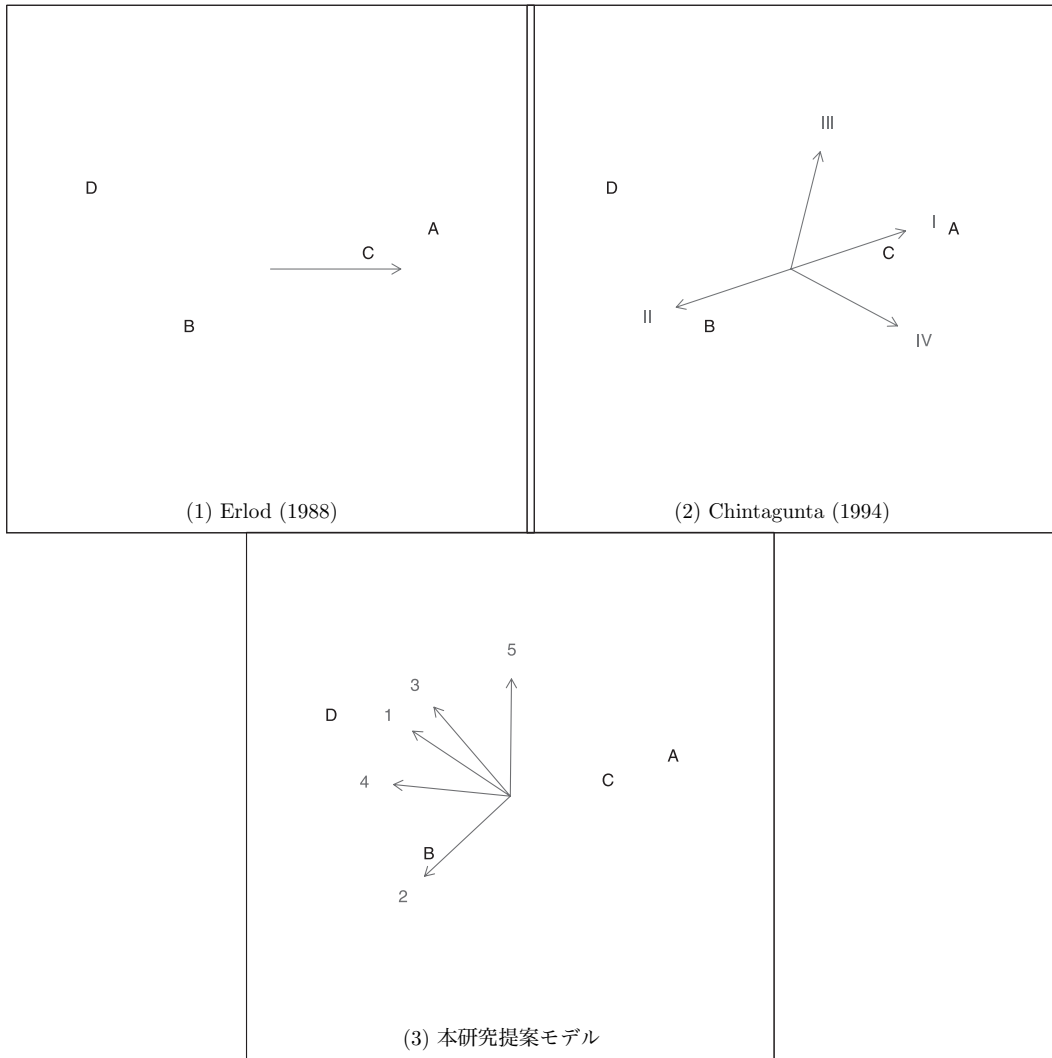


図1 先行研究と本研究の位置づけ。

ルを1つだけ推定している。図1-(1)はElrodによって提案されたジョイント・スペース・マップの例図である。マップ上でA~Dの記号は因子負荷量による各ブランドのポジション、矢印は因子スコアによる代表的消費者の選好ベクトルを表している。片平(1991)のLOGMAP(LOGit approach to Multiattribute Analysis for Positioning)やChintagunta(1994)では、選好ベクトルに消費者の異質性を導入し、有限混合モデル(潜在クラスモデル)を用いて、消費者を複数のセグメントに分類し、各セグメントの選好ベクトルを推定している。図1-(2)はChintagunta(1994)によって提案されたジョイント・スペース・マップの例図である。図1-(1)では1本であった選好ベクトルがローマ数字で表したセグメントごとにマップ上で描かれている。またErdem(1996)では、連続混合モデル(ランダム効

果モデル)を用いて異質性をセグメント別から消費者別へ拡張し、消費者ごとに異なる選好ベクトルを持つモデルを展開している。推定はSML (Simulated Maximum Likelihood approach)を用いているが、実際に推定するのは選好ベクトルの共通性の部分である。つまり、異質性を考慮してモデルが構築されているが、共通部分のみが推定されている。さらに、この研究では前期の購買が今期の購買に与える影響を状態依存項としてモデルに取り入れている。また、このモデルは、Inman *et al.* (2008)によってSKU (Stock Keeping Unit:在庫維持単位)レベルへと拡張されている。

ここまでの先行研究は、消費者の選好ベクトルに焦点を当てたモデルである。それに対し、Rutz and Sonnier (2011)ではブランド座標に焦点を当て、マップ上で各ブランドの座標が時間を通じて変化する動的モデルを提案している。詳しくは次節および2章で説明するが、本研究で提案するモデルは、Chintagunta (1994)やErdem (1996)の研究から異質性を進めて、選好ベクトルに消費者だけでなく時間の異質性を考慮した動的モデルである。この2つの動的モデルの違いは、ブランド間の競合関係の変化に注目するか、または消費者の選好の変化に注目するかにある。本研究の提案モデルは、消費者はブランドの購買・消費経験により選好を変化させるという仮定に基づく、消費者の選好の変化に注目したモデルである。

以上で消費者パネルデータからジョイント・スペース・マップを作成するモデルについて述べた。アンケートデータを用いる外的分析に対し、消費者パネルデータを用いる内的分析は以下の利点を持つ。(1)データを収集するコストが少ない、(2)データは日々蓄積されるため追跡的な分析が容易、(3)アンケートのような実験データではなく消費者が現実の状況において選択を行った行動データで実際の消費心理を表したデータである。

1.3 本研究の目的

これらの先行研究を踏まえ、本研究では次の2点を目的とする。第1の目的は、消費者個別のパラメータを推定すると同時に、購買経験を通じた消費者の選好ベクトルの変化を動的に捉えるモデルにより動的ジョイント・スペース・マップの作成し、購買経験による選好の変化を可視化することである。そして、第2の目的は動的変化を駆動する分散パラメータを消費者ごとに推定することにより消費者の特性を捉え、消費者をマッピングすることである。図1-(3)は、本研究の提案モデルにより作成される消費者1人の動的ジョイント・スペース・マップの例図であり、マップ上での数字は購買機会を表し、本消費者の購買経験を通じて選好ベクトルが変化していく様子を見ることができる。また、マップは消費者別に作成されるため、選好ベクトルの動き方からブランドロイヤルやバラエティーシーカーといった消費者の特性を捉えることが可能である。ここでブランドロイヤルとは特定のブランドに強い選好を持つ消費者を指し、バラエティーシーカーは特定のブランド

に選好を持たない消費者を指す。マップ上で選好ベクトルが動かなければロイヤルな特性を持つと推測でき、反対に様々な方向に選好が動けばバラエティーシーカーの特性を持つと予想できる。本研究では第2の目的にあるように、選好ベクトルの動き方を決める分散パラメータの値を消費者個別に推定し、ロイヤルとバラエティーへ消費者の分類を行うことが可能である。

以下、本論文では、第2章で提案モデルを説明した後、第3章で実際の消費者パネルデータを用いた実証分析を報告する。最後に第4章で結論を述べる。

2. モデル

2.1 効用関数の定式化

u_{jht} を消費者 $h(=1, \dots, H)$ の $t(=1, \dots, T_h)$ 回目の購買機会におけるブランド $j(=1, \dots, m)$ の効用として、全ブランドでまとめた効用ベクトルを $\mathbf{u}_{ht} = (u_{1ht}, \dots, u_{mht})'$ とする。効用関数は、価格・プロモーションなどのマーケティング変数に関し線形な構造を仮定し、さらにこれと独立な切片項は階層構造として時変の因子構造を持つと仮定する。つまり、

$$\mathbf{u}_{ht} = \boldsymbol{\alpha}_{ht} + \mathbf{X}_{ht}\boldsymbol{\beta}_h + \boldsymbol{\varepsilon}_{ht}; \quad \boldsymbol{\varepsilon}_{ht} \sim N_m(\mathbf{0}, \mathbf{I}) \quad (2.1)$$

$$\boldsymbol{\alpha}_{ht} = \mathbf{a}\mathbf{f}_{ht} + \boldsymbol{\eta}_{ht}; \quad \boldsymbol{\eta}_{ht} \sim N_m(\mathbf{0}, \mathbf{C}) \quad \mathbf{C} = \text{diag}(c_1^2, \dots, c_m^2) \quad (2.2)$$

ここで $\mathbf{X}_{ht} : (m \times k)$ は k 個の説明変数からなるマーケティング変数行列である。また、 $\mathbf{a} : (m \times d)$ は時間と消費者について不変な因子負荷行列、 $\mathbf{f}_{ht} = (f_{ht1}, \dots, f_{htd})' : (d \times 1)$ は消費者毎に動的に変化する d 次元の因子スコアベクトルである。動的ジョイント・スペース・マップを作成する際には、因子負荷行列 \mathbf{a} が因子分析によってブランド次元より低次元に圧縮された属性空間におけるブランドポジションとなり、因子スコア \mathbf{f}_{ht} がその属性に対する消費者の各購買時点での重みとして選好ベクトルとなる。因子スコア \mathbf{f}_{ht} と誤差項 $\boldsymbol{\varepsilon}_{ht}$ にはそれぞれ独立で多変量正規分布に従うと仮定を置き、以下のような制約を課す。

$$\mathbf{E}(\mathbf{f}_{ht}) = \mathbf{0}, \quad \mathbf{E}(\mathbf{f}_{ht}\mathbf{f}_{ht}') = \boldsymbol{\Delta}_h = \text{diag}(\delta_{h1}^2, \dots, \delta_{hd}^2) \quad (2.3)$$

$$\mathbf{E}(\boldsymbol{\varepsilon}_{ht}|\mathbf{f}_{ht}) = \mathbf{0}, \quad \mathbf{E}(\boldsymbol{\varepsilon}_{ht}\boldsymbol{\varepsilon}_{ht}'|\mathbf{f}_{ht}) = \mathbf{I} \quad (2.4)$$

式(2.4)では効用関数の誤差項の共分散行列には単位行列を仮定しているが、これは因子構造の部分が共分散を表現するため制約とはならない。

$$\text{Cov}_{(\mathbf{u}, \mathbf{f}|\mathbf{a})}(\mathbf{u}_{ht}) = \mathbf{a}\mathbf{E}(\mathbf{f}_{ht}\mathbf{f}_{ht}')\mathbf{a}' + \mathbf{C}^* = \mathbf{a}\boldsymbol{\Delta}_h\mathbf{a}' + \mathbf{C}^* \quad (2.5)$$

$$\mathbf{C}^* = \text{diag}(c_1^2 + 1, \dots, c_m^2 + 1)$$

ここで通常の因子分析では、

$$\mathbf{E}(\mathbf{f}_{ht}\mathbf{f}_{ht}') = \mathbf{I}, \quad \mathbf{E}(\boldsymbol{\varepsilon}_{ht}\boldsymbol{\varepsilon}_{ht}'|\mathbf{f}_{ht}) = \boldsymbol{\Sigma}_h = \text{diag}(\sigma_1^2, \dots, \sigma_m^2)$$

の仮定を置くが、後述するように本論文では因子スコアの分散により消費者をロイヤルとバラエティーシーカーに分類するため、式 (2.3), (2.4) の仮定を置く。

本研究で提案するモデルは、式 (2.1) のブランド選択モデル (多項プロビットモデル) と式 (2.2) の動的因子モデルを組み合わせた形になっている。ブランド選択モデルについては、消費者は効用最大化原理に基づき $u_{jht} = \max(u_{1ht}, \dots, u_{mht})'$ となるブランド $j(y_{ht} = j)$ を選択する仮定を置く。動的因子モデルによる選好ベクトル f_{ht} の動的構造については次節で説明する。

2.2 選好ベクトルのダイナミクス

購買機会を通じた消費者の選好の動的変化として、選好ベクトルがランダムウォークに従い、徐々に動くことを仮定する滑らかな事前分布 (smoothness prior) を持つモデルを提案する。

$$f_{hti} = f_{ht-1,i} + \nu_{hti}; \quad \nu_{hti} \sim N(0, \delta_{hi}^2) \quad i = 1, \dots, d \quad (2.6)$$

このモデルは、消費者の選好ベクトルは大きく動かないがスムーズに変化するという事前知識を導入するものである。滑らかな事前分布は、Harvey and Durbin (1986) や Kitagawa and Gersh (1984) などの時系列構造の研究で用いられ、有用な結果を残している。このモデルを以下では SP モデルと呼ぶ。

SP モデルをベクトルで表記すると以下のようなになる。

$$f_{ht} = f_{ht-1} + \nu_{ht}; \quad \nu_{ht} \sim N_d(\mathbf{0}, \Delta_h) \quad \Delta_h = \text{diag}(\delta_{h1}^2, \dots, \delta_{hd}^2) \quad (2.7)$$

このとき分散パラメータ Δ_h は消費者個別に推定する。また、対角とし、 f_{ht} の各次元は独立とする。

2.3 異質性モデルと事前分布

マーケティング変数への反応係数 β_h については、次の階層回帰モデルを用いて消費者の異質性をモデル化する。

$$\beta_h = \Theta' z_h + \lambda_h; \quad \lambda_h \sim N_k(0, \Lambda) \quad (2.8)$$

ここで $z_h : (p \times 1)$ は消費者 h の性別や年齢などの属性データである。さらに、いま $\mathbf{a}'_j = (a_{j1}, \dots, a_{jd})$ を因子負荷行列 \mathbf{a} の j 行目とし、各行は独立に分布すると仮定する。 \mathbf{a}'_j と c_j^2 の事前分布は Lee (2007) に従い、次のように設定する。

$$c_j^2 | \mathbf{a}_j \sim IG(n_{c0}/2, s_{c0}/2) \quad (2.9)$$

$$\mathbf{a}_j \sim N_d(\mathbf{a}_0, \mathbf{A}_0) \quad (2.10)$$

2.4 モデルの識別性

通常のベイズ多項プロビットモデルの推定と同じく $m+1$ 個のブランドを用意し、最後のブランドを基準ブランドに定め、その他のブランドからの差をとることにより相対効用 $u_{jht}^* = u_{jht} - u_{m+1,ht}$ ($j = 1, \dots, m$) を定義し、位置に関する識別性を確保する。これは、提案モデルにより作成されるジョイント・スペース・マップ上で基準ブランドを原点に置くことと同じ意味を持つ。この識別性確保の方法は、最尤法による推定を行う Chintagunta (1994) や Inman *et al.* (2008) などの先行研究と同じである。また、これらの研究はブランド選択モデルとしてロジットモデルを基礎としているが、本研究と同じくプロビットモデルを用いたジョイント・スペース・マップの研究 Elrod and Keane (1995) でも同様の方法が取られ、基準ブランドをマップの原点に固定して推定を行っている。なお、基準ブランドには市場全体への影響の少ない市場シェアの低いブランドやプライベートブランドを用いている。

尺度に関する識別性は、(2.4)にあるように分散を単位行列としていることで確保できる。また、因子構造の部分では、Geweke and Zhou (1996) に従って、因子負荷行列に以下の制約を加える。

$$\mathbf{a} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ a_{21} & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{md} \end{pmatrix} \quad \begin{cases} a_{ii} = 1 & i = 1, \dots, d \\ a_{il} = 0 & i < l \end{cases} \quad (2.11)$$

3. 実証分析

3.1 データと変数の説明

実証分析ではカップ麺カテゴリ 6 ブランド ($m+1=6$) の消費者パネルデータを用いた。観測期間は 2009 年 1 月 1 日から 2009 年 4 月 30 日までの 4 ヶ月間であり、観測期間内で 3 回以上の購買があった 100 人 ($H=100$) の消費者を分析対象とした。消費者の平均購買機会は 6.91 回、データの総購買機会は 691 回となっている。

マーケティング変数 \mathbf{X}_{ht} には価格とプロモーションの有無を表すダミー変数を、消費者の属性データ z_h には性別と年齢を用いた。本パネルデータの要約統計量を表 1 に掲載する。表中のプロモーション率は総購買機会の内で、エンド陳列や販促物などによるプロモーションが行われた割合を示す。エンド陳列とは、店舗の入り口や陳列棚の両端に商品が目立つように配置するプロモーション手法である。市場シェアは D が最も高く、次に B・E が続く。A はシェアは低いが、価格は高く、カップ麺カテゴリでの高価格ブランドとなっており、プロモーション率は低い。また、最も低価格なブランドである C もプロモーションが行われていない特徴を持っている。なお、識別性を確保するための基準ブランドは、シェア

表1 データ統計.

ブランド	市場シェア	平均価格	プロモーション率
A	0.07	155.66	0.06
B	0.20	119.75	0.25
C	0.10	98.00	0.00
D	0.29	114.06	0.41
E	0.20	129.76	0.17
F	0.15	125.78	0.26

表2 モデル比較.

		LML
MNP		-4913.83
JSM	1 因子	-4977.44
	2 因子	-4980.45
	3 因子	-4985.02
SP	1 因子	-4904.86
	2 因子	-4904.55
	3 因子	-4906.68

の低い A・C が特徴的なブランドであるため、プライベートブランドである F を選択した。

3.2 モデル比較と推定結果

パラメータ推定は MCMC により行った。事前分布のハイパーパラメータの設定及び MCMC アルゴリズムは付録に掲載する。

表2はモデル指標の比較結果である。提案モデルである SP モデルに加え、ブランド切片に因子構造を含まない通常の多項プロビットモデル (MNP) と、選好ベクトルを $f_{ht} = f_h$ として動的構造を含まないジョイント・スペース・マップ (JSM) の合計3モデル間での比較を行った。また、因子構造を含む SP・JSM モデルでは1~3因子モデル ($d = 1, \dots, 3$) での比較も行った。モデル比較の指標としては LML (Log of Marginal Likelihood) を用いた。

表2では、静的モデル (MNP・JSM) に対して、提案モデルである動的モデル (SP モデル) の LML が大きく、動的構造を支持する結果となっている。また、SP モデル内での1~3因子モデルの比較では僅差ではあるが2因子モデルが支持されている。

表3はモデル比較で支持された2因子の SP モデルのパラメータ推定値である。左から、効用関数におけるマーケティング変数への反応パラメータ、次に反応パラメータの階層モデルパラメータ、最後にジョイント・スペース・マップを描く際の各ブランドの座標となる因子負荷行列をまとめている。

表3 パラメータ推定値.

効用関数： $E[\bar{\beta}_h]$		因子負荷行列： $\bar{\alpha}$		
係数	事後平均	ブランド	事後平均	
価格	-6.099	A	1.000 0.000	
プロモーション	2.497	—	—	
階層モデル： Θ				
係数	事後平均		C	0.042 0.716
	価格	プロモーション		
切片	-2.296	2.193	D	1.906 0.447
	(7.307)	(2.699)		
性別	4.810	0.237	E	-0.952 1.247
	(2.112)	(0.574)		
年齢	-1.332	0.061	F	0.000 0.000
	(1.845)	(0.677)		

表3左に掲載のマーケティング変数に対する反応パラメータの数値については、各消費者の代表値（事後平均： $\bar{\beta}_h$ ）を平均した値 $E[\bar{\beta}_h]$ を示している。価格係数については、期待通り負の値に推定されており、価格が低いほど効用は増加し、そのブランドの選択確率が増加するという結果となっている。プロモーション係数についても同様に期待通り正の値に推定され、プロモーションがあれば効用が増加し、選択確率が増加するという結果となっている。これらのマーケティング変数に対する係数の階層モデルパラメータの推定値 Θ を見ると、有意に推定されているのは価格に対する性別の違いのみであり、性別が価格感度に対して影響を与えていることが分かる。因子負荷行列については、ほとんどの要素が有意に推定されているが、2つだけ有意でないものがある。ブランドFについては基準ブランドに選択したため、マップにおける座標は原点となっている。

3.3 動的ジョイント・スペース・マップ

次に、推定された因子負荷行列をブランド座標とし、同時に動的な選好ベクトルをマッピングした動的ジョイント・スペース・マップについて見ていく。図2～4は、SPモデルから描かれた3種類の消費者の動的ジョイント・スペース・マップである。図中の記号A～Fはブランドの位置を、矢印と数字は各購買機会における選好ベクトルを表す。図の横軸は第1属性（因子）、縦軸は第2属性（因子）を表している。

図2は特定のブランドのみ購買するブランドロイヤルな消費者の動的ジョイント・スペース・マップである。この消費者の購買履歴を見るとBのみ購入しており、選好ベクトルも購買機会を通じて全てBの方向を向いていてほとんど動いていないことが分かる。

次に図3は、6ブランドの内4ブランドを購買しているバラエティーシーカーの消費者

購買機会	1	2	3	4	5
選択ブランド	B	B	B	B	B




図2 ロイヤル.

購買機会	1	2	3	4	5	6	7	8	9	10
選択ブランド	F	E	B	D	B	D	F	F	B	E




図3 バラエティー・シーカー 1.

購買機会	1	2	3	4	5	6	7	8	9	10
選択ブランド	C	C	E	C	B	E	D	E	E	F





図4 バラエティー・シーカー 2.

の例である。図2のマップとは対照的に、マップ上で選好ベクトルが大きく動いていることが分かる。

最後の図4も購買機会を通じて異なるブランドを選択しているバラエティーシーカーのマップである。しかし図3の消費者と異なり、マップ上の選好ベクトルが動いていない。理由としては、選好ベクトルは動かないが、マーケティング変数への反応が大きいため、多様なブランドを購入していると考えられる。実際、この消費者の価格反応係数は -8.41 と表3に示した消費者間の平均よりも絶対値で大きな値である。また、この消費者はマップ上にブランドのない方向へ選好ベクトルが向いており、このような消費者が多く存在する市場ではポジショニング戦略を練り直す必要がある。

3.4 ロイヤルとバラエティーシーカーへの分類と消費者ポジショニング

SPモデルの動的ジョイント・スペース・マップ上で、購買機会ごとに選好ベクトルが変化しない場合は、その分散パラメータ δ_{hi}^2 が小さな値を持ち、逆に大きく動く場合は δ_{hi}^2 が大きな値を持つと考えられる。よって δ_{hi}^2 の大きさにより潜在的なロイヤルとバラエティーシーカーに分類できる。ここで“潜在的”の意味は、ブランドに対してではなく、因子構造で導かれた各属性に対して、消費者をロイヤルとバラエティーシーカーへ分類することを示している。つまり、マップの次元が2次元の場合、 δ_{h1}^2 が大きく、 δ_{h2}^2 が小さい消費者は属性1についてはバラエティーを好み、属性2についてはロイヤルな特性を持つと言える。



	$\bar{\delta}_{h1}^2$	$\bar{\delta}_{h2}^2$
平均	4.07	2.58
中央値	2.13	2.12
標準偏差	6.69	1.63

図5 消費者ポジショニング.

図5は各消費者の選好ベクトルの分散パラメータの事後平均 ($\bar{\delta}_{h1}^2, \bar{\delta}_{h2}^2$) を散布図によって消費者のポジショニングしたものである。図5から、消費者の多くは両属性の分散が小さい左下にプロットされており、選好の変化が少ないロイヤルな消費者が多い市場と理解できる。ただし、どちらか一方の分散が大きい消費者も小数ではあるが存在することが分かる。また、標準偏差を見ると δ_{h1}^2 の方が消費者間の散らばりが大きい。

図2で描かれた消費者は、選好ベクトルが1方向でほとんど動いていないため因子構造より得られた両属性に対してロイヤルな消費者と言える。この消費者は図5では左下にプロットされる。この消費者のように両方の次元において小さな分散を持つ消費者は、選好ベクトル、したがって、ブランド切片はほとんど変化しない固定的性質を持つ。

反対に選好ベクトルの時間的変化が大きい図3の消費者は、選好ベクトルの変化量が、横軸方向は大きいのに対し縦軸方向は少ない。つまり第1属性に対してはバラエティーシーカー、第2属性に対してはロイヤルと言える。この消費者は図5では右下にプロットされる。

最後に、消費者ポジションとブランドポジションの関係からマーケティングのインプリケーションについて考察する。このカップ麺カテゴリでは、図5で左下にプロットされる両属性に対しロイヤルな消費者が多く、このような消費者は選好ベクトルの時間的変化が少ない。よって次の購買機会でも選好ベクトルは同じ方向を向くと予測できるため、それに応じたプロモーションが行える。このカテゴリで特に注意が必要なのは図5で右下にプロットされる第1属性の分散パラメータ δ_{h1}^2 が大きいバラエティーシーカーの消費者である。 δ_{h1}^2 が大きい消費者は、動的ジョイント・スペース・マップ上で選好ベクトルが横方向に大きく変化する。SPモデルにおける動的ジョイント・スペース・マップで描かれた各ブランドのポジションは横方向に広がっているため、選好ベクトルが第1属性で大きく変化する

ると、次に選好ベクトルが向くブランドを予測することは難しくなる。これについては、バラエティーシーカーの特性を持つ消費者に対して全ブランドを提示できるよう売り場のディスプレイ管理を行うなどの対応が考えられる。

4. 結論

本論文では購買経験を通じて変化する選好ベクトルを持つ動的ブランド選択モデルからジョイント・スペース・マップを作成した。このモデルはブランド切片を時間不変の因子負荷量と時変の因子スコアに分解することにより、それぞれマップ上におけるブランドポジションと消費者の選好ベクトルを同時に推定している。また、モデル比較では静的モデルに対して、製品の購買・消費経験による選好ベクトルの動的変化のモデル化として、滑らかな事前分布を仮定した動的モデルが支持された。このモデルは前期購買時の選好ベクトルからの変化に対しノンパラメトリックなモデルであり、選好は緩やかに変化すると仮定したものである。また、実証分析では、選好ベクトルの分散パラメータに注目し、因子構造により導かれた低次元属性空間上で特定の属性に対してロイヤルまたはバラエティーシーカーの特性を持つ消費者をポジショニングした。これにより、その製品市場に参加する消費者の傾向として、ロイヤルが多い、またはバラエティーシーカーが多いなどの特徴をつかむことができた。

提案するモデル分析により、マーケッターは顧客ごとに購買機会を通じた選好の変化を追跡することが可能となり、ロイヤルまたはバラエティーシーカーであるかを判断することができる。加えて、消費者のポジショニングによりそのカテゴリ市場に参加している消費者の性質を知ることができる。バラエティーシーカーが多いカテゴリの場合はブランドの種類を増やすなど、消費者の特性に合わせたマーケティング戦略が必要となる。また、全消費者の動的ジョイント・スペース・マップを描いて比較したとき、図4で示した例のようにマップ上でブランドがない方向へ選好が向いている顧客が多い場合も考えられる。このような発見はプロモーション戦略だけでなくブランド自体のポジショニング戦略についても新たな知見となり得るだろう。

今後の課題として、第1に基準ブランドの選択に関する問題がある。基準に選ぶブランドが異なれば、マップの座標や消費者の選好ベクトルの方向が異なり、解釈が変わってしまう可能性がある。これについて、先行研究では、市場への影響力の少ないシェアの低いブランドやプライベートブランドを基準に定めることで、一定の解決策としている。しかし、実務上、シェアの低いブランドやプライベートブランドを分析対象としたい場合もある。このとき基準ブランドの選択は大きな問題となり、基準ブランドに依存しないモデリングが望まれる。その解決策の1つは、外部財 (outside goods) を持つモデルへの拡張である。ここで外部財とは、分析対象の商品 (内部財) と同時に購買された、その他の商品

を指す。本研究は、消費者の購買機会における「買い物かご」の中で、内部財のみ扱うモデルであったが、外部財を持つモデルは、その他の商品である外部財も考慮する。ただし、内部財と外部財は関連性があることが望ましく、実証研究で用いたカップ麺を内部財とすれば、外部財は同時に購買したその他の食料品全般となり、日常雑貨などは除かれる。この外部財を持つモデルでは、外部財を基準としてすべてのブランドが相対評価され、選好ベクトルも外部財から方向が決定されることになる。使用したデータセットは外部財を含まず、これを適用できない。また、内部財の選択データと外部財の選択データを同時に扱うため、多項プロビット・ロジットモデルとは異なるブランド選択モデルが必要となる。

第2の課題としては、選好の動的構造に関する研究がある。本論文では、選好の動的構造として、選好が徐々に動くことを仮定する滑らかな事前分布を持つ SP モデルを提案した。しかし、マーケティングの観点からは、SP モデルで捉えることができない、選好の動的変化の構造や、選好が変化する要因について関心が高い。動的構造として選好が変化する要因を掴むことができれば、効率的なプロモーションを行うことができ、より多くのインプリケーションを得ることができるだろう。

付録 MCMC アルゴリズム

A.1 事前分布

prior	Empirical Application
$vec(\Theta) \sim N_{k \times p}(\Theta_0, \Lambda \otimes W_0^{-1})$	$\Theta_0 = \mathbf{0}, \quad W_0^{-1} = \mathbf{I} \times 100^{-1}$
$\Lambda \sim IW_k(\lambda_0, \Lambda_0)$	$\lambda_0 = 4, \quad \Lambda_0 = \mathbf{I} \times \lambda_0^{-1}$
$\mathbf{a}_j \sim N_d(\mathbf{a}_0, \mathbf{A}_0)$	$\mathbf{a}_0 = \mathbf{0}, \quad \mathbf{A}_0 = \mathbf{I} \times 100^{-1}$
$c_j^2 \sim IG(n_{c0}/2, s_{c0}/2)$	$n_{c0} = 2, \quad s_{c0} = 2$
$\delta_{hi}^2 \sim IG(n_{\delta 0}/2, s_{\delta 0}/2)$	$n_{\delta 0} = 2, \quad s_{\delta 0} = 2$

A.2 事後分布

1. $\mathbf{u}_{ht} | y_{ht}, \mathbf{X}_{ht}, \boldsymbol{\alpha}_{ht}, \boldsymbol{\beta}_h$

$$\mathbf{u}_{ht} | - \sim TN_{m[R_{ht}^m]}(\boldsymbol{\alpha}_{ht} + \mathbf{X}_{ht}\boldsymbol{\beta}_h, \mathbf{I})$$

このとき切断領域 R_{ht}^m は、観測データが $y_{ht} = j$ のときに以下を定義する。

$$\begin{cases} u_{jht} > \max\{\mathbf{u}_{ht(-j)}\} \\ u_{kht} \leq \max\{\mathbf{u}_{ht(-k)}\} \quad (k \neq j) \end{cases}$$

2. $\beta_h | \mathbf{u}_{ht}, \mathbf{X}_{ht}, \alpha_{ht}, \Theta, z_h, \Lambda$

$\mathbf{u}_{ht}^* = \mathbf{u}_{ht} - \alpha_{ht}$ として式 (2.1) を変化させると,

$$\mathbf{u}_{ht}^* = \mathbf{X}_{ht} \beta_h + \varepsilon_{ht}; \quad \varepsilon_{ht} \sim N_m(\mathbf{0}, \mathbf{I})$$

となり, 被説明変数が \mathbf{u}_{ht}^* , 説明変数が \mathbf{X}_{ht} の多変量回帰分析における係数推定となる.

$$\beta_h | - \sim N_k(\hat{\beta}_h, \mathbf{B}_h)$$

$$\mathbf{B}_h = (\Lambda^{-1} + \mathbf{X}'_{ht} \mathbf{X}_{ht})^{-1}, \quad \hat{\beta}_h = \mathbf{B}_h (\Lambda^{-1} \Theta' z_h + \mathbf{X}'_{ht} \mathbf{u}_{ht}^*)$$

$$\mathbf{X}_h = (\mathbf{X}_{h1}; \dots; \mathbf{X}_{hT_h}), \quad \mathbf{u}_h^* = (\mathbf{u}_{h1}^*; \dots; \mathbf{u}_{hT_h}^*)$$

3. $\Theta | \beta_h, z_h, \Lambda$

$$\text{vec}(\Theta) | - \sim N_{k \times p}(\hat{\Theta}, \Lambda \otimes \mathbf{W})$$

$$\mathbf{W} = (\mathbf{W}_0^{-1} + \mathbf{Z}' \mathbf{Z})^{-1}, \quad \hat{\Theta} = \mathbf{W} (\mathbf{W}_0^{-1} \Theta_0 + \mathbf{Z}' \beta)$$

$$\mathbf{Z} = (z_1, \dots, z_H)', \quad \beta = (\beta_1, \dots, \beta_H)'$$

4. $\Lambda | \beta_h, z_h, \Theta$

$$\Lambda | - \sim IW_k(\lambda_0 + H, \Lambda_0 + \mathbf{S})$$

$$\mathbf{S} = (\beta - \mathbf{Z} \Theta)' (\beta - \mathbf{Z} \Theta)$$

5. $\alpha_{ht} | \mathbf{u}_{ht}, \mathbf{X}_{ht}, \beta_h, \mathbf{a}, \mathbf{f}_{ht}, \mathbf{C}$

$\mathbf{u}_{ht}^\dagger = \mathbf{u}_{ht} - \mathbf{X}_{ht} \beta_h$ として式 (2.1) を変化させると,

$$\mathbf{u}_{ht}^\dagger = \alpha_{ht} + \varepsilon_{ht}; \quad \varepsilon_{ht} \sim N_m(\mathbf{0}, \mathbf{I})$$

となり, 被説明変数が \mathbf{u}_{ht}^\dagger , 説明変数が切片項のみの多変量回帰分析における係数推定となる.

$$\alpha_{ht} | - \sim N_m(\hat{\alpha}_{ht}, \mathbf{A}_n)$$

$$\mathbf{A}_n = (\mathbf{C}^{-1} + \mathbf{I}_m)^{-1}, \quad \hat{\alpha}_{ht} = \mathbf{A}_n (\mathbf{C}^{-1} \mathbf{a} \mathbf{f}_{ht} + \mathbf{I}_m \mathbf{u}_{ht}^\dagger), \quad \mathbf{I}_m : m \times m \text{ の単位行列}$$

6. $\mathbf{C} = \text{diag}(c_1^2, \dots, c_m^2) | \{\alpha_{ht}\}, \mathbf{a}, \{\mathbf{f}_{ht}\}$

$$c_j^2 | - \sim IG \left(\frac{n_{c0} + \sum_{h=1}^H T_h}{2}, \frac{s_{c0} + S_c}{2} \right), \quad j = 1, \dots, m$$

$$S_c = \sum_{h=1}^H \sum_{t=1}^{T_h} (\alpha_{jht} - \mathbf{a}'_j \mathbf{f}_{ht})^2$$

7. $\mathbf{a}|\{\boldsymbol{\alpha}_{ht}\}, \{\mathbf{f}_{ht}\}, \mathbf{C}$

$$\mathbf{a}_j|-\sim N_d(\hat{\mathbf{a}}_j, \mathbf{D}_n)$$

$$\mathbf{D}_n = (\mathbf{C}^{-1} + \mathbf{f}'\mathbf{f})^{-1}, \quad \hat{\mathbf{a}}_j = \mathbf{D}_n(\mathbf{A}_0^{-1}\mathbf{a}_0 + \mathbf{f}'\boldsymbol{\alpha}_j)$$

$$\mathbf{f} = (\mathbf{f}_1; \cdots; \mathbf{f}_H), \quad \mathbf{f}_h = (\mathbf{f}_{h1}, \cdots, \mathbf{f}_{hT_h})'$$

$$\boldsymbol{\alpha}_j = (\boldsymbol{\alpha}_{j1}; \cdots; \boldsymbol{\alpha}_{jH}), \quad \boldsymbol{\alpha}_{jh} = (\alpha_{jh1}, \cdots, \alpha_{jhT_h})'$$

8. $\{\mathbf{f}_{ht}\}|\{\boldsymbol{\alpha}_{ht}\}, \mathbf{a}, \boldsymbol{\Delta}_h$

式 (2.2) と式 (2.7) の状態空間表現より Multi Move Sampler を用いた状態推定を行う (Carter and Kohn (1994))

9. $\boldsymbol{\Delta}_h = \text{diag}(\delta_{h1}^2, \cdots, \delta_{hd}^2)|\{\mathbf{f}_{ht}\}$

$$\delta_{hi}^2|-\sim IG\left(\frac{n_{\delta 0} + T_h}{2}, \frac{s_{\delta 0} + S_{\delta_i}}{2}\right), \quad i = 1, \cdots, d$$

$$S_{\delta_i} = \sum_{t=2}^{T_h} (f_{hti} - f_{ht-1,i})^2$$

謝辞

本稿の改訂にあたり、特集号の編集者および査読者から有益なコメントを頂戴した。ここに謝意を表したい。また、本論文は、著者照井伸彦が日本学術振興会・科学研究費・基盤研究 (A)21243030 の助成を受けた研究成果の一部である。

参考文献

- Carter and Kohn (1994). On Gibbs sampling for state space models, *Biometrika*, **81**, 541–553.
- Chintagunta (1994). Heterogeneous logit model implications for brand positioning, *Journal of Marketing Research*, **32**, 304–311.
- Elrod (1988). Choice map: Inferring a product market map from panel data, *Marketing Science*, **7**(1), 21–40.
- Elrod, T. and Keane, M. P. (1995). A factor-analytic probit model for representing the market structure in panel data, *Journal of Marketing Research*, **32**, 1–16.
- Erdem (1996). A dynamic analysis of market structure based on panel data, *Marketing Science*, **15**(4), 359–378.
- Geweke and Zhou (1996). Measuring the pricing error of the arbitrage pricing theory, *The Review of Financial Studies*, **9**(2), 557–587.
- Guadagni, P. M. and Little, J. D. C. (1983). A logit model of brand choice calibrated on scanner data, *Marketing Science*, **2**(3), 203–238.
- Harvey, A. C. and Durbin, J. (1986). The effects of seat belt legislation on British road casualties: A case study in structural time series modelling, *J. R. Stat. Soc.*, **149**(3), 319–360.
- Inman, J. J., Park, J. and Sinha, A. (2008). A dynamic choice map approach to modeling attribute-level varied behavior among stockkeeping units, *Journal of Marketing Research*, **45**, 94–103.
- 片平秀貴 (1991). 『新しい消費者分析－LOGMAP の理論と応用－』 東京大学出版会。

- Kitagawa and Gersh (1984). A smoothness priors-state space modeling of time series with trends and seasonality, *J. Am. Stat. Assoc.*, **79**, 378–389.
- Lee, Y. (2007). *Structural Equation Modeling: A Bayesian Approach*, Wiley.
- Rutz, O. J. and Sonnier, G. P. (2011). The evolution of internal market structure, *Marketing Science*, **30**(2), 274–289.