

Discussion Papers In Economics And Business

個人内での選好の変化を考慮した市場構造分析

里村卓也

Discussion Paper 02-15

Graduate School of Economics and
Osaka School of International Public Policy (OSIPP)
Osaka University, Toyonaka, Osaka 560-0043, JAPAN

個人内での選好の変化を考慮した市場構造分析

里村卓也

Discussion Paper 02-15

August 2002

この研究は「大学院経済学研究科・経済学部記念事業」
基金より援助を受けた、記して感謝する。

Graduate School of Economics and
Osaka School of International Public Policy (OSIPP)
Osaka University, Toyonaka, Osaka 560-0043, JAPAN

個人内での選好の変化を考慮した市場構造分析*

大阪大学大学院経済学研究科 里村卓也

satomura@econ.osaka-u.ac.jp

2002年8月

概要

本研究では、消費者個人内での選好の変化を考慮しながら、マッピングにより市場構造の分析を行うモデルを提案する。市場構造の分析方法として、消費者の理想ベクトルとブランドの布置を同一空間上に表現する選好の内的分析がある。このようなモデルとしてLOGMAP-J(片平 1990)があり、購買履歴データよりポジショニング・マップ上でのブランドの布置と各消費者が所属する理想ベクトルを同時に推定することができる。しかしながらLOGMAP-Jでは、180度離れたセグメントに同一の消費者が高確率で所属するのは不可能である。消費者の中には多様性追及的行動を行うものが存在するが、このような消費者はLOGMAP-Jでは対応できない。

本研究では動学的セグメンテーションを選好の内的分析に適用することにより、消費者毎の理想ベクトルが購買時点毎に変化するモデルを構築した。状態とパラメータの推定にはマルコフ連鎖モンテカルロ法が適用され、消費者の理想ベクトルの変化の推定された。実証分析の結果、モデル間の比較や、消費者およびブランドに関する含意が得られた。理想ベクトルが大きく変化すると推定された消費者も存在することがわかった。

1 はじめに

マーケティングでは消費者の選好度を分析する手法として、 n 次元空間上¹にブランド等の対象を布置し、対象間の関係を視覚的に表現する手法がとられる。視覚的に表現された空間はジョイント・スペース分析と呼ばれている。市場におけ

*本研究の一部は「大阪大学大学院経済学研究科・経済学部記念事業」基金の助成を受けた、記して感謝する。

るブランドの競合を分析することは、メーカーにとってはいくつかの重要な意味を持つ。メーカーにとっては、競合ブランドを識別することにより自社ブランドの差別化に必要な要素を抽出することができる。また小売業にとっては、競合ブランド同士は消費者から見れば同一のサブカテゴリーに属していると考えられるために、店頭における棚割り等の販売政策に反映させることができる。一方、消費者のブランドに関する選好はジョイント・スペース上では理想ベクトルや理想点として表現される。各消費者の、ブランドに対する選好の分析は、市場シェアの予測や今後の新製品の開発にとって重要である。ただしブランドの選好は消費者間で異質であると考えられるので、理想ベクトルや理想点もひとつであるとは限らない。

1.1 選好の内的分析

選好度の分析には大きく分類すると外的分析と内的分析がある(岡太 2001)。外的分析とは、与えられた既知の対象布置の中に、個人を表現する理想ベクトルまたは理想点を埋め込む方法である。PREFMAP(Carrol 1972)が代表的な外的分析手法である。一方内的分析は選好度を分析して対象の布置と個人の分布を同時に求めることをさす。MDPREF(Carrol 1972)は選好の内的分析の代表的な手法であり、対象を点、個人をベクトルで表現する。MDPREFは個人×対象で表現される選好度同列を分解することによって得られる。しかしながらスキャナー・データを用いて内的分析を行おうとした場合には、個人別の選好度をデータから直接得ることができない。さらに市場における消費者の反応も同時に分析したい場合も出てくる。

片平(1990)のLOGMAP-Jは選好の内的分析と市場反応分析を同時に行うためのものである。LOGMAP-Jではロジット型選択モデルにおいて理想ベクトルを導入し、ロジット・パラメータの消費者間異質性を考慮すると同時にブランドマップを作成するものである。結果として全消費者共通のブランド・マップが得られ、そのマップ上に各消費者固有の反応も測定される。

Cooper and Inoue(1996)では消費者セグメント毎の選好構造と市場構造を把握するモデルを提案している。彼らのモデルでは、市場における競合グループ形成過程を、属性評価スキーマと理想点のプロファイルに関連づけることにより、識別された競争市場構造を解釈しようというものである。

1.2 多様性追求的行動と動学的セグメンテーション

LOGMAP-Jでは消費者の所属する理想ベクトルはセグメントであると解釈できる。消費者を選好が同一のセグメントに分割した場合、通常は分析期間中は消費者は同一セグメントに所属し、セグメントの構造は期間中一定であることを仮定している。しかしながら消費者が分析期間中に同一セグメントに所属している保証はないし、またたとえ同一セグメントに所属していたとしても、セグメントの構造が期間中一定である保証もない。

例えば飲料のように、一人の消費者が味覚や刺激に対して多様性を追求するようなカテゴリーでは、消費者はいろいろなブランドを購入することがある。多様性追求 (variety seeking) 的行動とは消費者が購買時点においてさまざまなサービスや商品を探し回る傾向のこと (清水 1999) である。多様性追求が生じる理由としては 1) 飽和状態による自己の内面からの動機づけ、2) 価格プロモーションや店舗内環境 (レイアウト、品揃え等) 等の外部環境の変化、3) 将来の嗜好に対する不確実性、等が挙げられる (Kahn 1995)。多様性を追求する消費者が存在する場合には、セグメントの構造が期間中一定であることを仮定することは難しい。

そこで、セグメントの動学的変化を考えることが必要となり、これらは動学的セグメンテーション (Dynamic Segmentation) と呼ばれている (Wedel and Kamakura 1998)。Petty and Cacioppo (1986) によれば、関与の程度やその他の要因により消費者は購買意思決定プロセスを変更する。動学的セグメンテーションではこのような消費者の購買意思決定プロセスの変化も積極的にモデルに取り込もうというものである。

動学的セグメンテーションの中でも、セグメント間の移動を扱ったものは潜在変化 (Latent Change) モデルと呼ばれている。セグメント間の変化を顕在変数を用いて表したもの (Kamakura, Wedel and Agrawa 1994; Yang and Allenby 2000) や、セグメント間の変化を隠れマルコフモデルを用いて表したもの (Poulsen 1990; Böckenholt and Langeheine 1996; Ramaswamy 1997) がある。

さて、隠れマルコフモデルを用いた動学的セグメンテーションについて見てみよう。時点を $t (= 1, 2)$ の 2 時点、時点 t での消費者の購買行動を y_t とする。 $t = 1$ で消費者の所属するセグメントを $t1 (= 1, \dots, T1)$ 、セグメントへの所属確率を π_{t1} 、モデルのパラメータを θ_1 とする。とする。 $t = 2$ で消費者の所属するセグメントを $t2 (= 1, \dots, T2)$ 、 $t = 1$ で $t1$ に所属していた消費者が $t = 2$ でセグメント $t2$ へ所属する確率を $\pi_{t2|t1}$ 、モデルのパラメータを θ_2 とする。 $t = 1$ から $t = 2$ におけ

るセグメントの推移確率は $\pi_{t2|t1}$ である。このときの尤度は

$$l(\theta_1, \theta_2, \pi_{t1}, \pi_{t2|t1} | y_1, y_2) = \sum_{t1=1}^{T1} \sum_{t2=1}^{T2} \pi_{t1} f_{t1}(y_1 | \theta_{t1}) \pi_{t1|t2} f_{t2}(y_2 | \theta_{t2}).$$

となる。尤度を最大化するパラメータを求めれば Bayes の定理より消費者の所属するセグメントを推定することが可能である。

しかしながら、このようなモデルでは期間の数が多くなるほど尤度が複雑になってしまいパラメータを推定することが困難となる。Kitagawa(1987) ではこのようなモデルについては再帰的手法により状態とパラメータの推定を用いることを提案している。

1.3 既存研究の問題点

LOGMAP-J(片平 1990) では、購買履歴データよりブランドマップの作成と各消費者が特定の理想ベクトルに所属する確率が推定可能である。しかしながら理想ベクトルが 180 度離れたセグメントに同一の消費者が高確率で所属するのは不可能である。消費者の理想ベクトルは時点に依存せず固定的なものとして扱っているため、消費者の多様性追求的行動が組み込めないのである。

このような問題を解決するためには、購買時点毎に所属する理想ベクトルが変化するモデルを構築すればよい。ただし、購買データより消費者の所属する理想ベクトルが全く自由に变化してしまうと考えるよりも、ある時点での消費者がどのような理想ベクトルを持つのかは過去の理想ベクトルに依存すると考えるほうが自然であろう。理想ベクトルをセグメントと考えれば、動学的セグメンテーションを利用することによりモデル化は可能である。ただし、セグメント数が多くなれば、データからモデルのパラメータや個人別の理想ベクトルの変化を推定することは困難となる。

本研究では、購買履歴データより市場反応分析と選好の内的分析を行うと同時に、消費者のセグメンテーション(理想ベクトル)が購買時点毎に変化するしくみを取り入れている。ただしこのようなモデルの推定に最尤法を利用しようとしても、尤度関数が複雑であり、最大化することは困難である。そこで、パラメータと理想ベクトルへの所属確率の推定方法として、近年マーケティング・サイエンスの分野でも一般的になったマルコフ連鎖モンテカルロ (Markov Chain Monte Carlo; 以下 MCMC) 法を用いることとする。

2 モデル

提案するモデルは LOGMAP-J をベースにして、各消費者のセグメント（理想ベクトル）への所属確率を購買時点毎に変化させるものである。なお以下のモデル化ではデータの制約上、消費者は家計であると仮定する。

2.1 ブランド選択モデル

セグメント s に所属する家計 h の時点 t でのブランド m に対する効用 $U_{hmt|s}$ を以下のように表す。

$$U_{hmt|s} = V_{hmt|s} + \varepsilon_{hmts} \quad (1)$$

ただし

$$V_{hmt|s} = \alpha_{s1}w_{hmt} + \alpha_{s2}x_m \quad (2)$$

とする。また

w_{hmt} : 家計 h の t 期のブランド m のマーケティング変数ベクトル

x_m : ブランド m のマップ上の座標ベクトル

ε_{hmts} : i.i.d. 極値分布に従う誤差項

α_{s1}, α_{s2} : パラメータ・ベクトル

とする。このときセグメント s に所属する家計 h が時点 t においてブランド m を選択する確率は

$$Pr(y_{ht} = 1_m | s) = \frac{\exp(V_{hmt|s})}{\sum_{j=1}^M \exp(V_{hjt|s})} \quad (3)$$

ただし

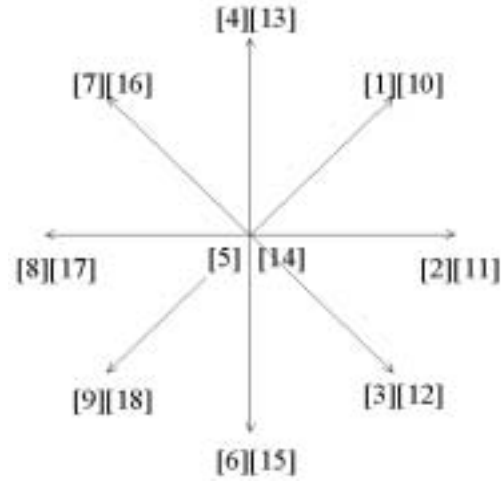
y_{ht} : 時点 t での家計 h の選択結果

$$1_m = (\delta_{1m}, \dots, \delta_{Mm})' \quad \delta_{km} = \begin{cases} 1 & k = m \text{ の場合} \\ 0 & \text{その他の場合} \end{cases}$$

M : ブランド数

となる。

図 1: β_s の例



2.2 反応パラメータの設定

パラメータの推定では LOGMAP-J と同じく各セグメントの反応パラメータをあらかじめ固定したものとして扱うこととする。

LOGMAP-J では $\alpha_s = (\alpha_{s1}, \alpha_{s2})$ とし、 α_s を $\alpha_s = \gamma\beta_s, |\beta_s| = 1$ と分解すると、 $\gamma (= \gamma_1, \gamma_2)$ が α_s のスケール、 β_s が相対ウェイト・ベクトルとなる。 β_s は考えられるあらゆる β_s パターンをなるべく少ない数のベクトルを用いて表現する。ここでは LOGMAP-J と同じく図 1、表 5 のようなベクトルを用いた。ただし図では β_{s1} を価格のパラメータと考え、図中の [1] ~ [9] は価格のパラメータが負、[10] ~ [18] は価格のパラメータが 0 であるとしている。

式 (2) を書き直すと

$$V_{hmt|s} = \gamma_1\beta_{s1}w_{htm} + \gamma_2\beta_{s2}x_m. \quad (4)$$

となる。ただし、実証分析における推定では γ_2 と x_m は識別することが不可能であるため、 $\gamma_2 = 1$ に固定する。

2.3 所属セグメントの切り替え

ここではセグメントへの所属を潜在状態と考える。ブランドの選択は潜在状態に依存し、状態間推移はマルコフ過程に従い、また選択結果を顕在変数と考える。

すなわち家計 h は時点 t で S 個のセグメントに確率的に所属するが、時点 t でのセグメント s への所属確率は、時点 $t-1$ での所属確率のみに依存するとする。

推移確率行列において状態 i から状態 j への推移確率を p_{ij} とすると、

$$\begin{aligned} Pr(S_{ht} = j | S_{h,t-1} = i, \psi_{h,t-1}) &= Pr(S_{ht} = j | S_{h,t-1} = i) = p_{ij} \\ 0 \leq p_{ij} \leq 1, \quad \sum_{j=1}^S p_{ij} &= 1. \end{aligned} \quad (5)$$

である。ただし $\psi_{h,t} = \{y_{h1}, \dots, y_{ht}\}$ とする。さらに以降の定式化のために、 $\psi^{h,t+1} = \{y_{h,t+1}, \dots, y_{hT_h}\}$ を定義しておく。ただし T_h は家計 h の期間中購買回数である。同様に $\varphi_{ht} = (S_{h1}, \dots, S_{ht})$ 、 $\varphi^{h,t+1} = (S_{h,t+1}, \dots, S_{hT_h})$ と定義しておく。

次にパラメータ $\{p_{ij}\}$, γ_i , x_m と状態 $\{S_{ht}\}$ を MCMC 法を用いて推定する。

3 MCMC 手法による推定

時点 $t-1$ での家計 h の状態 (理想ベクトル) $S_{h,t-1}$ がわかっている場合に、時点 t において家計 h がブランドを購入する確率は

$$\Pr(y_{ht} | S_{h,t-1}, \gamma, x) = \sum_{s=1}^S \Pr(S_{ht} = s | S_{h,t-1}) \Pr(y_{ht} | S_{ht}, \gamma, x). \quad (6)$$

となる。 L_h を家計 h の尤度とすると、

$$L_h = \sum_{S_{h1}} \sum_{S_{h2}} \dots \sum_{S_{hT_h}} [p(S_{h1}) p(y_{h1} | S_{h1}) \prod_{t=2}^{T_h} p(S_{ht} | S_{h,t-1}) p(y_{ht} | S_{ht}, r, x)]. \quad (7)$$

さらに $L = \prod_{h=1}^H L_h$ 、すなわち全家計の尤度とする。尤度 L は複雑であり、非線形最適化のアルゴリズムを用いても尤度を最大化することは難しい。

Kitagawa(1987) は再帰的な方法により、パラメータの推定方法について示している。ただし、このような再帰的な方法をもってしても本モデルの推定は複雑な計算が必要である。そこで MCMC 法を用いて推定することとする。

MCMC 法は統計学の分野で研究が進み、多くの分野において実証分析で応用されている。この手法は Bayes 統計学における事後分布の計算を行うためのシミュレーションの方法であり、複雑な事後分布の計算や未知母数の個数が非常に多いときには有効な手法である。特にマーケティングにおいては消費者の異質性をいかにしてマーケティング・モデルに取り込み、データから推定を行うかという問題が長らく議論されてきたが、階層的 Bayes により消費者の異質性を確率変数と

して表現し、MCMC法を用いて推定を行うという手法が主流となっている (Allenby and Rossi 1999)。

本研究においてMCMC法を適用することの利点は、 $\{S_{ht}\}$ を未知パラメータとして扱い他のパラメータと一緒にシミュレートすることができる点にある。

3.1 同時分布の定式化

まず最初に、パラメータと状態の同時分布を示す。同時分布は

$$\begin{aligned} g(\varphi, \mathbf{p}, \mathbf{x}, \gamma | \psi) &= g(\mathbf{x}, \gamma, \mathbf{p} | \psi, \varphi) g(\varphi | \psi) \\ &= g(\mathbf{x}, \gamma | \psi, \varphi) g(\mathbf{p} | \psi, \varphi) g(\varphi | \psi) \\ &= g(\mathbf{x}, \gamma | \psi, \varphi) g(\mathbf{p} | \varphi) g(\varphi | \psi) \end{aligned} \quad (8)$$

となる。ただし $g(\cdot)$ はパラメータの同時分布であり $\mathbf{x} = \{x_m\}$, $\gamma = \{\gamma_i\}$, $\mathbf{p} = \{p_{ij}\}$, $\psi = \{\psi_{ht}\}$, $\varphi = \{\varphi_{ht}\}$ である。

(8) は、 φ という条件で、推移確率 \mathbf{p} が他のパラメータおよびデータ ψ と独立であることによるものである。

3.2 事後分布のサンプリング

g 番目の $\mathbf{x}^{(g)}, \gamma^{(g)}, \mathbf{p}^{(g)}, \varphi^{(g)}$ のサンプリングが行われた場合ギブス・サンプリングを用いて事後分布のサンプリングは以下のようにして得られる。

$$\begin{aligned} \varphi^{(g+1)} &\text{ from } \varphi | \psi, \mathbf{x}^{(g)}, \gamma^{(g)}, \mathbf{p}^{(g)} \\ \mathbf{p}^{(g+1)} &\text{ from } \mathbf{p} | \varphi^{(g+1)}, \\ \mathbf{x}^{(g+1)} &\text{ from } \mathbf{x} | \psi, \gamma^{(g)}, \varphi^{(g+1)}, \\ \gamma^{(g+1)} &\text{ from } \gamma | \psi, \mathbf{x}^{(g+1)}, \varphi^{(g+1)}. \end{aligned}$$

$g+1$ 番目のサンプリングでは、まず φ を発生させる。 φ の要素である S_{ht} の同時分布からサンプリングを行う。次に \mathbf{p} を φ のみから発生させる。何故なら \mathbf{p} は \mathbf{x}, γ と独立であるからである。最後に \mathbf{x} と γ を発生させる。サンプリング手法の詳細については以下のとおりである。

3.3 φ のサンプリング

$\varphi_{h,T_h} = (S_{h,1}, \dots, S_{h,T_h})$ の同時密度関数は Chib(1996) と同様に、以下のように書くことができる。

$$\begin{aligned}
 g(\varphi_{h,T_h} | \psi_{h,T_h}) &= g(S_{h,T_h}, S_{h,T_h-1}, \dots, S_{h,2}, S_{h,1} | \psi_{h,T_h}) & (9) \\
 &= g(S_{h,T_h} | \psi_{h,T_h}) g(\varphi_{h,T_h-1} | \psi_{h,T_h}, S_{h,T_h}) \\
 &= g(S_{h,T_h} | \psi_{h,T_h}) g(S_{h,T_h-1} | \psi_{h,T_h}, \varphi^{h,T_h}) g(\varphi_{h,T_h-2} | \psi_{h,T_h}, \varphi^{h,T_h-1}) \\
 &\quad \vdots \\
 &= g(S_{h,T_h} | \psi_{h,T_h}) \prod_{t=1}^{T_h-1} g(S_{ht} | \psi_{h,T_h} \varphi^{h,t+1})
 \end{aligned}$$

$g(S_{ht} | \psi_{h,T_h} \varphi^{h,t+1})$ は Bayes の定理により導かれる。

$$\begin{aligned}
 g(S_{ht} | \psi_{h,T_h} \varphi^{h,t+1}) &= g(S_{ht} | \psi_{ht}, \psi^{h,t+1}, \varphi^{h,t+1}) \\
 &\propto g(S_{ht} | \psi_{h,t}) f(\psi^{h,t+1}, \varphi^{h,t+1} | \psi_{ht}, S_{ht}) \\
 &\propto g(S_{ht} | \psi_{h,t}) g(S_{h,t+1} | S_{ht}, \psi_{ht}) f(\psi^{h,t+1}, \varphi^{h,t+2} | \psi_{ht}, S_{ht}, S_{h,t+1}) \\
 &\propto g(S_{ht} | \psi_{h,t}) g(S_{h,t+1} | S_{ht}) & (10)
 \end{aligned}$$

3行目から4行目へは $f(\psi^{h,t+1}, \varphi^{h,t+2} | \psi_{ht}, S_{ht}, S_{h,t+1})$ は S_{ht} と独立であることを利用した。最終行の第2項 $g(S_{h,t+1} | S_{ht})$ は S_{ht} から $S_{h,t+1}$ への推移確率である。最終行の第1項 $g(S_{ht} | \psi_{h,t})$ は以下の予測ステップと更新ステップから得ることができる。

予測ステップ

$$\begin{aligned}
 \Pr(S_{ht} = j | \psi_{h,t-1}) &= \sum_{i=1}^S \Pr(S_{ht} = j, S_{h,t-1} = i | \psi_{h,t-1}) \\
 &= \sum_{i=1}^S \Pr(S_{ht} = j | S_{h,t-1} = i, \psi_{h,t-1}) \Pr(S_{h,t-1} = i | \psi_{h,t-1}) \\
 &= \sum_{i=1}^S p_{ij} \Pr(S_{h,t-1} = i | \psi_{h,t-1}). & (11)
 \end{aligned}$$

更新ステップ

$$\begin{aligned}
 \Pr(S_{ht} = j | \psi_{ht}) &= \Pr(S_{ht} = j | y_{ht}, \psi_{h,t-1}) \\
 &= \frac{f(y_{ht} | S_{ht} = j, \psi_{h,t-1}) \Pr(S_{ht} = j | \psi_{h,t-1})}{f(y_{ht} | \psi_{h,t-1})}. & (12)
 \end{aligned}$$

ただし

$$f(y_{ht}|\psi_{h,t-1}) = \sum_{j=1}^S f(y_{ht}|S_{ht} = j, \psi_{h,t-1}) \Pr(S_{ht} = j|\psi_{h,t-1}).$$

とする。(12)式の第1行から第2行へはBayesの定理を利用した。 $t = 1, t = 2, t = 3$ と時点を進め各時点毎に予測ステップと更新ステップを行うことにより、 $g(S_{ht}|\psi_{h,t})$ を得ることができる。

家計 h について $g(S_{ht}|\psi_{h,t})$ が得られると、(10)式から $g(S_{ht}|\psi_{h,T_h}\varphi^{h,t+1})$ は

$$\Pr(S_{ht} = j|\psi_{h,T_h}\varphi^{h,t+1}) = \frac{\Pr(S_{ht} = j|\psi_{h,t})g(S_{h,t+1}|S_{ht} = j)}{\sum_{i=1}^S \Pr(S_{ht} = i|\psi_{h,t})g(S_{h,t+1}|S_{ht} = i)}. \quad (13)$$

となる。家計 h について時点 t 以降の状態の履歴 $\varphi^{h,t+1}$ が分かっている場合には(0,1)区間の一様分布から発生させた乱数を rv_{ht} を用いて

$$\sum_{i=1}^j \Pr(S_{ht} = i|\psi_{h,T_h}\varphi^{h,t+1}) \leq rv_{ht} < \sum_{i=1}^{j+1} \Pr(S_{ht} = i|\psi_{h,T_h}\varphi^{h,t+1})$$

を満たす j を $S_{ht} = j$ として S_{ht} のサンプリングを行う。家計 h について $t = T_h, t = T_h - 1, \dots, t = 2, t = 1$ とサンプリングをして φ_{h,T_h} を得る。

3.4 p のサンプリング

状態 S_{ht} が与えられた場合、推移確率行列 P のサンプリングは容易に行うことができる。

$p_i = (p_{i1}, \dots, p_{iS})$ の事前分布が家計全体で既知のパラメータ・ベクトル $a_i = (a_{i1}, \dots, a_{iS})$ を持つ Dirichlet 分布に従うと仮定する。

$$p_i|a_i \sim \text{Dirichlet}(a_{i1}, \dots, a_{iS}).$$

S_{ht} が得られた場合の p_i の事後分布は、

$$p_i \sim \text{Dirichlet}(a_{i1} + n_{i1}, \dots, a_{iS} + n_{iS}) \quad (14)$$

ただし n_{ij} は家計全体での状態 i から j への遷移数である。

このとき p_i は以下のようにしてサンプリングすることができる。

$$p_{i1} = \frac{z_{i1}}{\sum_{j=1}^S z_{ij}}, \dots, p_{iS} = \frac{z_{iS}}{\sum_{j=1}^S z_{ij}}, \quad (15)$$

$$z_{ij} \sim \text{Gamma}(a_{ij} + n_{ij}, 1).$$

3.5 x のサンプリング

x の事前分布を平均 x_0 、共分散行列 X_0 の正規分布とする。Bayes の定理により、 x の事後分布は以下ようになる。

$$g(\mathbf{x}|\boldsymbol{\psi}, \boldsymbol{\gamma}, \boldsymbol{\varphi}) \propto \phi(\mathbf{x}|\mathbf{x}_0, X_0) \times \prod_{h=1}^H \prod_{t=1}^{T_h} p(y_{ht}|\mathbf{x}, \boldsymbol{\gamma}, S_{ht}) \quad (16)$$

(16) 式の第 2 項は各家計のセグメントへの所属確率が与えられた時の全観測値の同時分布である。

x の事後分布はよく知られた分布で表現することはできない。そこでメトロポリス・ヘイスティングス (Metropolis-Hastings, 以下 M-H) アルゴリズムを用いて推定を行う。本研究では酔歩連鎖 (random walk) を用いた M-H アルゴリズム (Chiang et al. 1999) を採用した。この酔歩連鎖では新しい点の候補 $x^{(c)}$ は以下のようにして得られる。

$$\mathbf{x}^{(c)} = \mathbf{x}^{(g)} + d_x' \mathbf{u} \quad (17)$$

ただし $\mathbf{u} \sim N(0, I)$ であり、 d_x は適当な定数ベクトルである。このとき $x^{(c)}$ は以下の確率で受け入れられる。

$$\min \left\{ \frac{g(\mathbf{x}^{(c)}|\boldsymbol{\psi}, \boldsymbol{\gamma}, \boldsymbol{\varphi})}{g(\mathbf{x}^{(g)}|\boldsymbol{\psi}, \boldsymbol{\gamma}, \boldsymbol{\varphi})}, 1 \right\}. \quad (18)$$

$x^{(c)}$ が受け入れられた場合には $x^{(g+1)} = x^{(c)}$ 、 $x^{(c)}$ が受け入れられない場合には $x^{(g+1)} = x^{(g)}$ として、次のサンプリングに進む。

3.6 γ のサンプリング

γ の事前分布を平均 γ_0 、共分散行列 R_0 の正規分布とする。Bayes の定理により、 γ の事後分布は以下ようになる。

$$g(\boldsymbol{\gamma}|\boldsymbol{\psi}, \mathbf{x}, \boldsymbol{\varphi}) \propto \phi(\boldsymbol{\gamma}|\boldsymbol{\gamma}_0, R_0) \times \prod_{h=1}^H \prod_{t=1}^{T_h} p(y_{ht}|\mathbf{x}, \boldsymbol{\gamma}, S_{ht}) \quad (19)$$

(19) 式の第 2 項は各家計のセグメントへの所属確率が与えられた時の全観測値の同時分布である。 γ についても M-H アルゴリズムを用いて推定を行う。

$$\boldsymbol{\gamma}^{(c)} = \boldsymbol{\gamma}^{(g)} + d_\gamma' \mathbf{u} \quad (20)$$

ただし d_γ は適当な定数ベクトルである。このとき $\gamma^{(c)}$ は以下の確率で受け入れられる。

$$\min \left\{ \frac{g(\gamma^{(c)}|\boldsymbol{\psi}, \boldsymbol{x}, \boldsymbol{\varphi})}{g(\gamma^{(g)}|\boldsymbol{\psi}, \boldsymbol{x}, \boldsymbol{\varphi})}, 1 \right\}. \quad (21)$$

$\gamma^{(c)}$ が受け入れられた場合には $\gamma^{(g+1)} = \gamma^{(c)}$ 、 $\gamma^{(c)}$ が受け入れられない場合には $\gamma^{(g+1)} = \gamma^{(g)}$ として、次のサンプリングに進む。

4 実証分析

4.1 データについて

実証分析では日経 NEEDS-SCAN から得られたスーパーマーケットのインスタントコーヒーのデータを用いた。データ期間は2000年1年間である。対象家計は期間中にインスタントコーヒーを5回から24回購入した183パネル(世帯)、総購買履歴数1455である。対象ブランドは8ブランドである。ただしPBはストア・ブランドである。マーケティング変数として価格掛け率を用いた。期間中平均購買率と期間中平均価格掛け率は表1のとおり。

4.2 提案モデルとLOGMAP-Jとの比較

ブランドの布置は2次元とし提案モデルとLOGMAP-JについてMCMC法によりパラメータと状態の推定を行った。²

MCMC法を利用する場合には標本が均衡分布に収束するまでは、初期値に依存する期間(burn-in period)であるとして破棄し、それ以降の標本を用いて推論を行うことになっている。本研究では8,000サンプルのうちの初期5,000サンプルは棄て、残りの3,000サンプルを用いて推論を行うこととした。

MCMC法で推定したモデルの選択の基準には周辺尤度(marginal likelihood)やその比であるBayes比を用いることが多い。周辺尤度の最も単純な推定値はモンテカルロ積分を用いて求めることができる³。さらにデータとの適合という点からモデルを比較するために適中率を計算した。適中率 $HitR$ は以下で算出した。

$$HitR = \frac{\sum_h \sum_t \sum_m H_{htm}}{\sum_h \sum_t N_{ht}}$$

表 1: 期間中平均購買率と期間中平均価格掛け率

ブランド	購買率	価格掛け率
AB	17.3%	0.74
AM	6.8%	0.77
NE	17.4%	0.76
NG	21.5%	0.79
NM	1.7%	1.00
NP	1.0%	0.94
PB	26.8%	0.94
UT	7.6%	0.79

表 2: モデル間の比較

	提案モデル	LOGMAP-J
周辺尤度 (in sample)	-1133.29	-1400.01
適中率 (in sample)	75.2%	69.0%

ただし

$$\hat{P}_{htj} = \Pr(y_{ht} = 1_j | \hat{\theta}), \hat{\theta} \text{ は推定されたパラメータ}$$

$$\delta_{htm} = \begin{cases} 1 & \text{家計 } h \text{ が時点 } t \text{ においてブランド } m \text{ を選択した場合} \\ 0 & \text{それ以外} \end{cases}$$

$$\hat{\delta}_{htm} = \begin{cases} 1 & \hat{P}_{htm} = \max(\hat{P}_{htj}) \\ 0 & \text{それ以外} \end{cases}$$

$$H_{htm} = \begin{cases} 1 & \delta_{htm} = \hat{\delta}_{htm} \text{ の場合} \\ 0 & \text{それ以外} \end{cases}$$

N_{ht} : 家計 h の時点 t での選択肢数 (ブランド数)

周辺尤度、適中率について提案モデルと LOGMAP-J の比較結果を表 2 に示す。
提案モデルのほうが周辺尤度が大きく、適中率も高くなっている。

4.3 提案モデルの推定結果

次に提案モデルのパラメータの推定結果を示す。表 3、表 4 は x と γ の推定結果である。ただし数値はサンプリング結果の平均値、[] は 95% 信頼区間である。また提案モデルのパラメータのうち x と γ の分布の図 2、図 3 に示す。価格のパラメータ γ_1 は提案モデルでは 10.54、LOGMAP-J では 9.18 であり、提案モデルのほうが価格弾力性が大きかった。 γ が正であるのは、 $\beta_{s,1}$ を負または 0 に固定していることによる。

図 4 は提案モデルで推定したブランドの布置と、理想ベクトルの分布の平均値が表 5 にはその数値が記されている。[3][4][5][7] の理想ベクトルの割合が高くなっており、全体として価格感度が高いことがわかる。

図 4 からわかるように [3] の理想ベクトルの方向には PB が、これと 180 度反対の [7] の理想ベクトルの方向には NG が布置されており、これら 2 つのブランドの選好は正反対であることが分かる。NG と PB は両者ともトップシェアのブランドであり、これら 2 つのブランドの布置が 180 度反対であることは面白い。

[3][7] の理想ベクトルと 90 度交わる形で [1][9] の方向にも所属確率の高い理想ベクトルがある。[1] の方向には (AB, NE) が [9] の方向には (AM, NM, NP, UT) などがある。ただし、各ブランドとも NG や PB に比べて原点からの距離は小さく、ブランド固有の効用は小さいことがわかる。日本のインスタント・コーヒーには製造方法からフリーズ・ドライ・タイプとスプレー・タイプという 2 つの種類が存在している。面白いことに (AB, NE) はスプレー・タイプ、(AM, NM, NP, UT) はフリーズ・ドライ・タイプであり、消費者の選好構造と製品タイプが一致していることがわかる。

図 5 には LOGMAP-J で推定したブランドの布置と、理想ベクトルが示されている。表 5 にはその数値が記されている。全体として提案モデルより右に少し回転した形になっているがブランド間の関係はほぼ同じである。また理想ベクトルの分布もあまり変わらない。ただし [12][16] のように価格に敏感でない層の割合が増えている。

4.4 個人の理想ベクトルの変化

個人の理想ベクトルの変化である状態推移行列 P を図 6 に示す。推移確率行列の対角成分のうち $p_{1,1}, p_{3,3}, p_{4,4}, p_{5,5}, p_{7,7}, p_{9,9}, p_{15,15}$ の 7 つの推移確率が非常に大きく

表 3: 提案モデルによるパラメータ

	x_1	x_2
AB	2.03 [1.35, 2.63]	3.56 [2.79, 4.14]
AM	-1.43 [-2.15, -0.28]	-2.59 [-3.41, -1.88]
NE	0.93 [-0.20, 1.86]	4.16 [3.30, 4.85]
NG	-7.65 [-8.55, -6.89]	2.28 [1.73, 3.00]
NM	-0.90 [-2.14, 0.05]	-2.73 [-3.27, -2.07]
NP	-0.28 [-1.08, 0.42]	-2.10 [-2.64, -1.61]
PB	12.26 [11.18, 13.29]	-0.67 [-1.32, 0.13]
UT	-4.96 [-5.97, -3.90]	-1.91 [-2.49, -1.36]
γ_1	10.54 [9.04, 11.68]	

数値はサンプリング結果の平均値。[] は 95%信頼区間。

表 4: LOGMAP-J によるパラメータ

	x_1	x_2
AB	1.70 [0.91, 2.29]	2.32 [1.36, 3.00]
AM	-1.66 [-2.17, -1.13]	-0.39 [-1.05, 0.16]
NE	1.88 [1.35, 2.45]	2.99 [2.52, 3.41]
NG	-2.18 [-2.50, -1.84]	4.50 [3.90, 5.15]
NM	-1.99 [-2.96, -1.35]	-2.70 [-3.34, -2.04]
NP	-1.10 [-2.10, 0.31]	-1.46 [-2.09, -0.78]
PB	5.41 [4.94, 5.91]	-3.71 [-4.16, -3.17]
UT	-2.05 [-2.86, -1.47]	-1.56 [-2.39, -0.77]
γ_1	9.18 [8.54, 10.04]	

数値はサンプリング結果の平均値。[] は 95%信頼区間。

表 5: 理想ベクトルの分布

s	理想ベクトル の所属確率 (提案モデル)	理想ベクトル の所属確率 (LOGMAP-J)	β_{s1}	β_{s21}	β_{s22}
1	9.5%	20.8%	-0.707	0.500	0.500
2	0.5%	10.3%	-0.707	0.707	0.000
3	18.1%	6.7%	-0.707	0.500	-0.500
4	26.1%	12.6%	-0.707	0.000	0.707
5	16.7%	14.5%	-1.000	0.000	0.000
6	0.4%	0.2%	-0.707	0.000	-0.707
7	14.1%	0.4%	-0.707	-0.500	0.500
8	0.9%	10.3%	-0.707	-0.707	0.000
9	5.1%	0.0%	-0.707	-0.500	-0.500
10	0.5%	1.1%	0.000	0.707	0.707
11	0.5%	0.1%	0.000	1.000	0.000
12	0.6%	7.1%	0.000	0.707	-0.707
13	0.6%	0.3%	0.000	0.000	1.000
14	0.4%	3.1%	0.000	0.000	0.000
15	3.9%	0.0%	0.000	0.000	-1.000
16	0.9%	11.2%	0.000	-0.707	0.707
17	0.5%	0.0%	0.000	-1.000	0.000
18	0.6%	1.3%	0.000	-0.707	-0.707

なっており、これらの [1][3][4][5][7][9][15] の理想ベクトルに所属する消費者は同一の理想ベクトルに居続けることがわかる。インスタント・コーヒー市場において消費者の選好は変わりにくいと解釈することができる。

図7には理想ベクトルの変化の程度を評価した。各家計の多様性追求指数 (VS_h) は

$$VS_h = 1 - \max\{T_h^{-1} \sum_{t=1}^{T_h} I(j = \max(S_{ht}))\} \quad j = 1, \dots, S$$

ただし

$\max(S_{ht})$ は時点 t において $\Pr(S_{ht} = i)$ を最大にする i

$I(\)$ は $j = \max(S_{ht})$ のとき 1、それ以外では 0 をとるインディケータ関数

とした。多様性追求指数が 0 に近い家計ほど、ひとつの理想ベクトルに留まり続けることになる。本研究の結果からは、多様性追求指数が 0.1 以下の家計は全家計の 80.9% を占めており、多くの家計では理想ベクトルは変化しないことになる。本研究で扱ったインスタント・コーヒーのような市場では消費者選好は固定的であると理解できる。

図8はある家計のセグメントの変化である。家計 A は、理想ベクトル [7] から移動せずに購買行動を行っていることがわかる。一方、家計 B では価格に敏感でない理想ベクトル [15] から、価格に敏感でしかもマップ上では [15] と 180 度反対の [4] に移動したことがわかる。

このように提案したモデルは消費者ひとりひとりの理想ベクトルの変化を推定することが可能であり、個人対応のマーケティングにおいて有用なツールとなりえる。

5 まとめ

本研究では消費者個人内で理想ベクトルが時間とともに変化するモデルを提案した。本研究で提案したモデルにより個人内での選好構造の変化を考慮した市場構造分析を行うことが可能となった。状態とパラメータの推定にはマルコフ連鎖モンテカルロ法が適用され、消費者の理想ベクトルの変化が推定された。購買履歴データを用いた実証分析した結果、多くの消費者の理想ベクトルは変化しない

ことがわかった。ただし一部の家計では理想ベクトルが大きく変化することがわかった。

最後に今後の課題をいくつか挙げる。

本研究では消費者の時点 t での理想ベクトルは時点 $t-1$ にのみ依存して変化するとした。このようなモデル化により、「いつ」理想ベクトルが変化したのかわかることはできるが、「なぜ」理想ベクトルが変化したのかわからない。所属セグメントの変化を顕在変数により表現する必要もあろう。

また、本研究では18個の理想ベクトルをアприオリに仮定しているが、消費者が所属すると推定された理想ベクトルは全ベクトルの半数以下であった。理想ベクトルの数について検討する必要がある。さらにモデルの周辺尤度の計算ではモンテカルロ積分を用いたが、リバーシブルジャンプ MCMC (Green 1995) や birth-death MCMC (Stephens 2001) 等のようにパラメータとモデルの同時推定を行う方法もあるので、モデル選択の方法を検討をすることが必要となつてこよう。

新しい消費者購買行動データの利用も今後の課題である。インターネットの普及により消費者の Web ページの閲覧や商品選択に関する行動の記録が可能となっている。広告の閲覧、値引き等のプロモーション、これまでの購買履歴等が取得可能となっている。これら電子的世界でのデータを活用した分析も期待される。

注

- 1 表現される空間は必ずしもユークリッド空間であるとは限らない。自己組織化マップを用いたブランドのポジショニング分析のように非ユークリッド空間の場合もありうる。
- 2 実証分析では事前分布のパラメータをそれぞれ $a'_i = 0.1$ 、 $x_0 = 0$ 、 $X_0 = 3I$ 、 $\gamma_0 = 0$ 、 $R_0 = 3I$ とした。また $d_x = 0.05$ 、 $d_\gamma = 0.05$ とした。
- 3 しかしながら本研究で提案したモデルのように事前分布と尤度関数の形状が異なる場合にはこの推定量は精度が悪いことが指摘されている (Raftery 1996)。

参考文献

- Allenby, G.M. and P.E. Rossi (1999), "Marketing Models of Household Heterogeneity," *Journal of Econometrics*, 89, 57-78
- Böckenholt, U. and R. Langeheine (1996), "Latent Change in Recurrent Choice Data," *Psychometrika*, Vol.61, 285-301.
- Carroll, J.D. (1972), "Individual differences and multidimensional scaling," in *Multidimensional Scaling: Theory and Applications in the Behavioral Sciences Vol.1 Theory*, R.N. Shepard, A.K. Romney and S.B. Nerlove (eds.), Seminar Press.
- Chiang, J., S. Chib and C. Narasimhan (1999), "Markov chain Monte Carlo and models of consideration set and parameter heterogeneity," *Journal of Econometrics*, 89,223-248.
- Chib, S. (1996), "Calculating posterior distributions and modal estimates in Markov mixture models," *Journal of Economics*, 75,79-97.
- Cooper, L.G. and A. Inoue (1996), "Building Market Structures From Consumer Preferences," *Journal of Marketing Research*, 33, 293-306.
- DeSarbo, W.S., Y. Kim and D. Fong (1999), "A Bayesian multidimensional scaling procedure for the spatial analysis of revealed choice data," *Journal of Econometrics*, 89, 79-108.
- Green, P.J. (1995), "Reversible jump Markov chain Monte Carlo computation and Bayesian model determination," *Biometrika*, 82, 711-732.
- Kahn, B. (1995), "Consumer variety-seeking among goods and services," *Journal of Retailing and Consumer Services*, Vol.2, 139-148.
- Kamakura, W.A., M. Wedel and J. Agrawal (1994), "Concomitant Variable Latent Class Models for Conjoint Analysis," *International Journal of Research in Marketing*, 11,451-64.

- Kitagawa, G. (1987), “Non-Gaussian state space modeling of nonstationary time series,(with discussion)”, *Journal of American statistical Association*, 82,1032-1063.
- Petty, R.E. and J.T. Cacioppo (1986), *Communication and Persuasion: Central and Peripheral Routes to Attitude Change*, New York: Springer-Verlag.
- Poulsen, C.S. (1990), “Mixed Markov and latent Markov modeling applied to brand choice behavior,” *International Journal of Research in Marketing*, Vol.7, 5-19.
- Raftery, A.E. (1996), “Hypothesis testing and model selection,” in *Markov Chain Monte Carlo in Practice*,” W. R. Gilks, S. Richardson and D.J. Spiegelhalter, (eds.), Chapman & Hall
- Ramaswamy, V. (1997), “Evolutionary preference segmentation with panel survey data: An application to new products,” *International Journal of Research in Marketing*, 14,57-80.
- Rossi, P.E., R.E. McCulloch and G.M. Allenby (1996), “The Value of Purchase History Data in Target Marketing,” *Marketing Science*, Vol15, 321-340.
- Stephens, M. (2001), “Bayesian analysis of mixture models with an unknown number of components -an alternative to reversible jump methods,” *Annals of Statistics*, 28, 40-74.
- Yang, Sha, and G.M. Allenby (2000), “A Model for Observation, Structural, and Household Heterogeneity in Panel Data,” *Marketing Letters*, 11, 137-149
- Wedel, M. and W.A.Kamakura (1998), *Market Segmentation*, Kluwer Academic Publishers.
- 岡太彬訓 (2001) 「次元の縮約とクラスター化」『マーケティングの数理モデル』岡太彬訓・木島正明・守口剛 編, 朝倉書店.
- 片平秀貴 (1990) 「マッピングを伴う市場反応モデル」マーケティング・サイエンス No.36 13-27.
- 清水聰 (1999) 『新しい消費者行動』千倉書房.

図 2: 提案モデルのパラメータ x と γ の分布 (1)

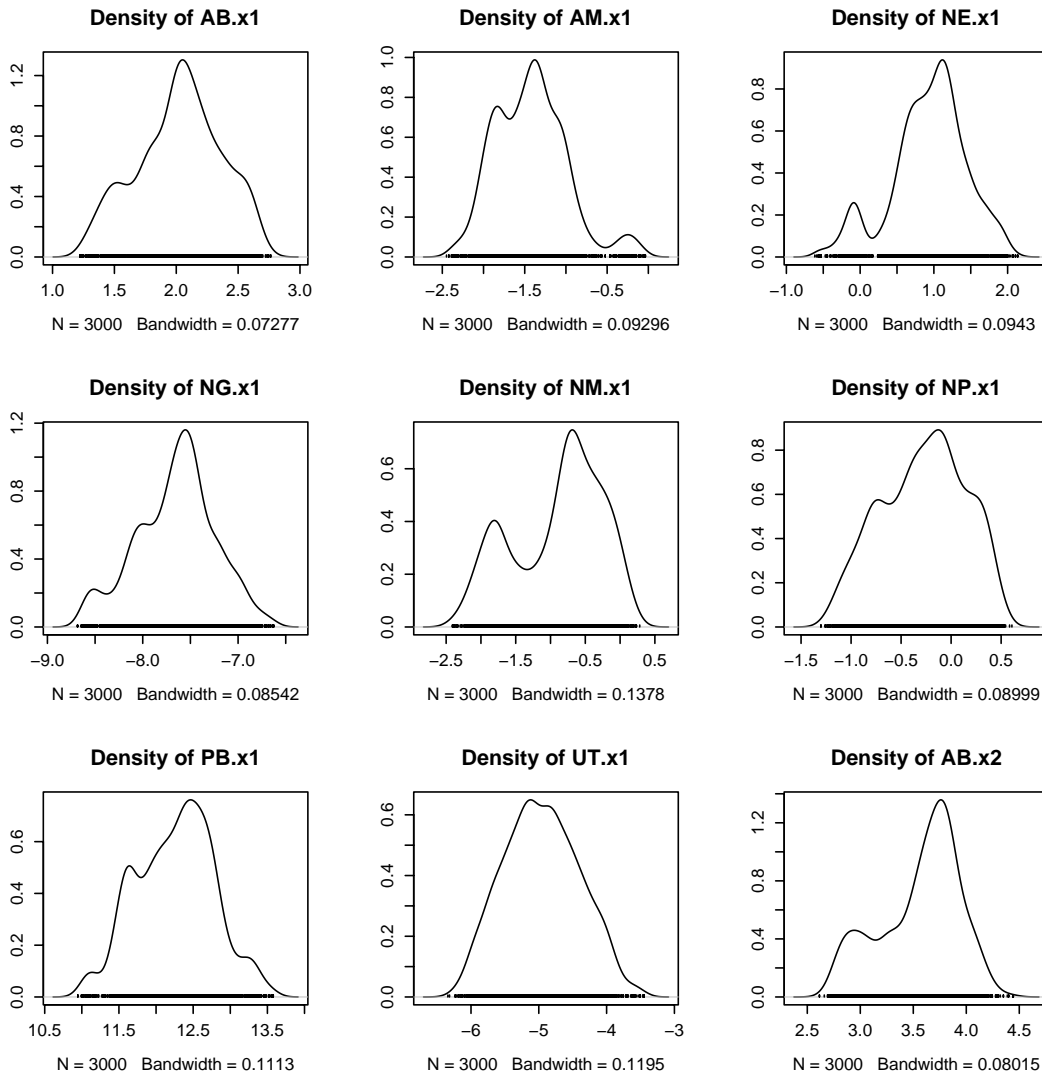


図 3: 提案モデルのパラメータ x と γ の分布 (2)

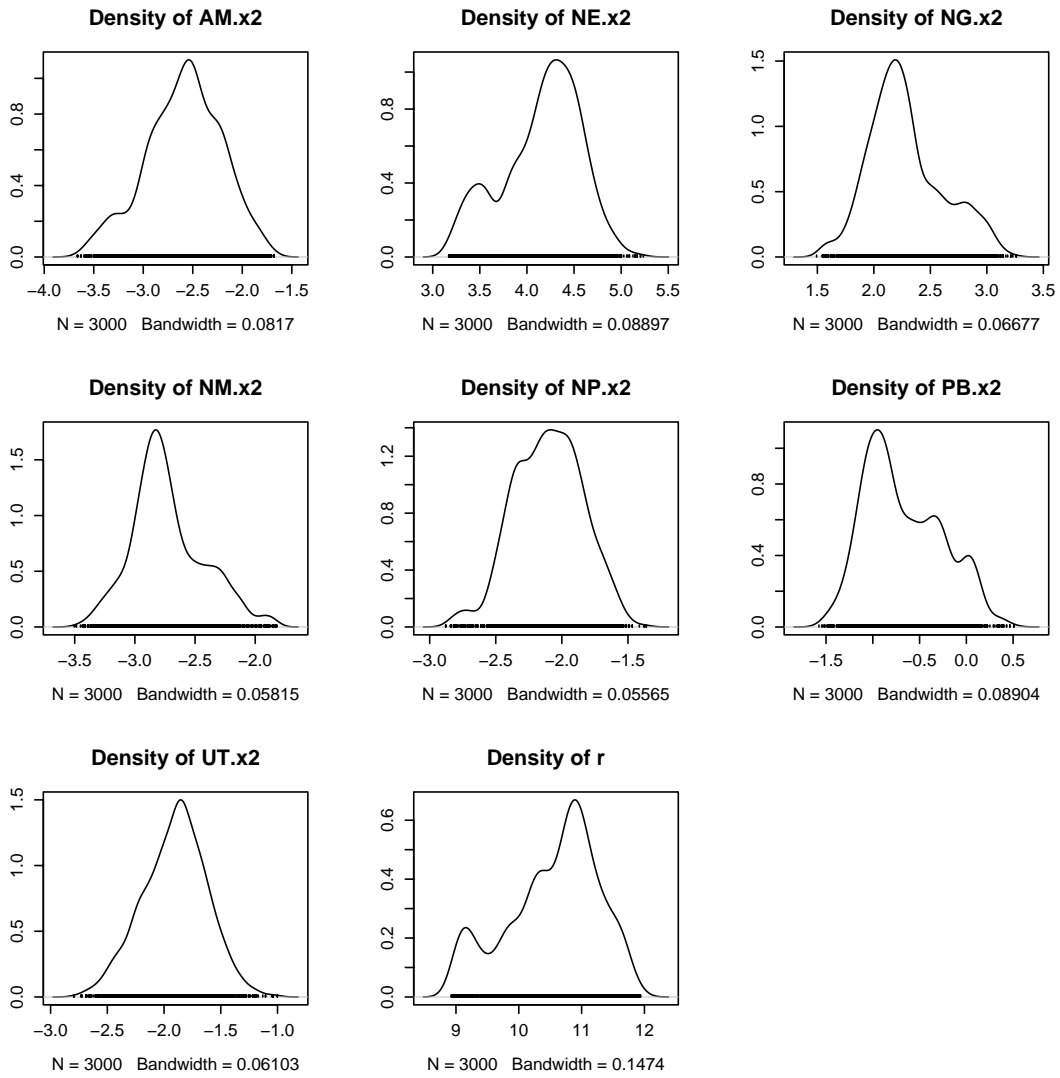




図 4: ブランドの布置と理想ベクトルの分布 (提案モデル)



理想ベクトルの長さは期間中の平均家計シェアに比例。
 ただし図中にはシェアが4%以上の理想ベクトルのみを描画している。

図 5: ブランドの布置と理想ベクトルの分布 (LOGMAP-J)



理想ベクトルの長さは期間中の平均家計シェアに比例。
 ただし図中にはシェアが4%以上の理想ベクトルのみを描画している。

図 6: 状態推移確率の分布




図 7: 各家計の理想ベクトルの変化の程度




図 8: ある家計の理想ベクトルの変化

