

前節: 大規模ビジネスデータとマーケティング

照井伸彦(東北大学)

1

マーケティングと情報

2種類の電子的情報

(1) POS (Point of Sales: 販売時点) データ: **集計データ**

=>マネージャー:
ブランドの販売動向を正確に瞬時に把握できる。
しかし、顧客を識別できない。

=>会員となる必要がない。
e.x. コンビニ、スーパーでの買い物

(2) FSP (Frequent Shoppers Program) データ: **非集計データ**

=>マネージャー:
a) ブランドの販売動向を正確に瞬時に把握+顧客を識別
b) "誰が何をいつ、どのようなとき、どんな価格で、e.t.c. 買ったか?"
をリアルタイムで把握

=>購買前に入会が必要。
e.x. 航空会社のマイレージプログラム、
ドラッグストア・スーパー・家電量販店などのポイントカードシステム, e.t.c.

=>膨大な市場取引データ: **ビッグデータ**

2



- ・ブランドAの現在の在庫水準は?
 - ・何がいまの売れ筋か?
 - ・どのような現在の環境が販売に貢献しているか?
- (1) 店頭プロモーション
=>今日のプロモーションは有効か?
- (2) 気温や天候
実務の神話:
アイスクリームは30°Cを超えると爆発的に売れる

3

マーケティングと情報

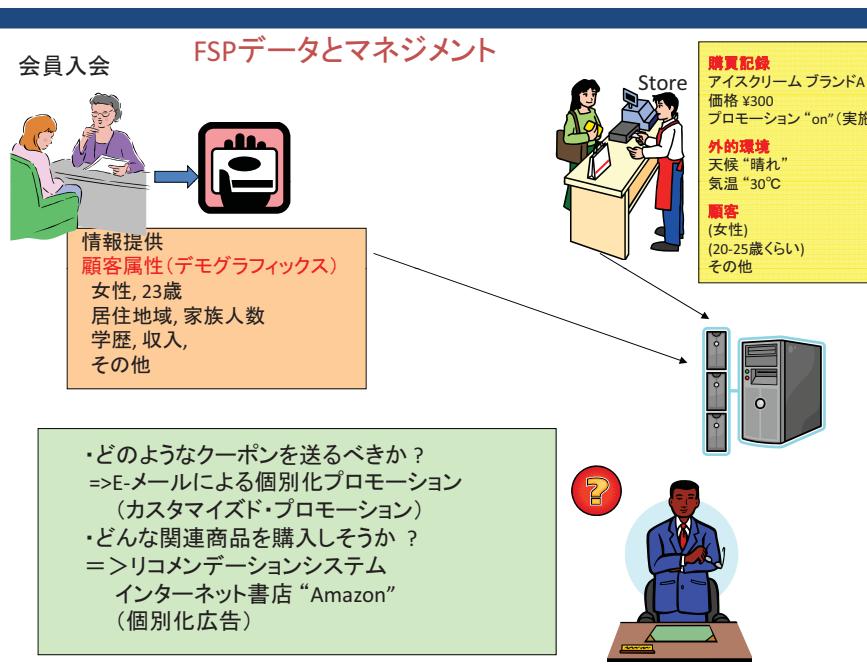
POS (Point of Sales: 販売時点) データ

マネージャー:

ブランドの販売動向を正確に瞬時に把握できる。
しかし、顧客を識別できない。

=>会員となる必要がない。

e.x. コンビニ、スーパーでの買い物



マーケティングと情報

FSP(Frequent Shoppers Program)データ

マネージャー:

a) ブランドの販売動向を正確に瞬時に把握

+

顧客を識別

b) "誰が何をいつ、どのようなとき、どんな価格で、
e.t.c. 買ったか?"

をリアルタイムで把握

=>購買前に入会が必要.

e.x. 航空会社のマイレージプログラム、
ドラッグストア・スーパー・家電量販店などの
ポイントカードシステム, e.t.c.

1. ブランド選択モデル

消費者パネルデータ

- 購買時のマーケティング変数を含むブランド選択データ
- POSレジ・会員カード (FSP : Frequent Shoppers Program)
- 消費者ごとに時系列で収集
- 個人・家計の属性(性別、年齢、職種、年収、etc)

表 消費者パネルデータと属性データ

顧客ID	購買機会	購買	価格			プロモーション		
			A	B	C	A	B	C
1	1	A	77	50	155	1	0	0
1	2	B	90	50	157	0	1	0
1	3	C	90	50	122	0	0	1
1	4	A	90	53	126	0	1	0
2	1	A	68	51	94	0	0	0
2	2	B	90	50	155	1	0	0
3	1	C	70	50	160	1	0	0
3	2	C	90	55	150	0	0	0
3	3	C	80	50	140	0	0	0

顧客ID	性別	年齢	職種	年収
1	男	20	建築	500
2	女	40	自営業	800
3	女	35	主婦	0

1. ブランド選択モデル

多項選択モデル

$$\mathbf{u}_{ht} = \boldsymbol{\alpha} + \mathbf{X}_{ht}\boldsymbol{\beta} + \mathbf{e}_{ht}; \quad \mathbf{e}_{ht} \sim N(\mathbf{0}, \Sigma) \quad (1)$$

$h = 1, \dots, H$: 消費者 $t = 1, \dots, T_h$: 購買機会 m : ブランド数

$\mathbf{u}_{ht} = (u_{1ht}, \dots, u_{mht})'$: 効用ベクトル

\mathbf{x}_{ht} ($m \times k$): マーケティング変数行列(価格・プロモーションなど)

$\boldsymbol{\alpha}$ ($m \times 1$): ブランド切片(ロイヤルティ) $\boldsymbol{\beta}$ ($k \times 1$): 反応係数

- 多項ロジット・プロビットモデル
- 効用が最も高いブランドを選択(効用最大化原理)
- データ全体から消費者共通の推定値 ($\boldsymbol{\alpha}, \boldsymbol{\beta}$)

1. ブランド選択モデル

多項選択モデル

顧客ID	購買機会	購買	価格			プロモーション		
			A	B	C	A	B	C
1	1	A	77	50	155	1	0	0
1	2	B	90	50	157	0	1	0
1	3	C	90	50	122	0	0	1
1	4	A	90	53	126	0	1	0
2	1	A	68	51	94	0	0	0
2	2	B	90	50	155	1	0	0
3	1	C	70	50	160	1	0	0
3	2	C	90	55	150	0	0	0
3	3	C	80	50	140	0	0	0

$$\theta = (\alpha, \beta)'$$

- 全データをプール
- 消費者共通(代表的消費者)の推定値
- マス・マーケティング
- 消費者の異質性を無視

10

1. ブランド選択モデル

消費者の異質性

$$\mathbf{u}_{ht} = \underline{\alpha_h} + \underline{X_{ht}\beta_h} + \mathbf{e}_{ht}; \quad \mathbf{e}_{ht} \sim N(\mathbf{0}, \Sigma) \quad (2)$$

$$\boldsymbol{\theta}_h = \gamma \mathbf{z}_h + \boldsymbol{\nu}_h; \quad \boldsymbol{\nu}_h \sim N(\mathbf{0}, \Delta) \quad (3)$$

\mathbf{z}_h ($c \times 1$): 消費者 h の属性データ

$\boldsymbol{\theta}_h = (\alpha_h, \beta_h)' ((m+k) \times 1)$: パラメータベクトル

γ $((m+k) \times c)$: 回帰係数行列

- 階層ベイズモデル
- 消費者個別の推定値 $(\{\alpha_1, \dots, \alpha_H\}, \{\beta_1, \dots, \beta_H\})$
- 異質性を仮定かつ共通性をモデル化(式(3))
- γ の推定値からの知見 (例: 女性はプロモーション反応率が高い)

11

1. ブランド選択モデル

消費者の異質性

顧客ID	購買機会	購買	価格			プロモーション		
			A	B	C	A	B	C
1	1	A	77	50	155	1	0	0
1	2	B	90	50	157	0	1	0
1	3	C	90	50	122	0	0	1
1	4	A	90	53	126	0	1	0
2	1	A	68	51	94	0	0	0
2	2	B	90	50	155	1	0	0
3	1	C	70	50	160	1	0	0
3	2	C	90	55	150	0	0	0
3	3	C	80	50	140	0	0	0

$$\begin{aligned} \theta_1 &= (\alpha_1, \beta_1)' \\ \theta_2 &= (\alpha_2, \beta_2)' \\ \theta_3 &= (\alpha_3, \beta_3)' \end{aligned}$$

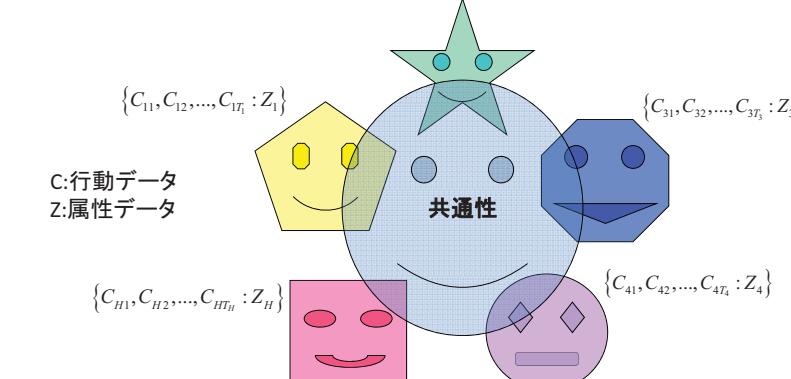
顧客ID	性別	年齢	階級	年収
1	男	20	建築	500
2	女	40	自営業	800
3	女	35	主婦	0

- 消費者個別の推定値
- ターゲット・マーケティング
- ロイヤルティや反応係数が時間不变とは限らない
→ 購買・消費経験により変化すると考えるのが一般的

12

階層ベイズによる異質性モデリング

$$\{C_{21}, C_{22}, \dots, C_{2T_2} : Z_2\}$$



マーケティングのデータ:

- 多くの意思決定主体に関する情報 (パネル, サーベイ)
- 各主体のデータが少ない
- 全体で集計
- 各主体の異質性を無視

→ 各主体間の情報をプールするモデル
例えはランダム効果モデル

$$\beta_h = \bar{\beta} + \varepsilon_h, \quad \beta_h = Z_h \theta + \varepsilon_h,$$

・典型的構造

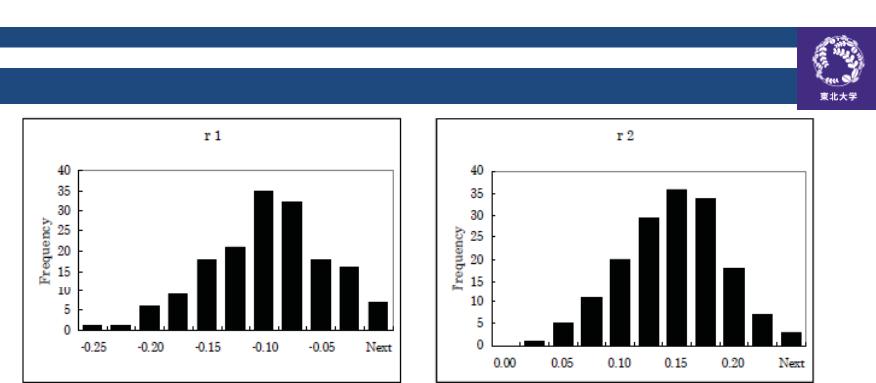
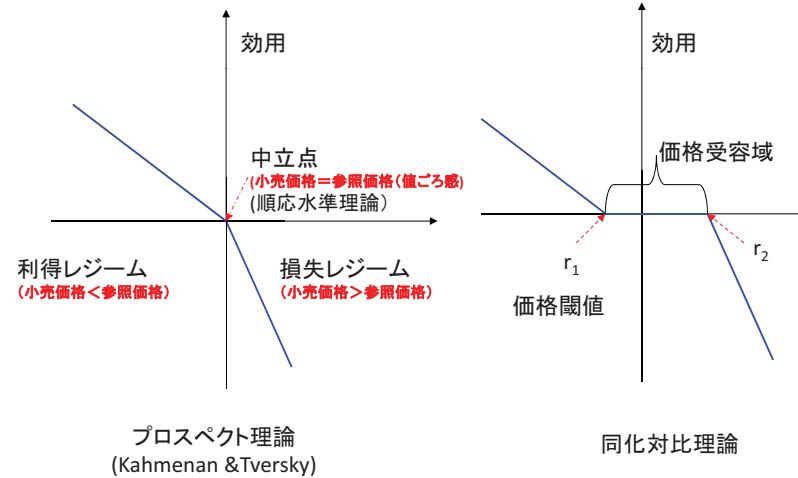
- (1) 主体内行動 → 尤度関数
- (2) 主体間行動 → 異質性の分布
- (3) 意思決定モデル

(1) 価格閾値の推定

Marketing Science (2006): Terui and Dahana



価格閾値の個別推定



- (1) 25%以上ディスカウントしないと反応しない人もいれば
0.5%でも反応する顧客がいる
 - (2) 20%以上値上げしても拒否しない人もいれば
0.5%でも拒否する顧客がいる
- => 個別の反応度に応じて受容される価格帯が異なる

15

(2) 価格カスタマイゼーション

Journal of Interactive Marketing(2006): Terui and Dahana



異質価格閾値

=> 各消費者の価格に鈍感な領域

ディスカウント

下限の価格閾値を越えないディスカウント “ $r_1 > P - RP > 0$ ” => ロス
(消費者は反応しないため)

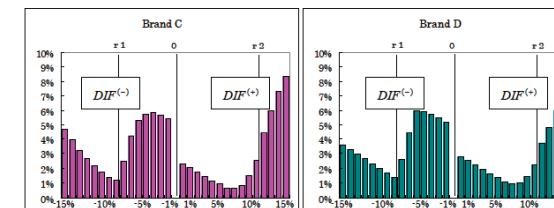
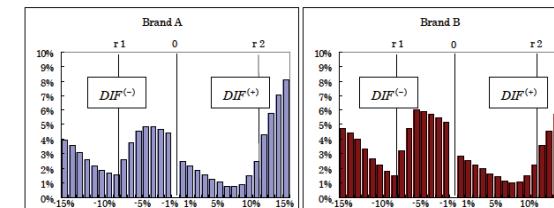
値上げ

上限の価格閾値を越えない値上げ “ $0 < P - RP < r_2$ ” => 利益
(消費者は値上げを感じない)

異質価格閾値の情報はつぎの2つの点で貢献

1. 下限の価格閾値を越えないディスカウントによるロスを最小化
2. 上限の価格閾値を越えない値上げによる利益を最大化

非カスタマイゼーション価格 (flat pricing)との比較



● 正の棒グラフ
=> カスタマイズ価格がより優位

● 異なるマージンは異なる形を生む
=> しかし結論は同じ

16

17

ブランドに対する”飽き”の動的変化 の個人別測定と製品・ 品揃え戦略

照井伸彦(東北大学)

18

概要

- 消費者の効用関数を用いた複数離散モデルをベースとして、ブランドに対する”飽き”を動的因子モデルによりブランド群に付随する因子負荷量と個人に付随する因子スコアに分解する。
- また”飽き”を各ブランドの成分データに回帰することにより、飽きさせる成分、飽きさせない成分、中立な成分を検出し、ブランドの改良・開発戦略に向けた成分の特徴づけを行う。
- さらに個人別に推定された因子スコアの動的変化から”飽き”的状態を捉え、補償価値にもとづく価値評価を通じた品揃え戦略を提示する。

20

Dynamic Brand Satiation

長谷川 翔平*

照井 伸彦*

Greg M. Allenby**

* 東北大学大学院経済学研究科

** Fisher College of Business, Ohio State University

19

1. ブランド選択モデル

多項選択モデル

$$\boldsymbol{u}_{ht} = \boldsymbol{\alpha} + \boldsymbol{X}_{ht}\boldsymbol{\beta} + \boldsymbol{e}_{ht}; \quad \boldsymbol{e}_{ht} \sim N(\mathbf{0}, \boldsymbol{\Sigma}) \quad (1)$$

$h = 1, \dots, H$: 消費者 $t = 1, \dots, T_h$: 購買機会 m : ブランド数

$\boldsymbol{u}_{ht} = (u_{1ht}, \dots, u_{mht})'$: 効用ベクトル

\boldsymbol{x}_{ht} ($m \times k$): マーケティング変数行列(価格・プロモーションなど)

$\boldsymbol{\alpha}$ ($m \times 1$): ブランド切片(ロイヤルティ) $\boldsymbol{\beta}$ ($k \times 1$): 反応係数

- 多項ロジット・プロビットモデル
- 効用が最も高いブランドを選択(効用最大化原理)
- データ全体から消費者共通の推定値($\boldsymbol{\alpha}, \boldsymbol{\beta}$)

22

1. ブランド選択モデル

時間の異質性(ダイナミクス)

$$\boldsymbol{u}_{ht} = \underline{\alpha}_{ht} + \boldsymbol{X}_{ht}\boldsymbol{\beta}_h + \boldsymbol{e}_{ht}; \quad \boldsymbol{e}_{ht} \sim N(\mathbf{0}, \boldsymbol{\Sigma}) \quad (4)$$

$$\alpha_{ht} = \alpha_{ht-1} + \boldsymbol{w}_{ht}; \quad \boldsymbol{w}_{ht} \sim N(\mathbf{0}, \boldsymbol{\Lambda}) \quad (5)$$

- 線形ガウス状態空間モデル(DLM : Dynamic Linear Model)
- 消費者・時間別の推定値($\{\alpha_{11}, \dots, \alpha_{1T_h}\}, \boldsymbol{\beta}_1, \dots, \{\alpha_{H1}, \dots, \alpha_{HT_h}\}, \boldsymbol{\beta}_H$)
- パラメータの時間的推移

23

1. ブランド選択モデル

時間の異質性(ダイナミクス)

顧客ID	購買機会	購買	価格			プロモーション		
			A	B	C	A	B	C
1	1	A	77	50	155	1	0	0
1	2	B	90	50	157	0	1	0
1	3	C	90	50	122	0	0	1
1	4	A	90	53	126	0	1	0
2	1	A	68	51	94	0	0	0
2	2	B	90	50	155	1	0	0
3	1	C	70	50	160	1	0	0
3	2	C	90	55	150	0	0	0
3	3	C	80	50	140	0	0	0

- 消費者・時間別の推定値
- ブランドロイヤルティの推移
- 次期の購買予測
- 原因の考察・モデル化

24

1. ブランド選択モデル

多項選択モデルの限界

- 複数ブランドの同時購買
- 購買個数
- ⇒ 下表 (b) のデータには対応できない

表 複数離散選択データ

(a) 離散選択データ

購買機会	ブランド		
	A	B	C
1	1	0	0
2	1	0	0
3	0	1	0
4	0	0	1
5	0	1	0

(b) 複数離散選択データ

購買機会	ブランド		
	A	B	C
1	2	0	1
2	1	1	0
3	0	1	0
4	0	0	2
5	0	3	2

25

1. ブランド選択モデル

複数同時離散選択モデル (Kim et al. 2002)

$$\begin{cases} \max \quad U(\boldsymbol{x}_{ht}) = \sum_{j=1}^m \psi_{jh}(x_{jht} + 1)^{\alpha_j} & \text{: 効用関数} \\ s.t. \quad p'_{ht}\boldsymbol{x}_{ht} \leq E_{ht} & \text{: 予算制約式} \end{cases} \quad (6)$$

$\boldsymbol{x}_{ht} = (x_{1ht}, \dots, x_{mht})'$: 需要(購買)量ベクトル

ψ_{jh} : Baselineパラメータ → ロイヤルティ

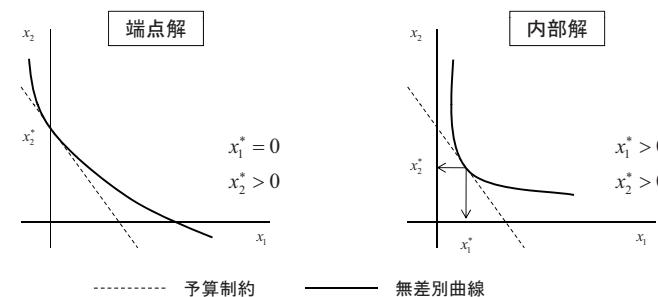
α_j : Satiationパラメータ → 飽きを表すパラメータ

⇒ 複数ブランド購買・複数個購買を端点解と内部解で表現

26

1. ブランド選択モデル

図1 端点解と内部解(2ブランドの場合)



- 購買は無差別曲線と予算制約式の接点で決定
 - 予算制約式のもとで効用が最大となる点
- 無差別曲線はSatiationパラメータ α_j の数値で変化

27

2. 目的

消費者のブランドへの選好は様々な理由で変化

- 価格・プロモーション
- 新製品の参入
- 消費者心理の変化
- 購買・消費経験
- ブランドまたは属性に対する飽き

ブランドに対する「飽き(飽和)」を考慮した研究

Kim et al.(2002,2007), Bhat(2005), Satomura et al.(2011a),etc.

28

2. 目的

本研究の特徴

- 複数離散選択データ(Multiple-Discreteness Data)
 - 同カテゴリ内で複数ブランドの購買
 - 消費者の購買を単独ブランド購買(端点解)と複数ブランド購買(内部解)をモデルで表現
 - より広い範囲のデータを利用可能

離散選択データ

購買機会	ブランド		
	A	B	C
1	1	0	0
2	1	0	0
3	0	1	0
4	0	0	1
5	0	1	0

複数離散選択データ

購買機会	ブランド		
	A	B	C
1	2	0	1
2	1	1	0
3	0	1	0
4	0	0	2
5	0	3	2

29

2. 目的

本研究の特徴

- 属性データの利用
 - 商品は多数の属性から構成(サイズ、フレーバー、etc.)
 - 属性の購買に与える影響
- 飽きを表すパラメータに因子構造
 - 多次元パラメータの縮約
 - 飽きを属性固有と消費者固有の効果へ分解
- ダイナミクス
 - 購買・消費経験による飽きの動的変化
 - 動的因子モデルとトレンドモデル

30

3. 提案モデル

効用関数 (based on Bhat 2007 and Satomura et al. 2011b)

$$\begin{cases} \max U(x_{ht}, z_{ht}) = \sum_{j=1}^m \frac{\psi_{jht}}{\gamma_{jht}} \ln(\gamma_{jht} x_{jht} + 1) + \ln z_{ht} \\ s.t. \quad p'_{ht} x_{ht} + z_{ht} \leq E_{ht} \quad x_{jht} \geq 0, \quad z_{ht} > 0 \end{cases} \quad (7)$$

$h = 1, \dots, H$: 消費者 $t = 1, \dots, T_h$: 購買機会 m : ブランド数

・データ

$x_{ht} = (x_{1ht}, \dots, x_{mht})'$: 需要(購買)量ベクトル

$p_{ht} = (p_{1ht}, \dots, p_{mht})'$: 価格ベクトル E_{ht} : 予算

z_{ht} : 外部財(分析対象のカテゴリ x_{ht} と同時に購買されたその他の商品. $p_z = 1$)

・パラメータ

ψ_{jht} : Baselineパラメータ ($\psi_{jh} > 0$) → ロイヤルティ

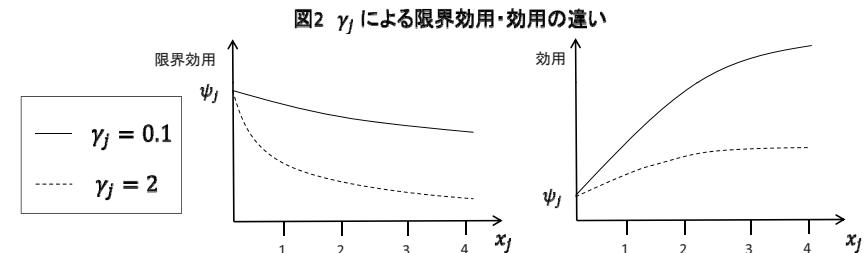
γ_{jht} : Satiationパラメータ ($\gamma_{jht} > 0$) → 飽きを表すパラメータ

31

3. 提案モデル

限界効用

$$\frac{\partial U(x, z)}{\partial x_j} = \frac{\psi_j}{\gamma_j x_j + 1} \quad (8)$$



- $x_j = 0$ のとき、限界効用 = $\psi_j \Rightarrow$ ブランドロイヤルティ
- $\gamma_j = 0.1$: 限界効用遞減が小さい = ブランド j に飽きていない
⇒ 予算内で x_j を単独で購買して効用を最大化 → 単独購買(端点解)
- $\gamma_j = 2$: 限界効用遞減が大きい = ブランド j に飽きている
⇒ 予算内で x_j 以外を購買して効用を最大化 → 複数購買(内部解)
- ψ_j : 大きいほど高ロイヤルティ、 γ_j : 大きいほど飽きやすい

32

3. 提案モデル

確率モデル

$$\psi_{jht} = \exp(\psi_{jht}^* + \varepsilon_{jht}) \quad \varepsilon_{jht} \sim N(0, 1) \quad (9)$$

- Baselineパラメータに誤差項
- $\psi_{jht} > 0$ の制約があるが、 ψ_{jht}^* は制約なしのパラメータ

属性のモデル化

$$\psi_{jht}^* = \mathbf{c}_j' \boldsymbol{\beta}_{ht} \quad (10)$$

$$\gamma_{jht}^* = \mathbf{c}_j' \boldsymbol{\alpha}_{ht} \quad (11)$$

$$\psi_{jht} = \exp(\psi_{jht}^* + \varepsilon_{jht}) \quad \gamma_{jht} = \exp(\gamma_{jht}^*)$$

\mathbf{c}_j ($p \times 1$): ブランド j を構成する p 個の属性データベクトル

$\boldsymbol{\beta}_{ht}, \boldsymbol{\alpha}_{ht}$ ($p \times 1$): BaselineとSatiationのpart-worth(部分効用)

33

3. 提案モデル

ダイナミクスのモデル化

1. トレンドモデル(確定的トレンド)

$$\boldsymbol{\beta}_{ht} = \begin{cases} \boldsymbol{\theta}_{h0} + \boldsymbol{\theta}_{h1}t + \boldsymbol{e}_{ht} & : \text{Linear} \\ \boldsymbol{\theta}_{h0} + \boldsymbol{\theta}_{h1}t + \boldsymbol{\theta}_{h2}t^2 + \boldsymbol{e}_{ht} & : \text{Squard} \\ \boldsymbol{\theta}_{h0} + \boldsymbol{\theta}_{h1} \ln t + \boldsymbol{e}_{ht} & : \text{Log} \end{cases} \quad \boldsymbol{e}_{ht} \sim N(0, V) \quad (12)$$

$$\text{消費者の異質性: } \boldsymbol{\theta}_{hi} \sim N(\bar{\boldsymbol{\theta}}_i, V_{\boldsymbol{\theta}_i}) \quad i = 0, 1, 2 \quad (13)$$

2. 動的因素モデル(確率的トレンド)

$$\boldsymbol{\alpha}_{ht} = \boldsymbol{a}f_{ht} + \boldsymbol{\delta}_{ht}; \quad \boldsymbol{\delta}_{ht} \sim N(0, \boldsymbol{\Sigma} = \text{diag}\{\sigma_1^2, \dots, \sigma_p^2\}) \quad (14)$$

$$f_{ht} = f_{ht-1} + v_{ht}; \quad v_{ht} \sim N(0, 1) \quad (15)$$

\boldsymbol{a} : 因子負荷量ベクトル(時間不変・消費者共通) = 属性固有のSatiation

f_{ht} : 因子スコア(時変・消費者個別) = 消費者固有のSatiation

34

3. 提案モデル

識別性

$$\mathbf{a} = \begin{pmatrix} 1 \\ a_{21} \\ a_{31} \\ \vdots \\ a_{p1} \end{pmatrix} \quad \text{or} \quad \mathbf{a} = \begin{pmatrix} 1 & 0 \\ a_{21} & 1 \\ a_{31} & a_{32} \\ \vdots & \vdots \\ a_{p1} & a_{p2} \end{pmatrix} \quad (16)$$

Geweke and Zhou(1996)

比較モデル

Baseline モデル

$$\begin{cases} \text{静的モデル} \\ \text{トレンドモデル} \\ \text{動的因子モデル} \end{cases}$$

Satiation モデル

$$\times \begin{cases} \text{静的モデル} \\ \text{トレンドモデル} \\ \text{動的因子モデル} \end{cases}$$

⇒ 2因子モデルを含めた合計14モデルで比較

35

3. 提案モデル

パラメータ

1. $\{\beta_{ht}\}$: Baseline パラメータ 式(10) (11)

2. $\{\alpha_{ht}\}$: Satiation パラメータ

3. θ_{hi}, V : トレンドモデル

4. $\hat{\theta}_i, V_{\theta_i}$: 階層モデル

5. $\mathbf{a}, \{f_{ht}\}, \Sigma$: 動的因子モデル 式(14) (15)

- 1. と 2. が条件付きになれば以降は回帰モデル
- 推定はMCMCで行う
- 状態変数 $\{f_{ht}\}$ の推定はForward Filtering and Backward Sampling (Carter and Kohn, 1994) を用いる

36

3. 提案モデル

推定: 尤度導出

- β, α の尤度 (以下の式中で ψ_j, γ_j は β, α の関数。式(10)・(11))

- 尤度は予算制約のもとで効用関数を最大化することで導出

・ラグランジュ関数

$$Q = U(x, z) - \lambda(p'x + z - E) \quad (17)$$

・キューン=タッカー条件

$$\frac{\partial Q}{\partial x_j} = \frac{\psi_j}{\gamma_j x_j + 1} - \lambda p_j = 0 \quad \text{if } x_j > 0 \quad : \text{購買あり} \quad (18)$$

$$\frac{\partial Q}{\partial x_j} = \frac{\psi_j}{\gamma_j x_j + 1} - \lambda p_j < 0 \quad \text{if } x_j = 0 \quad : \text{購買なし} \quad (19)$$

$$\frac{\partial Q}{\partial z} = \frac{1}{z} - \lambda = 0 \quad \text{always } z > 0 \Leftrightarrow \lambda = \frac{1}{z} = \frac{1}{E - p'x} \quad (20)$$

式(20)および確率項 $\psi_j = \exp(\psi_j^* + \varepsilon_j)$ より式(18)・(19)を整理

37

3. 提案モデル

$$\varepsilon_j = -\psi_j^* + \ln(\gamma_j x_j + 1) + \ln\left(\frac{p_j}{E - p'x}\right) \quad \text{if } x_j > 0 \quad (21)$$

$$\varepsilon_j < -\psi_j^* + \ln(\gamma_j x_j + 1) + \ln\left(\frac{p_j}{E - p'x}\right) \quad \text{if } x_j = 0 \quad (22)$$

ここで $g_j = -\psi_j^* + \ln(\gamma_j x_j + 1) + \ln\left(\frac{p_j}{E - p'x}\right)$ と置くと、尤度は以下で表される

$$L(x, z | \psi, \gamma) = \frac{\phi(g_1, \dots, g_{n_1}) |J| \times \int_{-\infty}^{g_{n_1+1}} \dots \int_{-\infty}^{g_m} \phi(\varepsilon_{n_1+1}, \dots, \varepsilon_m) d\varepsilon_{n_1+1} \dots d\varepsilon_m}{\underbrace{\quad}_{\text{式(21) : 購買ありの尤度}} \quad \underbrace{\quad}_{\text{式(22) : 購買なしの尤度}}} \quad (23)$$

$\phi(\cdot)$: 標準正規分布のPDF ($\varepsilon_j \sim N(0, 1)$ より)

$|J|$: ヤコビアン ($\varepsilon_j \rightarrow x_j$)

38

4. 実証分析

スナック菓子の実験データ (Kim et al. 2007)

- (1) 被験者へ2ドルの予算を支給
- (2) 全8種・価格0.33ドルのスナック菓子を購買してもらう
 - ・スナックは12の属性から構成
 - ・被験者は予算内でスナックを購買(6個=1.98ドルまで購買可)
 - ・予算を全て使い切らなくてもよい
- (3) 予算2ドル内で使わなかった分は被験者へ支給(外部財)
- (4) 被験者101人に対し(1)~(3)を7週間行いデータを収集

被験者: $H = 101$	購買機会: $T_h = 3 \sim 7$
ブランド数: $m = 8$	属性数: $p = 12$

39

4. 実証分析

表3 モデル比較

Model (Satiation, Baseline)		Log ML	DIC
No Dynamic	(1) (Homo, Hetero)	-5090.4	10711
	(2) (Hetero, Hetero)	-5075.5	11109
	(3) (Factor, Hetero)	-5060.4	11024
Trend	(4) (L.Trend, Hetero)	-5076.2	11440
	(5) (Sq.Trend, Hetero)	-5169.3	11591
	(6) (Log.Trend, Hetero)	-5033.5	11438
Dyn. Factor	(7) (Dyn.Factor, Hetero)	-4847.2	10975
	(8) (Dyn.Factor, L.Trend)	-2581.8	7521
	(9) (Dyn.Factor, Sq.Trend)	-2430.0	7136
No Characteristics	(10) (Dyn.Factor, Log.Trend)	-2656.4	7747
	(11) (Dyn.Factor, Dyn.Factor)	-3095.1	9122
	(12) Baseline (Dyn.Factor, Sq.Trend)	-2773.1	7788
2 Factors	(13) Both (Dyn.Factor, Sq.Trend)	-2695.5	7266
	(14) (Dyn.Factor, Sq.Trend)	-2433.2	7152

Log ML: モデルの対数尤度 DIC: MCMCにおけるAIC指標

支持されたモデル

Satiation : 動的因子モデル $\rightarrow \alpha_{ht} = \alpha f_{ht} + \delta_{ht}$

Baseline : 二乗トレンド $\rightarrow \beta_{ht} = \theta_{h0} + \theta_{h1}t + \theta_{h2}t^2 + e_{ht}$

以下では、このモデルの推定結果による考察を行う

41

4. 実証分析

表1 ブランド・属性データ

	c1	c2	c3	c4	c5	c6	c7	c8	c9	c10	c11	c12
A: Nacho Cheesier 3D	1.00	0.00	0.00	0.00	0.00	0.00	4.00	1.50	4.00	2.00	0.00	1.75
B: Spicier Nacho	0.00	0.00	0.00	0.00	0.00	1.00	3.00	0.67	3.83	4.25	2.00	0.00
C: Cooler Ranch 3D	1.00	0.00	3.17	0.00	0.00	0.00	0.00	1.33	4.17	4.00	0.00	0.00
D: Baja Picante	0.00	0.00	0.00	0.00	0.00	1.33	0.88	3.67	3.33	5.50	2.25	0.00
E: Jalapeno Cheddar 3D	1.00	0.00	0.00	0.50	0.00	1.83	4.25	0.00	4.17	5.00	1.00	0.00
F: Nacho Cheesier	0.00	0.00	0.00	0.00	0.00	0.00	4.00	1.50	4.00	2.00	0.00	1.75
G: Cooler Ranch	0.00	0.00	3.17	0.00	0.00	0.00	0.00	1.33	4.17	4.00	0.00	0.00
H: Sonic Sour Cream	0.00	2.17	0.67	0.00	0.50	0.00	3.38	0.00	3.83	0.00	0.00	0.00

スナックの形状、ハーブ・チーズ・スパイスの含有量など

表2 購買データ統計

	Purchase incidence	Total purchase quantity	Corner solution	Interior solution
A: Nacho Cheesier 3D	168	224	–	168 (1.00)
B: Spicier Nacho	177	262	4 (0.02)	173 (0.98)
C: Cooler Ranch 3D	188	231	–	188 (1.00)
D: Baja Picante	180	235	–	180 (1.00)
E: Jalapeno Cheddar 3D	190	295	2 (0.01)	188 (0.99)
F: Nacho Cheesier	244	446	6 (0.02)	238 (0.98)
G: Cooler Ranch	235	338	–	235 (1.00)
H: Sonic Sour Cream	218	277	–	218 (1.00)
Total	1600	2308	12 (0.01)	1588 (0.99)

括弧内はパーセンテージ

40

4. 実証分析

表4 (a) ブランドレベルパラメータ

	$E[\gamma_{jht}^*] = E[c\alpha_{jht}]$	$E[c\alpha]$	$E[y_{jht}^*] = E[c\beta_{jht}]$	mean	median
	mean	median	mean		
A: Nacho Cheesier 3D	0.086	0.114	0.620	-5.415	-2.925
B: Spicier Nacho	0.308	0.279	0.025	-7.475	-3.085
C: Cooler Ranch 3D	0.117	0.161	0.537	-6.354	-2.790
D: Baja Picante	0.352	0.318	-0.022	-9.796	-3.625
E: Jalapeno Cheddar 3D	0.334	0.308	0.105	-9.265	-3.804
F: Nacho Cheesier	0.360	0.368	-0.380	-4.188	-1.050
G: Cooler Ranch	0.390	0.370	-0.463	-5.127	-1.027
H: Sonic Sour Cream	0.264	0.243	-0.156	-5.636	-2.484

数値は消費者・時間全ての平均・中央値

- 1列目: ブランドレベルでのSatiation γ_{jht}^* はAが最小、Gが最大
 - Aが飽きにくく、Gが飽きやすい
- 2列目: 時変の消費者固有部分を除いたSatiation ($\gamma_{jht}^* = c_j' \alpha_{ht} = [c_j' \alpha] f_{ht}$)
 - 1列目とは逆の関係
 - ⇒ 因子の意味を “excitement” (or “anti-satiation”) と定義
- 3列目: Baseline ψ_{jht}^* についてはシェア通り(表2)

42

4. 実証分析

表4 (b) 属性レベルパラメータ

Characteristics	$E[\alpha_{bi}]$	α	$\Sigma = \text{diag}\{\sigma_1^2, \dots, \sigma_k^2\}$	$E[\beta_{bi}]$
c1	-0.273	1.000	-	0.187 (0.057)
c2	0.060	-0.151 (0.046)	0.149 (0.033)	-1.007
c3	-0.197	0.696 (0.090)	0.069 (0.012)	0.329
c4	0.062	-0.157 (0.101)	0.311 (0.104)	0.088
c5	0.350	-1.202 (0.073)	0.472 (0.217)	-0.887
c6	0.064	-0.212 (0.124)	0.152 (0.053)	-0.506
c7	-0.152	0.587 (0.039)	0.046 (0.007)	-0.221
c8	-0.111	0.441 (0.038)	0.079 (0.016)	-0.689
c9	0.157	-0.438 (0.070)	0.040 (0.005)	-0.648
c10	0.126	-0.357 (0.040)	0.041 (0.006)	-0.638
c11	-0.183	0.688 (0.061)	0.112 (0.027)	-0.325
c12	0.143	-0.527 (0.087)	0.116 (0.031)	0.913

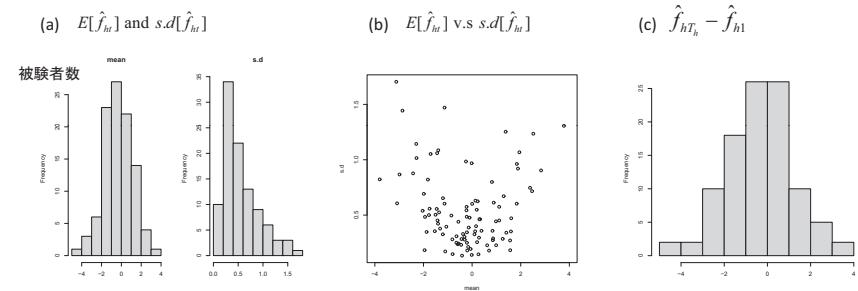
数値は消費者・時間全ての平均値

- 1列目: 飽きやすい属性(c5,9,12,10)、飽きにくい属性(c1,3,11,7,8)
- 2列目: 属性固有のSatiation(因子負荷量)
- 4列目: Baselineパラメータのpart worth
- 各属性の特徴
 - c3=(Baseline: 中, Satiation: 低)
 - c12=(Baseline: 高, Satiation: 高)

43

4. 実証分析

図3 因子スコアの消費者間分布 (\hat{f}_{ht} : excitement スコアの事後平均)



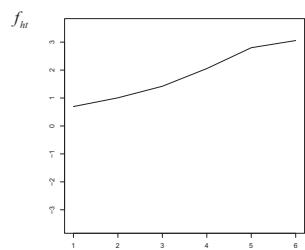
- f_{ht} (excitement スコア) は大きいほど飽きていない (因子の意味より)
- $E[\hat{f}_{ht}], s.d.[\hat{f}_{ht}]$ は事後平均時系列 $\{\hat{f}_{h1}, \dots, \hat{f}_{hT_h}\}$ の平均・標準偏差
- (a)・(b) : 高い異質性
- (b) : 多くの被験者は f_{ht} の変化が少ない (標準偏差が小さい)
- (c) : 1回目と最後の因子スコアの差 ($\hat{f}_{hT_h} - \hat{f}_{h1}$)
 - 約60%が負の領域 ⇒ 被験者は購買機会を通じて Satiation を増加させている

44

4. 実証分析

図4 被験者レベルのexcitement スコア時系列

(a) ID#99 (increasing trend)

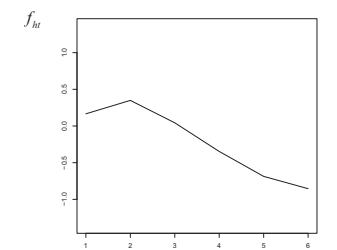


- f_{ht} が上昇 = 飽きていない
→ 単独購買
(購買数はBaselineの影響もある)

Purchase Occasion	f_h	Purchase Record								# of purchase
		A	B	C	D	E	F	G	H	
1	0.695	1	0	1	0	1	0	1	1	5
2	1.007	3	0	1	0	2	0	0	0	6
3	1.421	0	0	1	0	0	0	1	0	2
4	2.054	0	0	0	0	1	0	0	0	1
5	2.800	0	0	0	0	1	0	0	0	1
6	3.057	0	0	0	0	1	0	0	0	1

図4 被験者レベルのexcitement スコア時系列

(b) ID#26 (decreasing trend)



- f_{ht} が減少 = 飽いている
→ 複数購買

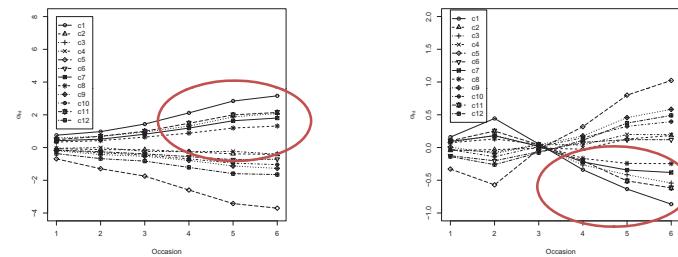
Purchase Occasion	f_h	Purchase Record								# of purchase
		A	B	C	D	E	F	G	H	
1	0.166	0	0	0	0	0	1	1	0	2
2	0.349	0	0	0	0	0	0	1	0	1
3	0.044	0	0	0	0	0	1	1	0	2
4	-0.347	0	0	0	0	0	2	2	0	4
5	-0.687	1	0	1	1	0	1	1	1	6
6	-0.854	1	0	1	0	1	1	1	1	6

45

46

Discussion : Satiation Dynamics

Figure 3 Part-Worth Dynamics (α_{kht} , $k=1, \dots, 12$)
 (a) ID#99 (b) ID#26



- Dynamic part-worth for each of the attribute
- (a) ID#99: Attributes c2, 5, 6, 9, 10, 11 (spice, pepper) have upward trend
=> Spice attributes increase satiation at a faster than others
- (b) ID#26: Attributes c1, 3, 7, 8, 12 (cheese, herb) lead to greater satiation
=> Spice attributes have downward trend, not increasing satiation

47

4. 実証分析

補償価値 (Compensating Value : CV)

- 特定のブランドを削除したとき、削除以前の効用水準を保つために必要な予算補填 (Kim et al. 2002)
- 金額ベースでの評価が可能
- 品揃えや製品ラインについての考察

全ブランド存在時の効用

$$V_{ht}(p_{ht}, E_{ht}) = \max U(x_{ht} | \hat{\psi}_{ht}, \hat{\gamma}_{ht}) \\ \text{s.t. } p_{ht}x_{ht} + z_{ht} = E_{ht}$$

CVの計算

$$\rightarrow V_{ht}^{(j)}(p_{ht}, E_{ht} + CV_{ht}^{(j)}) = V_{ht}(p_{ht}, E_{ht})$$

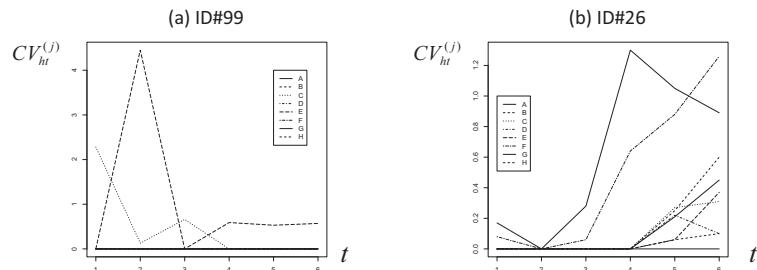
ブランド j を削除したときの効用

$$V_{ht}^{(j)}(p_{ht}, E_{ht}) = \max U(x_{ht} | \hat{\psi}_{ht}, \hat{\gamma}_{ht}) \\ \text{s.t. } p_{ht}'x_{ht} + z_{ht} = E_{ht} \text{ and } x_{jh} = 0 \\ (\hat{\psi}_{ht}, \hat{\gamma}_{ht} \text{ は事後平均})$$

48

4. 実証分析

図5 被験者レベルのCV時系列プロット

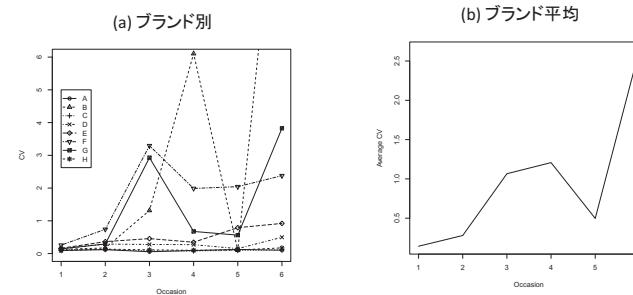


- ID#99: Eが大きい ⇒ Eを削除すると効用の減少大
- ID#26: FとGが大きいが、その他のブランドも増加傾向
– 最終時点ではほぼ全てのブランドを重要視

49

4. 実証分析

図6 ブランドレベルのCV時系列



- 各期の数値は $CV_t^{(j)} = \sum_{h=1}^H CV_{ht}^{(j)} / H$ ($t = 1, \dots, 7$)
- A,C,H以外はCVが上昇傾向
- 平均でも上昇している → 品揃えの重要度が増加

50

5. まとめ

- ・「飽き」の動的モデル
- ・属性に対する飽きを評価
- ・因子構造による次元圧縮と属性固有・消費者固有のSatiationへの分解
- ・補償価値による品揃えの最適化問題
- ・他のカテゴリID-POSデータへの適用
- ・マーケティング変数の利用可能性
- ・離散データの最適化に連続データを仮定している問題点

51

参考文献

- Bhat, C.R (2005) "A multiple discrete-continuous extreme value model: formulation and application to discretionary time-use decision", *Transportation Research B*, Vol.39, 679-707.
- Bhat, C.R. (2008) "The multiple discrete-continuous extreme value (MDCEV) model: Role of utility function parameters, identification considerations, and model extensions," *Transportation Research.B*, 42, 274-303.
- Carter, C.K. and Kohn, R. Carter (1994) "On Gibbs sampling for state space models", *Biometrika*, Vol.81, 541-553.
- Chintagunta, P. (1994) "Heterogeneous Logit Model Implications for Brand Positioning", *Journal of Marketing Research*, Vol.32, 304-311.
- Elrod, T. (1988) "Choice Map: Inferring a Product Market Map from Panel Data", *Marketing Science*, Vol.7, 21-40.
- Geweke, J. and G. Zhou (1996) "Measuring the Pricing Error of the Arbitrage Pricing Theory", *The Review of Financial Studies*, Vol.9, 557-587.
- Kim, J., G. Allenby and P. Rossi (2002), "Modeling Consumer Demand for Variety," *Marketing Science*, Vol.21, 229-250.
- Kim, J., G., Allenby and P., Rossi (2007), "Product attribute and models of multiple discreteness," *Journal of Econometrics*, Vol.138, 208-230.
- Satomura, T, J. Kim and G.M. Allenby (2011a) "Multiple-Constraint Choice Models with Corner and Interior Solutions", *Marketing Science*, Vol.30, No.3, 481-490
- Satomura, T., J.D. Brazell and G.M. Allenby (2011b) "Choice Models for Budgeted Demand and Constrained Allocation," working paper, Ohio State University.

52