

# プロダクト空間とブランド空間を考慮した ジョイント・スペース・マップ —北米ピックアップ・トラック市場への応用—

阿部 誠

北米ピックアップ・トラックのアンケート調査データを用いて、通常では推定が困難な限られた個人別選好情報から、ベイズ手法によって理想ベクトル/ポイントを推定し、ジョイント・スペース・マップを構築した。以下、三つの結論が得られた。まず、自動車製品への選好は、製品属性だけでなくブランド属性との相互作用に大きく影響される。次に、この自動車製品の選好データを描写するには、理想ポイントより理想ベクトルが適している。そして、データへのフィットと予測に関しては、この研究で提案されたヒューリスティック階層ベイズは実験ベイズよりも優れていたが、それほど大きな差は見られなかった。

キーワード：ブランド、知覚マップ、選好モデル、ジョイント・スペース、ベイズ推定、階層ベイズ

## 1. はじめに

マーケティングの目的は、顧客の知覚、選好を理解し、適切な商品をデザイン・販売して、ユーザのもとにとどけることである。マーケタは、どのような商品・サービスを (Product) いくらかで提供し (Price)、どのような広告や販売促進を行って (Promotion)、どの流通経路で販売するか (Place)、という 4P の要素を決めなければならない。成熟した経済社会で特に重要なことは、個々の消費者 (顧客) の違い (商品に関する選好やマーケティング刺激に対する反応の異質性) を十分に認識し、それに適切に対応することである。マーケティングでは、セグメンテーション、ポジショニング、ターゲティングと呼ばれる差別化された商品の提供や顧客によって異なったマーケティング活動などが、早い時期から行われてきた。

消費者の知覚と選好を分析する方法として、ジョイント・スペース分析と呼ばれる手法がよく使われる。これは、消費者の対象製品に対する平均的知覚を空間上にマッピングすると同時に、一人一人の消費者の選好を理想ベクトルあるいは理想ポイントとして同じ空間上に描いたものである。ジョイント・スペース・マップでは、通常、製品の位置は消費者間で共通である

が、理想ベクトル/ポイントは選好の異質性を反映して個人別に推定される。したがって、理想ベクトル/ポイントを計算するには対象製品の選好に関する個人データが十分にないと困難なので、例えばアンケートなどで個々人の選好データを収集する場合には、推定に必要な情報量が得られるように質問票をデザインしなければならない。

この研究では、通常では推定が困難な限られた個人別選好情報から、ベイズ手法によって理想ベクトル/ポイントを推定する。具体的には、ウェブ・アンケートによって得られた北米ピックアップ・トラックに対する個人別の選好データを用いて、製品空間とブランド空間に理想ベクトル/ポイントを推定する。方法論的には、2種類のベイズ推定手法、(1)サンプル中の回答者をプールしたデータを事前分布に用いた実験ベイズと、(2)事前分布は個人の異質性を表していると解釈し、事後分布と矛盾しないような事前分布をデータから導き出すヒューリスティック階層ベイズとを比較する。

以下、この論文では、まず節2でマーケティングにおけるマッピング手法を簡単に紹介したあと、節3では今回の分析に用いられた北米ピックアップ・トラックのデータを、節4ではジョイント・スペース・モデルの説明と推定方法を説明する。節5では競合モデルを比較し、その中で1番優れたモデルの分析結果を報告する。最後に節6で研究の結論と今後の課題を提示

あべ まこと  
東京大学 大学院経済学研究科  
〒113-0033 文京区本郷7-3-1

する。

## 2. マーケティングにおけるマッピング手法

図1はマーケティングにおけるマッピング手法を簡単に類型化したものであり、知覚マップ、選好マップ、そしてジョイント・スペース・マップと大きく三つに分類できる。知覚マップに用いられるデータは、属性評価データと類似度データの2種類がある。属性評価データは、対象カテゴリの様々な属性について各製品ごとに評価したものである。このタイプのデータを収集するにあたって重要なことは、消費者が製品を判断し知覚する際に用いる主な属性を列挙することと、質問票にある属性表現が明白で回答者によって解釈が違わないようにすることである。分析手法としては因子分析が一般的であるが、判別分析などが用いられることもある。類似度データは、属性を特定せずに対象製品間の全体的な類似度を順序尺度や間隔尺度で評価したものである。属性を特定しないので、質問票の作成に主観的な要素が入りにくい、消費者が通常、製品の知覚、判断に用いる属性に基づいて類似性が評価されるなどの長所はあるが、特に新製品開発などで有用な属性情報が全く得られないため、マップ軸のネーミングも含めて空間の解釈が難しいという弱点がある。分析手法には多次元尺度法 (multidimensional scaling) が使われる。

選好マップは個人の選好を製品の知覚マップ上に表したもので、理想ベクトル・モデルと理想ポイント・モデルの2種類がある。ベクトル・モデルでは知覚マップ上の理想ベクトルの方角に行けば行くほど、またポイント・モデルでは理想ポイントに近づけば近づくほど、回答者の選好が高くなる。消費者の選好を描写するのに、どちらのモデルがより相応しいかは、製品カテゴリ、回答者、評価状況などによって異なるためにケース・バイ・ケースである。今回の研究では、理

想ベクトル・モデルと理想ポイント・モデルの両方を構築し、データに当てはまりのよい方を選択する。

ジョイント・スペース・マップは外的分析と内的分析の二つに分けられる。外的分析では、まず対象製品を知覚マップ上に定めて、その位置を既知とした上で選好データから選好マップを導き出す。したがって、知覚マップを構築するための知覚データと選好マップを構築するための選好データの2種類が必要である。内的分析はアンフォールディング (unfolding) モデルとも呼ばれ、1種類のデータ、多くの場合は時系列で観測されたブランド選択のような類似度的データから、知覚マップと選好マップを同時に導き出す。したがって、内的分析から得られたジョイント・マップは通常、属性的解釈は伴わず、主に市場の競合構造の把握に適している。

今回の研究では、ピックアップ・トラックの新製品開発が念頭に置かれているため、まず属性評価データに基づいて知覚マップを構築し、その空間上に車種の選好データから得られた各消費者の理想ベクトルまたは理想ポイントをプロットするという、ジョイント・スペースの外的分析を行う。

## 3. データ

ジョイント・スペース分析に使われたデータは、北米のピックアップに対してウェブ・アンケートによって収集された。ピックアップ・トラックとは1列乗車 (定員2, 3名) に大きな荷台の付いているタイプの自動車である。十分なサンプル数を確保するために、対象車種は主要フルサイズ8車種とスモールサイズ7車種の合計15車種が考慮された。調査期間は2002年8月の約1ヶ月間で、有効回答179人分が得られた。回答者は米調査会社がかかえるパネルからサンプリングされており、不要なバイアスは可能なかぎり取り除かれている。アンケートは、車種への選好データ、製品属性評価、そしてブランド (メーカー) に対する属性評

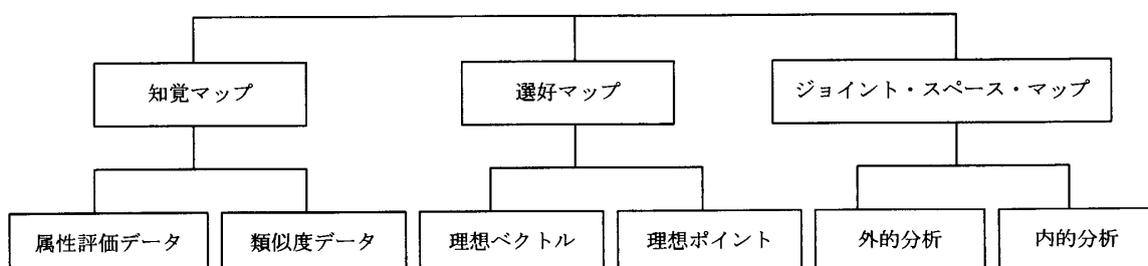


図1 マーケティングにおけるマッピング手法

価の合計三つのパートから構成されている。

アンケートの方法は、まず、各回答者にどのような車種の購入を検討しているか、どのような車種を知っているかを聞き、ピックアップ・トラックを6車種以上知っており、かつ購入可能性の高い消費者をスクリーニングした。次に、その中で選好の高い上位6車種をランク付けしてもらった。そして、選好の強い上位4車種について、22の製品属性に対して6点尺度で評価をしてもらった。最後に15車種を販売する五つのブランド（メーカ）について、九つのブランド属性に対して6点尺度で評価をしてもらった。アンケートの長さは必要最低限に抑えたが、それでも自動車のような複雑な製品の場合、質問項目数は134（＝選好ランキング＋22製品属性評価×4車種＋9ブランド属性評価×5ブランド）である。

#### 4. モデル

この研究では選好の外的分析を行うため、まず第1のステップでは、属性評価データに基づいて知覚マップを構築し、被験者の平均的な知覚としての製品の位置を定める。第2ステップでは、個々人の製品に対する選好データに基づいて、理想ベクトルあるいは理想ポイントを回答者別に求める。

##### 4.1 知覚マップの構築：プロダクト・マップとブランド・マップ

被験者の属性評価データから因子分析によって知覚マップを計算する。今回対象のカテゴリは自動車で、製品属性以上にブランド（メーカ）の影響が大きな関心である。また、対象製品には同一のメーカから複数の車種が含まれている。そこで、対象車種に関しての製品属性評価からはプロダクト（車種）・マップを構築し、メーカに対してのブランド属性評価からはブランド（メーカ）・マップを構築する。つまり個々の対象車種に対して、プロダクト空間での座標とそのメーカに対応したブランド空間での座標が決定されることになる。

##### 4.2 選好ランキングに基づく理想ベクトル/ポイントのモデル化

6車種は回答者の選好の順序によってランク付けされているため、選好データは順序尺度で与えられている。ここでは、選好ランク No.1の車種は6車種の中から一番好まれる車種の選択、選好ランク No.2の車種は残りの5車種の中から一番好まれる車種の選択、…、選好ランク No.5の車種は残りの2車種の中から

一番好まれる車種の選択、というように解釈して、これら五つの選択データが独立であると仮定できるランク・ロジット・モデル (Beggs, Cardell, Hausman, 1981; Chapman and Staelin, 1982; Strauss, 1979) を用いる。それぞれの選択確率は、六つの車種に対する効用値に基づいて多項ロジット・モデルで表せるため、ランク  $r$  の車種の効用値を  $v_r$  とすると、一人の回答者のランキングの尤度関数は式(1)のように表せる。

$$L(\text{preference data}) = \text{prob}(v_1 > v_2 > \dots > v_6) \\ = \prod_{r=1}^5 \frac{e^{v_r}}{\sum_{k=r}^6 e^{v_k}} \quad (1)$$

式(2)のように、効用  $v_r$  がその車種の  $I$  次元プロダクト・マップにおける座標軸の値  $x_{ri}$  ( $i=1, \dots, I$ ) と  $J$  次元ブランド・マップにおける座標軸の値  $z_{rj}$  ( $j=1, \dots, J$ ) の線型加重和であれば、理想ベクトル・モデルになる。

$$v_r = \sum_{i=1}^I \alpha_i x_{ri} + \sum_{j=1}^J \beta_j z_{rj} \quad (2)$$

理想ポイント・モデルは、式(3)のように、効用  $v_r$  に座標の2乗和と  $\alpha_i$ ,  $\beta_j$ ,  $\gamma$  の関数となる定数項  $\delta_0$  を加えることによって定義できる。

$$v_r = \sum_{i=1}^I \alpha_i x_{ri} + \sum_{j=1}^J \beta_j z_{rj} + \gamma \left[ \sum_{i=1}^I x_{ri}^2 + \sum_{j=1}^J z_{rj}^2 \right] + \delta_0 \quad (3)$$

##### 4.3 ベイズ手法による理想ベクトル/理想ポイントの推定

理想ベクトルを用いたジョイント・スペース分析では、パラメータ  $\alpha_i$  と  $\beta_j$  を個人別に推定する必要があるが、式(1)から分かるように一人の回答者のランキングから導かれる選択回数は5回である。今回の研究のように、推定された選好モデルの予測精度を評価するためにあらかじめ検証用データを残そうとすると、キャリブレーション用の選択回数は最大でも4回に減ってしまう。つまり、組み込めるプロダクト・マップの座標軸とブランド・マップの座標軸の合計は最大でも四つであり、推定値の安定性を考えると個人別パラメータの推定はほとんど不可能である。理想ポイント・モデルではパラメータの数がもう一つ増えるので、この状況は一層深刻である。

ここではパラメータに事前分布を仮定して、それが個人の選好ランキング・データによって更新されるというベイズ的手法を用いて、この問題を克服する。ベイズの定理によると、パラメータの事後分布  $f(\theta|\text{data})$  は、式(1)で表されるロジット尤度関数と事前分布  $f(\theta)$  の積になるため、式(4)のように表せる。

$$f(\theta|\text{data}) \propto L(\text{data}|\theta)f(\theta) \quad (4)$$

事後分布のモード（最大値）は対数に変換しても不変なので、式(4)の対数をとると、

$$\log\{f(\theta|\text{data})\} = LL(\text{data}|\theta) + \log\{f(\theta)\} + \text{定数} \quad (5)$$

となる。\$LL(\text{data}|\theta)\$ は対数尤度である。パラメータ \$\theta\$ の事前分布に平均 \$\mu\_\theta\$ と共分散 \$V\_\theta\$ の多変量正規分布を仮定すると、式(5)の対数事後分布は、対数尤度と \$-1/2(\theta - \mu\_\theta)^t V\_\theta^{-1}(\theta - \mu\_\theta)\$ の和になる。\$\mu\_\theta\$ と \$V\_\theta\$ は、\$\theta\$ と区別するためにハイパ・パラメータとも呼ばれる。ニュートン法などで最大化問題を数値的に求める場合、gradient と hessian は対数尤度のものに、それぞれ \$-V\_\theta^{-1}(\theta - \mu\_\theta)\$ と \$-V\_\theta^{-1}\$ が加わるだけなので、既存のロジットのコードを少し変更するだけでよい。

ベイズ統計で議論になるのは事前分布をどのように指定するか、あるいはハイパ・パラメータをどう設定するかであるが、大きく分けて3種類の方法がある。

#### (a) 古典的ベイズ

分析者の経験や主観から設定するが、そういった影響を極力避けたい場合は、事前情報を含まない無情報事前分布や拡散事前分布が使われる。

#### (b) 実験ベイズ (Empirical Bayes)

実験ベイズでは、事前分布のハイパ・パラメータを標本理論や頻度論に基づいてデータから推定する。上記の例でいうと、消費者をプールしたデータから共通の \$\theta\$ を最尤法によって点推定し、その値と共分散行列の倍数をそれぞれ \$\mu\_\theta\$ と \$V\_\theta\$ として用いる。倍数は事前分布の強さを調整する値で、Rossi and Allenby (1993) の表記では \$N/\nu\$ (\$N\$ は最尤推定に使われたプールされたデータのサンプル数) に該当する。今回の研究では、キャリブレーション用の選択回数はいくつ回答者で最大でも4回なので、この倍数は事前情報のサンプル数同等が1になるような (\$\nu=1\$) 弱い事前分布に設定した。

この方法は直観的で計算も比較的容易であるが、(1) ハイパ・パラメータの推定誤差を考慮していない、(2) 個人別パラメータを推定するときに事前分布と尤度にデータの重複があるため厳密な意味でベイズのフレームワークから外れている、(3) 推定された事前分布の効果が漸近的にゼロに収束しないなどの問題が残る。

#### (c) 階層ベイズ (Hierarchical Bayes)

実験ベイズの問題点は、ハイパ・パラメータ \$\mu\_\theta\$ と \$V\_\theta\$ をさらにベイズによって推定するという2段階プロセスを使えば克服できる。このようなモデルは階層

ベイズと呼ばれるが、パラメータとハイパ・パラメータの事後分布の推定にマルコフチェーン・モンテカルロ (MCMC) 法という計算量が莫大なシミュレーション手法を用いる必要がある (阿部, 2003)。事前分布はパラメータ \$\theta\$ の被験者間の異質性を描写すると解釈し、個人別パラメータを集計してヒストグラムをプロットすれば、それが事前分布と一致しなければならない。MCMC 法では、個々人の事後分布からパラメータを乱数発生させ、それに基づいて事前分布 (つまり個人間の異質性の分布) を更新するというプロセスを、事後分布が安定するまで数万回ほど繰り返す必要がある。

この研究では、MCMC 法を使わずにパラメータとハイパ・パラメータに矛盾がないようにデータから推定するヒューリスティック階層ベイズという方法を提案する。ここでは、MCMC 法のように個々人の事後分布からパラメータを乱数発生させる代わりに、事後分布の最尤値がその個人のパラメータの点推定値であると解釈し、それに基づいて事前分布を更新するというプロセスを繰り返すのである。具体的には、まず初期値として、上記の実験ベイズを用いて個人別パラメータを点推定する。そして、それらを集計することによって新たな事前分布を構築し、事後分布の点推定をベイズ的に更新する。

ヒューリスティック階層ベイズでは、事後分布のバラツキを無視して、最大値である点推定のみを考慮するのが特徴である。ここでの単純化には、利点と弱点がある。利点は、パラメータとハイパ・パラメータの点推定が安定するまでの繰り返しが5~10回なので、計算量としては実験ベイズの5~10倍ほど、MCMC 法と比較すると1000分の1程度である。弱点は、個人別パラメータのバラツキ (分散) が求められないために、統計的仮説検定ができないことである。今回のジョイント・スペース分析では、個々人の選好パラメータの中心値をマッピングすることが主な関心事なので、バラツキが得られないことより計算量を1/1000に短縮できることの方が、はるかにメリットがあろう。

## 5. 分析結果

### 5.1 知覚マップ：プロダクト・マップとブランド・マップ

まずは因子分析の主成分法を使って、プロダクト・マップを構築した。固有値は14.850, 3.434, 1.674, 0.846と続いたため、スクリープロットによるチェッ

クも含めて、因子数は3が採択された。3因子解の場合、共通性は半分以上の属性で0.9以上、全ての属性変数で0.7以上となった。この結果を2因子解と比較すると、二つの属性変数、low priceとmaintenanceの共通性がそれぞれ0.211, 0.609と低くなり、因子数3の妥当性が確認できる。バリマックス法による直交回転後の因子負荷量が表1に示されている。これから、第1因子は洗練/品質、第2因子はビッグ/タフ/ユーティリティ、第3因子は高い維持費/ランニング・コストと解釈できるであろう。ここでの3因子解のプロダクト・マップに、次節で説明する回答者別理想ベクトルをプロットしたジョイント・スペース・マップが2次元ごとに図2~4に示されている。

同様の手法を使って、ブランド属性評価データからブランド・マップを構築した。固有値は6.827, 1.435, 0.468と続いたため、スクリープロットによるチェックも含めて、因子数は2が採択された。共通性も、convenienceの0.836, country of originの0.732以外は全て0.9を超えた。バリマックス法による直交回転後の因子負荷量が表2に示されている。これから、第1因子はセールス、第2因子はサービスと解釈できる。図5は、この2因子解のブランド・マップに次節で説明する回答者別理想ベクトルをプロットしたジョイント・スペース・マップである。

## 5.2 ジョイント・スペース分析：競合モデルの比較

プロダクトとブランドの座標軸が知覚マップ空間上

に決定されたので、次に選好マップの推定に移る。回答者の6車種のランキングをモデル化し、選好パラメータを個人別に推定して、ジョイント・スペース・マップとしてプロットするのである。ここでは、シンプルなモデルからより精緻なモデルまで、選好データへ

表1 プロダクト・マップの3因子解の因子負荷量

	回転後の成分行列 <sup>a</sup>		
	成分 1	成分 2	成分 3
exterior	.598	.543	.338
cargo space	-.134	.875	.378
body size	.410	.883	.142
interior	.628	.682	.286
comfort	.698	.628	.303
towing	.264	.951	5.377E-02
acceleration	.640	.733	-6.997E-02
nimble	.953	.163	.116
stability	.578	.683	.290
roominess	.610	.752	.117
ride	.806	.434	.240
quiet	.914	.204	-3.728E-02
safe	.836	.389	9.706E-02
low price	-.126	7.949E-02	-.835
fuel economy	5.069E-02	-.526	-.708
maintenance	-6.127E-02	-.291	-.886
technology	.859	.453	.194
attention	.792	.494	.279
reliable	.931	-8.202E-02	-.255
quality	.968	.112	8.221E-04
durability	.703	.581	-.219
luxurious	.859	.368	.302

因子抽出法: 主成分分析  
 回転法: Kaiser の正規化を伴うバリマックス法  
 a. 6回の反復で回転が収束した。

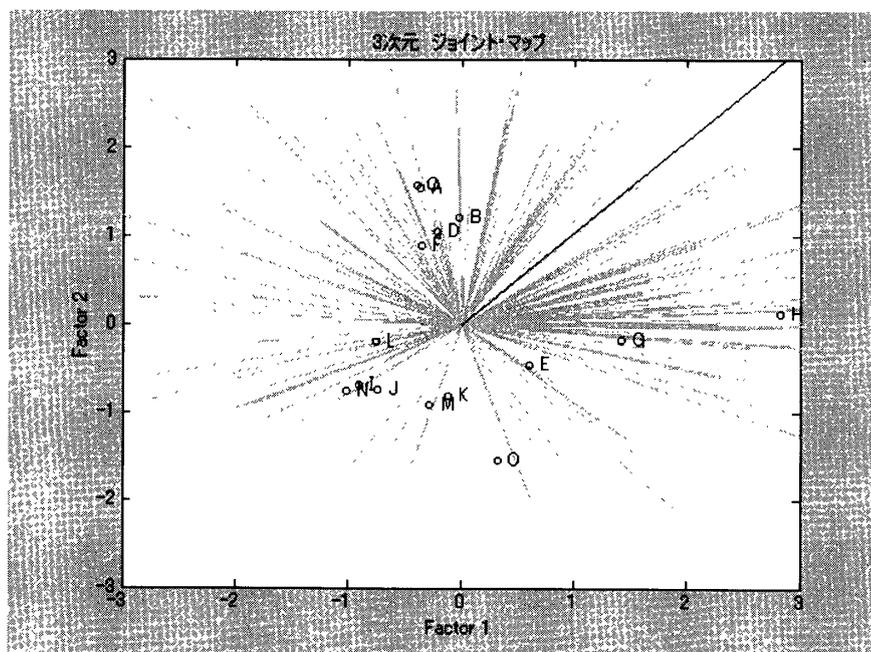


図2 3次元ジョイント・スペース・プロダクト・マップ (因子1 vs. 2)

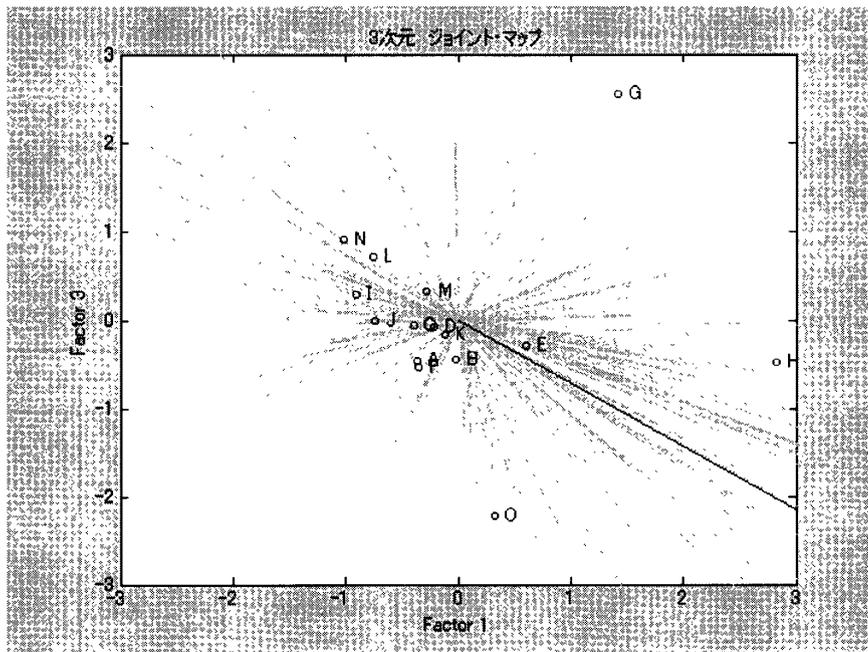


図3 3次元ジョイント・スペース・プロダクト・マップ (因子1 vs. 3)

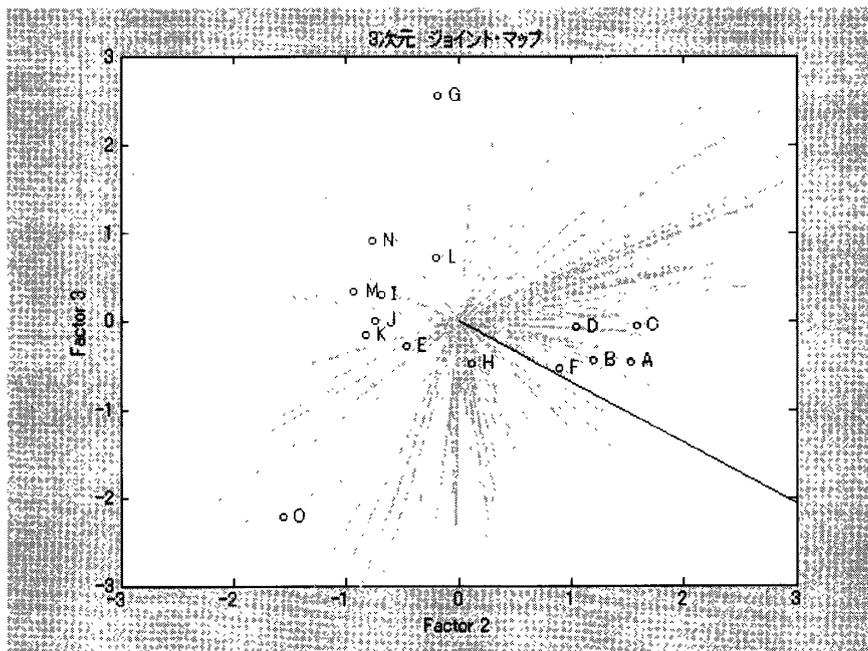


図4 3次元ジョイント・スペース・プロダクト・マップ (因子2 vs. 3)

のフィットと予測に関してどのモデルが一番当てはまりがよいかを、様々な競合モデルを構築して検証する。節4のモデル解説で紹介した順番に、比較したモデル要因を説明しよう。

まず、車種選好の要因として回答者のプロダクト属性評価のみを考慮するのか、それともプロダクト属性とブランド（メーカ）属性評価の両方を考慮するのかである。つまり、プロダクト効用を表した式(2)と式(3)において、プロダクト・マップの座標  $x_{ri}$  のみを組み込むのか、それともブランド・マップの座標  $z_{ri}$  も含

めるのかである。また、前節においてプロダクト・マップは3次元の方が適していることが分かったが、確認の意味で、再度、2次元と3次元によるプロダクト・マップの比較も行う。次に、回答者の選好は理想ベクトルと理想ポイントのどちらのモデルが適しているかを比較する。効用関数は式(2)が理想ベクトル、式(3)が理想ポイントに対応している。最後に、個人別選好パラメータを推定するために実験ベイズとヒューリスティック階層ベイズを比較する。これらの要因をまとめると、

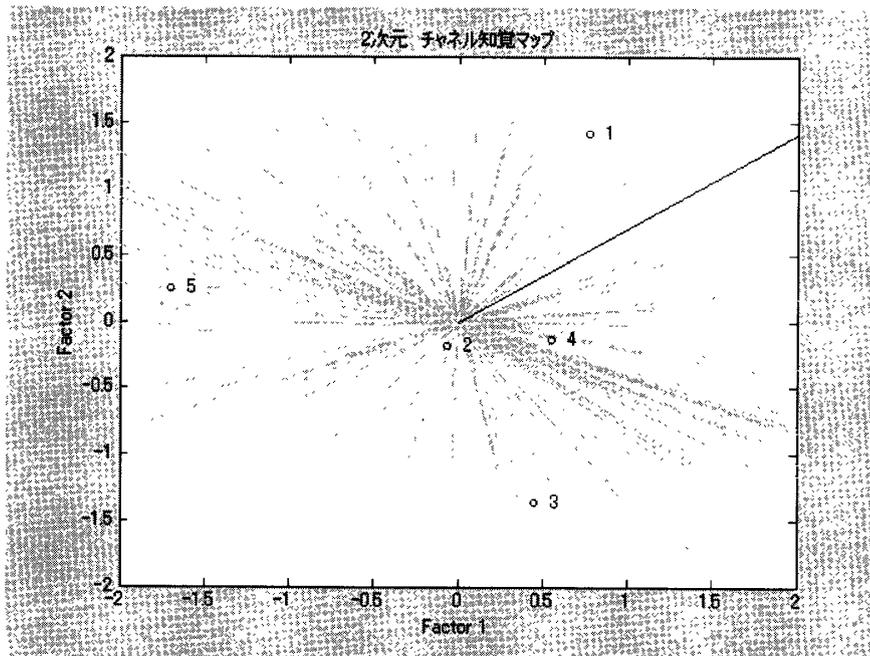


図5 2次元ジョイント・スペース・ブランド・マップ

表2 ブランド・マップの2因子解の因子負荷量

回転後の成分行列\*

	成分	
	1	2
convenient	.853	.328
atmosphere	.795	.564
professional sales	.897	.430
knowledgeable service	.321	.906
sales promotion	.952	.225
brand image	9.901E-02	.973
reliable	.490	.851
inventory	.960	.180
country of origin	.505	.690

因子抽出法: 主成分分析  
 回転法: Kaiser の正規化を伴うバリマックス法  
 a. 3 回の反復で回転が収束した。

- ・2次元 vs. 3次元プロダクト・マップ
- ・プロダクト・マップ vs. プロダクトとブランド・マップ両方
- ・理想ベクトル vs. 理想ポイント
- ・実験ベイズ vs. ヒューリスティック階層ベイズとなる。

上記の要因をコントロールした競合モデルに対して選好データへの当てはまりで評価するのだが、この場合、パラメータ推定に使われたキャリブレーション・データへのフィットと予測力を検証するためのバリデーション・データでの評価の両方において比較することが重要である。各回答者は6車種をランキングしているため、ランクジット・モデルでは、節4.2で説明されたように五つの独立した選択と解釈される。そ

こで、四つの選択データをキャリブレーション・データとして使い、回答者ごとに選好パラメータをベイズ手法で推定して、その最尤値を使って残りの一つの選択予測を行った。どのランキングの選択を予測検証用データにするかという問題を避けるために、五つの選択をそれぞれ予測検証用データとした結果の平均を評価する。データへのフィット基準としては、ベイズ事後分布の最大値に基づく対数尤度値 (loglikelihood), 選択された車種のモデルに対する予測確率の平均 (mean probability of correct choices), ヒットレート (percentage of correct choices) の三つが用いられた。結果の詳細を、表3, 4にまとめた。

・2次元 vs. 3次元プロダクト・マップ

既に因子分析の結果から、プロダクト・マップは2次元より3次元の方が妥当であることは分かったが、これは表3, 4を比較することによって選好データからも確認できる。3次元プロダクト・マップを用いた選好モデルでは、式(2)と式(3)における効用関数の説明変数に  $x_{r3}$  が一つ増えたことで、特にキャリブレーション・データへのフィットが向上している。バリデーション・データへの予測精度にも向上が見られる。

・プロダクト・マップ vs. プロダクトとブランド・マップ両方

理想ベクトル選好モデルに、 $x_{ri}$  だけでなくブランド・マップにおけるブランド (メーカー) の座標位置  $z_{rj}(j=1, \dots, J)$  を加えることによって、フィットと予測が大幅に向上することが、それぞれ表3, 4の1行

表3 2次元プロダクト・マップを用いた競合モデルの評価

2次元プロダクト・マップ		キャリブレーション		バリデーション	
選好モデル	知覚マップ	実験ベイズ	階層ベイズ	実験ベイズ	階層ベイズ
理想ベクトル	プロダクト・マップのみ	-738.1026	-737.8459	-250.2472	-250.4034
		0.4053	0.4055	0.3093	0.3089
		50.9497	50.7821	30.3911	30.3911
理想ベクトル	プロダクトとブランド・マップ両方	-462.2899	-460.5881	-258.2120	-260.8704
		0.5635	0.5648	0.3297	0.3273
		83.0726	83.4358	34.0782	33.7430
理想ポイント	プロダクトとブランド・マップ両方	-390.4274	-386.8841	-264.5689	-271.2975
		0.6101	0.6126	0.3279	0.3258
		89.3855	89.4413	32.6257	31.7318

表4 3次元プロダクト・マップを用いた競合モデルの評価

3次元プロダクト・マップ		キャリブレーション		バリデーション	
選好モデル	知覚マップ	実験ベイズ	階層ベイズ	実験ベイズ	階層ベイズ
理想ベクトル	プロダクト・マップのみ	-664.8735	-661.8342	-257.5128	-258.6267
		0.4429	0.4445	0.3157	0.3156
		61.0615	60.8659	32.1788	32.0670
理想ベクトル	プロダクトとブランド・マップ両方	-424.2505	-419.0870	-261.4995	-264.7551
		0.5918	0.5958	0.3357	0.3350
		85.1117	85.6425	33.1844	33.2961
理想ポイント	プロダクトとブランド・マップ両方	-361.0155	-354.8258	-266.7783	-273.2288
		0.6290	0.6337	0.3281	0.3276
		93.6034	94.3017	31.9553	31.7318

目と2行目を比較することで分かる。

・理想ベクトル vs. 理想ポイント

式(2), (3)を比べると分かるように、理想ポイント・モデルは理想ベクトル・モデルに2乗項を加えた、より自由度の大きいモデルである。当然、キャリブレーション・データへのフィットは向上しているのだが、バリデーション・データでの予測は逆に悪化することが、表3, 4の2行目と3行目を比べると分かる。これは理想ポイント・モデルが選好データに対してオーバ・フィッティングを招いているからである。したがって、今回の選好データに関しては理想ベクトル・モデルが妥当であるといえる。しかし製品カテゴリ、特に日常消費財においては、理想ポイントの方が消費者の選好をより正確にモデル化していることもあるため、この結果からベクトルかポイントかという選好モデルに関する一般的な結論を導くことはできない。

節4.3で説明したように、ヒューリスティック階層ベイズの弱点は、個人別パラメータの事後分布の中心

値(モード)のみが推定され、そのバラツキ(分散)は求められないことである。したがって、回答者一人一人に対して、理想ベクトルとポイントのどちらが妥当であるかを統計的に仮説検定するには、MCMC法による階層ベイズによって、個々人の式(3)にある $\gamma$ のモードだけでなく事後分布自体を計算する必要がある。

・実験ベイズ vs. ヒューリスティック階層ベイズ

データへの当てはまりを実験ベイズとヒューリスティック階層ベイズで比較すると、それほど大きな差は見られない。詳細は評価基準によって違うが、キャリブレーション・データに対してもバリデーション・データに対しても、概ね階層ベイズの方が優れているようである。

5.3 最適モデル

以上の議論を踏まえて、データへのフィットと予測の観点から総合的に判断すると、3次元プロダクト・マップと2次元ブランド・マップ両方の座標を理想ベ

クトルの形で組み込み、回答者別のパラメータをヒューリスティック階層ベイズによって推定したモデルが最適であることが分かった。

図2~4は、3次元プロダクト・マップと選好ベクトルを2次元ずつ、また図5は2次元ブランド・マップと選好ベクトルを、それぞれプロットしたものである。ここでは、ランク5（最も選好度の低い最後の2車種から好まれる車種を選択するデータ）のデータをバリデーション・データとして残し、ランク1~4のデータに基づいてパラメータ推定を行った結果得られたジョイント・スペース・マップが報告されている。それぞれの図には各回答者の理想ベクトルが描かれている他に、1本の濃くて長い直線が179人全員の平均理想ベクトルを表している。

式(2)から分かるように、各対象車種に対する効用値は、マップ上の座標から理想ベクトルに対して垂直に描いたプロジェクションに該当する。製品の効用は理想ベクトルの方角のみに依存するため、ここでの理想ベクトルの長さは回答者の選好がどれだけ説明されたかを表している。ベクトルが長ければ長いほど、キャリブレーション・データに対するフィットが高いことを意味している。

平均理想ベクトルの方角は、第1, 2, 3因子がそれぞれ正, 正, 負なので、洗練/品質, ビッグ/タフ/ユーティリティ, 低い維持費/ランニング・コストに向いており直感的である。回答者別の理想ベクトルは、平均ベクトルから様々な方角に拡散しており、個人によって選好がかなり違うことが視覚的に確認できる。特に因子1, 3では、平均ベクトルと180度逆の方角に選好が向いている回答者も多い。これは、十分なサ

ンプル数を確保するために価格の高いフルサイズと低いスモールサイズ的車種を混合したため、片方のタイプだけをより好む二つのセグメントが存在したことが、一つの理由として挙げられよう。選好の異質性をモデル化する必要性は、表5にある同質選好モデル（理想ベクトルが全ての回答者で同等に制約されているモデル）のフィットが、かなり劣っていることから、数値的に確認できる。

## 6. まとめ

この研究では、ウェブ・アンケートによって得られた北米ピックアップ・トラックに対する車種属性評価、車種選好ランキング、そしてメーカー属性評価から、選好の外的分析によるジョイント・スペース・マップを構築した。まず、回答者で共通のプロダクト（車種）・マップとブランド（メーカー）・マップが推定され、その空間上に回答者別の選好ベクトル/ポイントがプロットされた。利用できる選好情報は、「回答者が親しみのある6車種の選好ランキング」と限られているため、回答者別に選好モデルを推定することは通常の統計手法では困難である。ここでは、ベイズ推定手法を用いることで、この問題に対応した。

分析では、次の異なった要因を組み合わせた競合モデルを推定し、キャリブレーション・データへのフィットとバリデーション・データへの予測精度を検証した。

- ・2次元 vs. 3次元プロダクト・マップ
- ・プロダクト・マップ vs. プロダクトとブランド・マップ両方
- ・理想ベクトル vs. 理想ポイント

表5 同質選好モデルの評価

理想ベクトル		データ	
プロダクト・マップ	知覚マップ	キャリブレーション	バリデーション
2次元	プロダクト・マップのみ	-938.1077	-235.4613
		0.2929	0.2917
		29.3296	25.5866
3次元	プロダクトとブランド・マップ両方	-921.7210	-234.1069
		0.3041	0.2997
		33.9665	31.3966

注 各セルには三つの評価基準、  
 対数尤度値 (loglikelihood)  
 選択された車種のモデルによる予測確率の平均 (mean probability of correct choices)  
 ヒットレート (percentage of correct choices)  
 が示されている。

・実験ベイズ vs. ヒューリスティック階層ベイズ

その結果、一番適した選好モデルは、3次元プロダクト・マップと2次元ブランド・マップの位置を回答者別理想ベクトルの説明変数として組み込み、階層ベイズによって推定したジョイント・スペース・マップであった。

結論としては、次の三つが得られた。第一に、製品空間のみならずブランド空間を含めることによって個人の製品に対する選好データへの（キャリブレーション・データに対する）フィットと（バリデーション・データに対する）予測が大きく向上することが分かった。これは、自動車製品への選好が製品属性のみならずブランドに大きく依存することを意味する。今回の選好モデルはロジット型なので、効用関数が説明変数に対して線型加法型であっても、実際の選択確率は指数をとために積乗型になる。したがって、車種の選好は製品属性とブランド属性の相互作用に影響されていることを暗示している。第二に、この自動車製品の選好データを描写するには、理想ポイントより理想ベクトルが適していることが分かった。第三に、データへのフィットと予測に関しては、この研究で提案されたヒューリスティック階層ベイズは実験ベイズよりも優れていたが、それほど大きな差は見られなかった。前者の計算量が後者の5~10倍であることを考慮すると、計算の簡便な実験ベイズは理論的により厳密な階層ベイズと比較しても、手法的に有望な選択肢となりえるだろう。

今回のような知覚と選好を同時に考慮したジョイント・スペース・マップは新製品開発に特に有効である。また消費者の選好の異質性に関してはセグメントを超えて一人一人に対応しているので、One-to-One Marketing や CRM のツールとして、例えばセールスマンの意思決定支援システムとして、消費者の選好は高いはずなのだが実は知らない車種の推薦などにも活用できる。

今後の研究の発展としては大きく二つの方向が考えられる。第一に、ジョイント・スペース分析では、通常、選好の異質性を回答者別の理想ベクトル/ポイントとしてモデル化するが、知覚の異質性は考慮されていない。知覚の異質性を考慮した手法にはCarroll (1972)のINDSCAL, 同質な知覚セグメントの発見(古川, 1991), 潜在クラスによるセグメント別知覚マップの推定(Andrews and Manrai, 1999; DeSarbo and Wu, 2001)などが存在する。節5で示されたよ

うに、回答者別選好モデルが同質選好モデルと比べて非常に優れていることを考慮すると、回答者別知覚マップの推定は有望な研究課題であろう。

また手法的には、今回提案された実験ベイズとヒューリスティック法による階層ベイズを、MCMC法を使った階層ベイズと比較することが挙げられる。MCMC法では事後分布のモードのみならずバラツキを含めた分布自体を推定するために、回答者レベルでの統計的仮説検定を行えることが利点であるが、計算量はヒューリスティック法にくらべて1000倍近く、実験ベイズに比べては1万倍近くにも増えてしまう。関心の対象が事後分布のモードであれば実験ベイズ、仮説検定であればMCMC法と、適用状況に応じて使い分けることが重要ではないだろうか。

#### 参考文献

- [1] Andrews, R. L. and A. K. Manrai: "MDS Maps for Product Attributes and Market Response: An Application to Scanner Panel Data", *Marketing Science*, 18 (4), 584-604, 1999.
- [2] Beggs, S., S. Cardell, and J. Hausman: "Assessing the Potential Demand for Electric Cars", *Journal of Econometrics*, 16, 1-19, 1981.
- [3] Carroll, J. D.: "Individual Differences and Multidimensional Scaling", Shepard, R. N. (eds.), *Multidimensional Scaling*, New York: Seminar Press, 105-155, 1972.
- [4] Chapman, R. G. and R. Staelin: "Exploiting Rank Ordered Choice Set Data within the Stochastic Utility Model", *Journal of Marketing Research*, 19, 288-301, 1982.
- [5] DeSarbo, W. S. and J. Wu: "The Joint Spatial Representation of Multiple Variable Batteries Collected in Marketing Research", *Journal of Marketing Research*, 38 (2), 244-253, 2001.
- [6] Rossi, P. E. and G. Allenby: "A Bayesian Approach to Estimating Household Parameters", *Journal of Marketing Research*, 30, 171-82, 1993.
- [7] Strauss, D.: "Some Results on Random Utility Models", *Journal of Mathematical Psychology*, 20, 35-52, 1979.
- [8] 阿部誠: 「消費者行動のモデル化: 消費者の異質性」, *オペレーションズ・リサーチ*, 48, 2, 2003.
- [9] 古川一郎: 「知覚構造の異質性の測定と同質なセグメント別知覚マップの推定」, *マーケティング・サイエンス*, 37, 33-47, 1991.