

An Endogenous Segmentation Mode Choice Model with an Application to Intercity Travel

Bhat, C.R. (1997)
Transportation Science, 31(1), 34-48

理論談話会#10

2019/6/14

M1 熊野 孝彦

目次

1. 概要 Abstract
2. 序論 Introduction
3. モデル構造 Model Structure
4. モデル推定 Model Estimation
5. 実装 An Application to Intercity Mode Choice Modeling
6. 評価 Choice Elasticities and Policy Implications
7. 結論 Summary and Conclusion

1. 概要

特徴

モード選択モデルに**内生セグメント**の考え方をを用いた



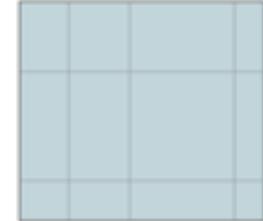
- ・ 旅行人口における**市場セグメント**の数を決定する
- ・ 個人を各セグメントに配分
- ・ 各セグメントの離散モード選択モデルを構築

一緒に決定

内生セグメンテーションモデルには**EM法**(期待値最大化法)と**準ニュートン法**の最大化アルゴリズムを組み合わせた推定方法を提案

(参考) セグメント

市場をニーズによって分割する



- ・ **セグメント** = マーケティング用語
- 購買行動において似通っている集団のこと

- ・ **セグメンテーション** 市場の成熟化 消費者のニーズの多様化
- ターゲットを決めるために、市場や消費者をセグメントに分類
- 効果的にビジネス成果を得ることができる

セグメンテーションの主な変数

カテゴリ	代表的な変数	セグメンテーションの例
地理的変数 (ジオグラフィック)	地方 気候 人口密度	関東、関西など 温暖、季節など 都市部、郊外など
人口統計変数 (デモグラフィック)	年齢 性別 家族構成 所得 職業	少年、若者、中年、高齢者など 男性、女性 独身、既婚、など 年収別 自営業、ブルーカラー、など
心理的変数 (サイコグラフィック)	ライフスタイル パーソナリティ	車好き、アウトドア派、など 保守的、新しもの好き、健康志向など
行動変数	使用率 ベネフィット	ヘビーユーザー、など 経済性、機能性、など

2. 序論

- ・ 背景

旅行モード選択モデルの推定は旅行需要の分析に重要

→MNL (multinomial-logit model)が一般的

理想 : 個人ごとの $\left(\begin{array}{l} \text{固有のモードバイアス} \\ \text{モードのサービスレベル} \end{array} \right)$ のパラメータを求めたい

↔モード選択推定のデータは個人ごとに1つの観測値しかない

⇒ **理想** は無理 (個人から繰り返しデータを取っても安定したパラメータ推定には不十分)

2. 序論

- ・ 背景

旅行モード選択モデルの推定は旅行需要の分析に重要

→MNL (multinomial-logit model)が一般的

好みの異質性

理想 : 個人ごとの $\left[\begin{array}{l} \text{固有のモードバイアス} \\ \text{モードのサービスレベル} \end{array} \right]$ のパラメータを求めたい

反応の異質性

個人を越えて適用させることが大事

↔モード選択推定のデータは個人ごとに1つの観測値しかない

⇒理想は無理 (個人から繰り返しデータを取っても安定したパラメータ推定には不十分)

2. 序論

- ・ 背景

旅行モード選択モデルの推定は旅行需要の分析に重要

→MNL (multinomial-logit model)が一般的

好みの異質性

理想 : 個人ごとの $\left(\begin{array}{l} \text{固有のモードバイアス} \\ \text{モードのサービスレベル} \end{array} \right)$ のパラメータを求めたい

反応の異質性

個人を越えて適用させることが大事

↔モード選択推定のデータは個人ごとに1つの観測値しかない

⇒理想は無理 (個人から繰り返しデータを取っても安定したパラメータ推定には不十分)

問題 : 横断的なデータからモード選択の様子を得るために, これらの異質性をどうMNLに組み込むか?

2. 序論

- ・ 背景

アプローチ①：パラメータをランダム係数で推定

→個人間の体系的な異質性を無視しているから×

アプローチ②：外生的市場セグメンテーション

アプローチ③：内生的市場セグメンテーション

2. 序論



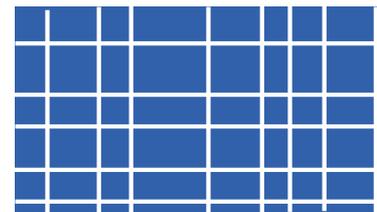
・ 外生的市場セグメンテーション

ある市場のセグメントを仮定 (個人の属性やトリップの特徴で分類)

理想: **ありとあらゆる変数を考慮したい** (→フル次元の外生市場セグメンテーションと呼ぶ)

→セグメントの数が増えすぎる

→2つの方法を用いて制約を乗り越えた



①RUFS法 (Refined Utility Function Specification):

重要な変数を導入し **alternative-specific** 変数として効用関数に直接組み込む

→好みとサービスレベルへの反応の, 変数間の低次元な交互作用を許容

②LDEMS法 (Limited-Dimensional Exogenous Market Segmentation):

セグメンテーションに変数の部分集合を用いる

メリット: 実用的で使いやすい(MNLのソフトウェアを用いるだけ)

デメリット: 好みとサービスレベルへの反応の, 変数間の高度な交互作用を抑制

2. 序論

・ 内生的市場セグメンテーション

体系学的な異質性を導入したい！

→セグメントの数を最適な値まで減らすというアプローチ

セグメント数

セグメントへの個人の配分

セグメントごとのパラメータ

を一緒に求める

メリット : 好みとサービスレベルへの反応の, 変数間の高度な交互作用を抑制

外生の
デメリット

2. 序論

・ 内生的市場セグメンテーション

体系学的な異質性を導入したい！

→セグメントの数を最適な値まで減らすというアプローチ

セグメント数

セグメントへの個人の配分

セグメントごとのパラメータ

を一緒に求める

メリット : 好みとサービスレベルへの反応の、変数間の高度な交互作用を抑制

すべての交互作用の効果を許容する

外生の
デメリット

2. 序論

・ 内生的市場セグメンテーション

体系学的な異質性を導入したい！

→セグメントの数を最適な値まで減らすというアプローチ

セグメント数

セグメントへの個人の配分

セグメントごとのパラメータ

を一緒に求める

メリット : 好みとサービスレベルへの反応の、変数間の高度な作用を抑制

すべての交互作用の効果を許容する

外生の
デメリット

デメリット : IIA特性があるかも (あとで検証する！)

直接MNLのソフトウェアを用いて推定できない (あとで克服する！)

→ 本論文では**内生的市場セグメンテーション**のアプローチを用いる！

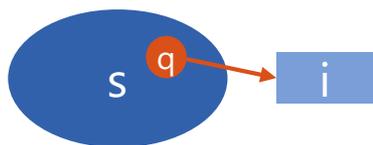
3. モデル構造

・ 仮定：「都市間の旅行という市場には S 個のセグメントが存在する」

→ 各セグメント s で離散モード選択モデルをつくる

ランダム効用を仮定
(ガンベル分布と独立同分布に従う)

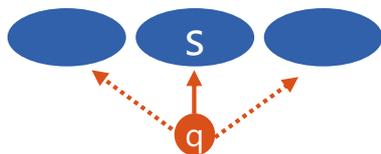
① セグメント s 内の個人 q がモード i を選ぶ確率 $P_q(i)|s$ (MNLの形)



$$P_q(i)|s = \frac{e^{\beta_s' x_{qi}}}{\sum_{j \in C_q} e^{\beta_s' x_{qj}}} \quad (1)$$

x_{qi} : 個人ごとの効用
 β_s' : パラメータベクトル

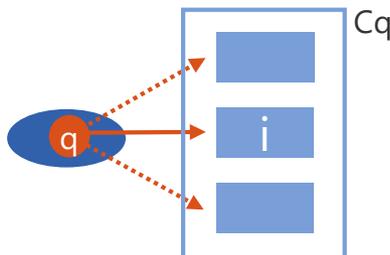
② 個人 q がセグメント s に属する確率 P_{qs}



$$P_{qs} = \frac{e^{\gamma_s' z_q}}{\sum_l e^{\gamma_l' z_q}} \quad (2)$$

γ_s' : パラメータベクトル
 z_q : 変数

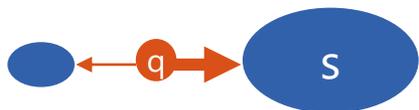
③ 個人 q がモード集合 C_q からモード i を選ぶ確率 $P_q(i)$ ((1)と(2)より)



$$P_q(i) = \sum_{s=1}^S P_{qs} \times [P_q(i)|s] \quad (3)$$

3. モデル構造

④ セグメント s のサイズ R_s 各個人がセグメント s に属する確率の和



$$R_s = \frac{\sum_q P_{qs}}{Q} \quad (4)$$

Q : 個人の総数

⑤ 各セグメント s を特徴づける属性 \bar{Z}_s

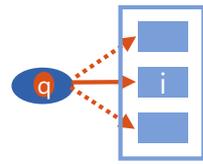


$$\bar{Z}_s = \frac{\sum_q P_{qs} Z_q}{\sum_q P_{qs}} \quad (5)$$

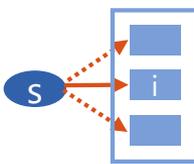
z_q : 変数

このモデルを用いると、個人レベル・セグメントレベル・市場レベルでのモード選択の推定を行うことができる

式(3)の $P_q(i)$

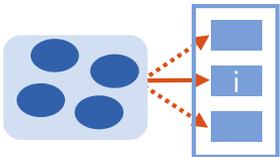


・セグメントレベルのモード分担率 : $W_s(i)$



$$W_s(i) = \frac{\sum_q P_{qs} \times [P_q(i)|s]}{\sum_q P_{qs}} \quad (6)$$

・市場レベルのモード分担率 : $W(i)$



$$W(i) = \frac{\sum_s \sum_q P_{qs} \times [P_q(i)|s]}{Q} = \sum_s R_s \times W_s(i) \quad (7)$$

4. モデル推定



- ・ 内生市場セグメンテーションを用いたモード選択モデルで**推定されるパラメータ**はパラメータベクトルの $\beta_s' \gamma_s'$ (式(1)(2))と、セグメント数 S である。
- ・ S によって最大化される**対数尤度関数**は次の式で表される。

$$\leq \sum_{q=1}^{q=Q} \log \left\{ \sum_{s=1}^S \left(P_{qs} \times \prod_{i \in C_q} [P_q(i)|s]^{\delta_{qi}} \right) \right\} \quad (8)$$

$$C_q : \text{個人 } q \text{ が選択できるモード集合}$$
$$\delta_{qi} = \begin{cases} 1 & (\text{個人 } q \text{ がモード } i \text{ を選んだとき}) \\ 0 & (\text{それ以外}) \end{cases} \quad (9)$$

(式(8)は有限混合モデルの特徴を表している)

$$q = 1, 2, \dots, Q$$
$$i \in C_q$$

◆混合モデルにおける尤度関数の最大化法：

ニュートン法 or 準ニュートン法は計算的に不安定である

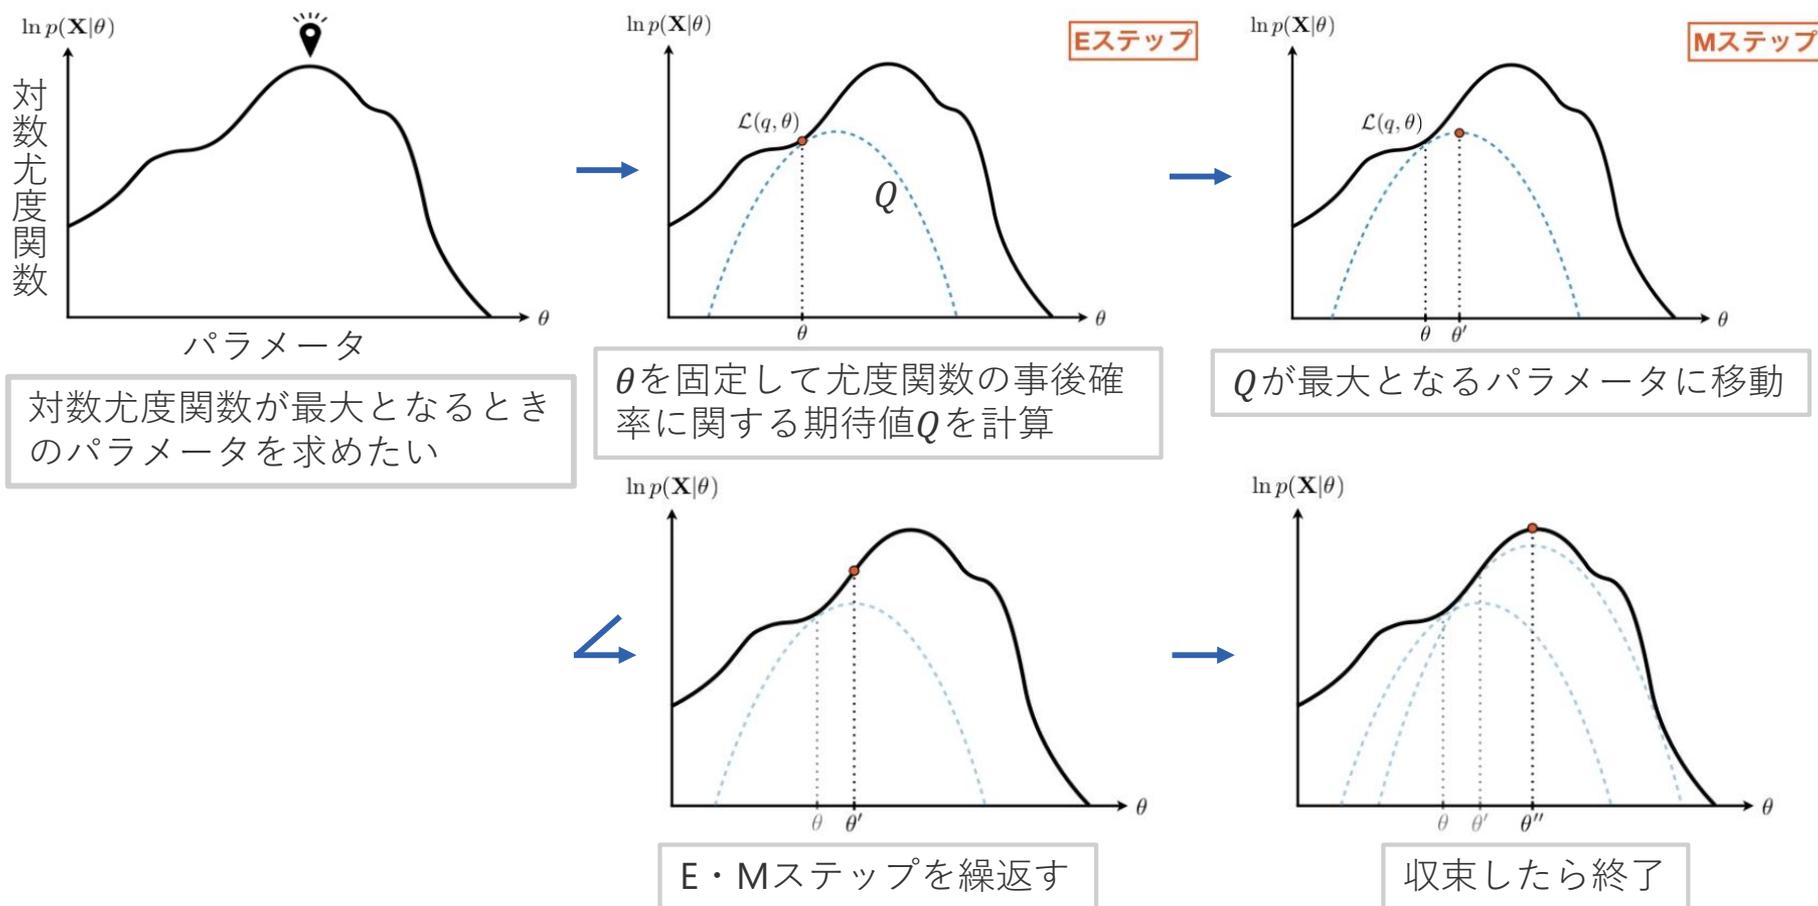
(Mclachlan & Basford, 1988) (Redner & Walker, 1984)

→尤度最大化の始点となるパラメータをいい感じのところから始める必要がある

→**EM法**を用いる

(参考) EM法のイメージ

- EM法：統計学において、隠れ変数がある確率モデルのパラメータを最尤推定する手法の一つ（機械学習などで用いられる）



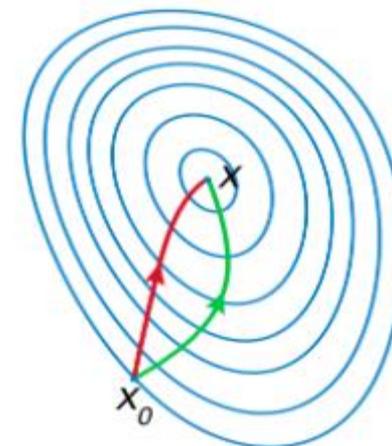
(参考) 準ニュートン法



・ ニュートン法

ニュートン法：連続最適化問題において関数の極大・極小解を見つけるためのアルゴリズム

2次の勾配まで考慮するので、1次の勾配しか考慮しない最急降下法より効率よく大域的最適解に到達できる。



緑：最急降下法
赤：ニュートン法

→最大化/最小化したい関数のヘッセ行列を用いる

・ 準ニュートン法

ヘッセ行列のかわりに、勾配ベクトルで近似する

○ DFP法

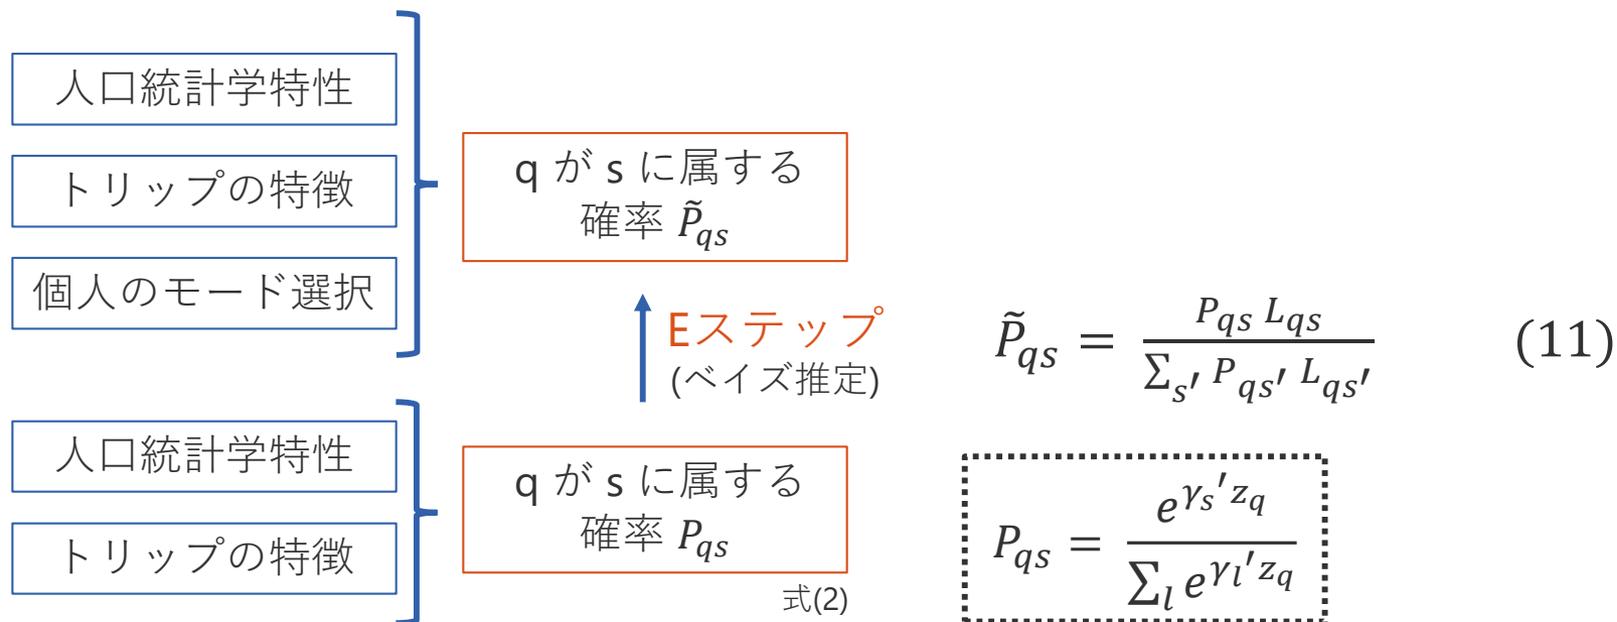
$$H_{k+1} = H_k + \frac{\Delta x_k \Delta x_k^T}{y_k^T \Delta x_k} - \frac{H_k y_k y_k^T H_k^T}{y_k^T H_k y_k}$$

4. モデル推定

- EM法 - P_{qs} から \tilde{P}_{qs} を推定 -

$$\stackrel{(8)}{<} \sum_{q=1}^{q=Q} \log \left\{ \sum_{s=1}^S \left(P_{qs} \times \prod_{i \in C_q} [P_q(i)|s]^{\delta_{qi}} \right) \right\} = \sum_{q=1}^{q=Q} \log \left\{ \sum_{s=1}^S P_{qs} \times L_{qs} \right\} \quad (10)$$

(L_{qs} の値は個人 q の選択尤度)



4. モデル推定



- EM法 - \tilde{P}_{qs} から β_s', γ_s' を求める -
- 効率的に \tilde{P}_{qs} の値から各セグメントの β_s', γ_s' の値を求めるには次のような対数尤度関数を用いる

$$\ln^* = \sum_q \left\{ \sum_s \tilde{P}_{qs} \log L_{qs} + \log L_q^* \right\} = \sum_q \sum_s \tilde{P}_{qs} \{ \log L_{qs} + \log P_{qs} \} \quad (15)$$

この対数尤度関数はMNLの対数尤度関数の組み合わせ

$$L_q^* = \prod_s [P_{qs}]^{\tilde{P}_{qs}}$$

パラメータの初期値を決めて、式(11)の P_{qs} から \tilde{P}_{qs} を求める: **Eステップ**
 \tilde{P}_{qs} を用いて(15)の対数尤度を最大化する: **Mステップ**  交互に繰り返す

4. モデル推定



- EM法 - 備考 -
- E-ステップとM-ステップの繰り返しで対数尤度関数は単調増加する (Dempsterら,1977)
- EM法は収束するまで繰り返される
- EM法の収束率は対数尤度が最大に近づくと遅くなる (→ 5章で解決！)
- **EM法はMNLのソフトウェアを用いるだけで推定できる**

5. 実装

- ・ 前提
- ・ 内生セグメンテーションモデルと他の方法とを比較
- ・ **都市間の旅行モード選択**の様子を分析
- ・ 1989年にVIAレール(カナダ)が将来の**トロント～モントリオール間**の旅行を予測
(さまざまな鉄道サービスの改善に応じた機関分担率の変化を推定することが目的)
- ・ モードの選択肢は**飛行機・車・電車**に限定 (バスはシェア率1%を切るので省略)
- ・ データサンプル：3,593人のビジネス旅行者の有料のビジネス旅行データ
- ・ 人口統計学的特性とトリップの特徴に関連した5つの変数
→ **収入, 性別, 旅行人数**(1人orグループか), **曜日**(平日or休日), **トリップ距離**(片道)
- ・ サービスレベルの変数
→ **サービスの頻度, 費用, 乗り物内にいる時間, 乗り物外にいる時間**

5. 実装

- 背景
- 内生セグメンテーションモデルと他の方法とを比較
- 都市間の旅行モード選択の様子を分析

Table 1. Mean and (Standard Deviation) of Modal Level-of-Service Variables

Mode	Frequency (departures/day)	Total cost (in Canadian \$)	In-vehicle time (in mins.)	Out-of-vehicle time (in mins.)
Train	4.21 (2.3)	58.58 (17.7)	244.50 (115.0)	86.32 (22.0)
Air	25.24 (14.0)	157.33 (21.7)	57.72 (19.2)	106.74 (24.9)
Car	not applicable	70.56 (32.7)	249.60 (107.5)	0.00 (0.0)

Note: All measures are one-way values. Air and train frequency refer to total departures by all carriers.

- サービスレベルの変数
- サービスの頻度, 費用, 乗り物内にいる時間, 乗り物外にいる時間

5. 実装

・ 内生セグメンテーションモデルの結果 - セグメント数 -

・ S (セグメント数) = 2,3,4 の各パターンで推定

・ 各パターンに対して 統計モデルの良さを評価するための指標 BIC値 (Bayesian Information Criterion) を計算

→ 好ましいモデルはBIC値が最も低い場合

S	2	3	4
BIC値	2291	2247.9	2259.8

⇒ セグメント数は**3つ**が最適！

5. 実装

- ・ 内生セグメンテーションモデルの結果
- ・ $S = 3$ での推定結果： サービスレベルの変数

Table 2. Intercity Mode Choice Analysis: Parameter Estimates for Three-Segment Solution

Model	Variable	Segment 1		Segment 2		Segment 3	
		Parameter	t-statistic	Parameter	t-statistic	Parameter	t-statistic
Segment-Specific Mode Choice Model	Mode Constants						
	Train	-3.0617	-2.54	4.7763	2.12	1.1737	0.60
	Air	-1.0516	-1.82	-1.3691	-1.01	4.3404	3.36
	Large City Indicator						
	Train	1.9273	2.20	0.2146	0.32	-0.0840	-0.12
	Air	2.2240	3.46	-1.3691	-1.01	2.6892	2.37
	Frequency of Service (deps./day)	0.1615	6.38	0.5784	3.49	0.1790	3.92
	Travel Cost (Canadian \$)	-0.0591	-4.53	-0.1728	-3.27	-0.0166	-0.54
Segment-Specific Mode Choice Model	Travel Time (minutes)						
	In-Vehicle	-0.0254	-3.25	-0.0030	-1.20	-0.0657	-5.21
	Out-of-Vehicle	-0.0436	-2.91	-0.0239	-1.84	-0.1627	-5.01
Segmentation Model	Constant	4.4227	7.62	1.5366	2.56	Base Segment	
	Income	-0.0293	-5.73	-0.0447	-8.60		
	Female Sex	-0.7614	-3.46	0.9703	4.05		
	Traveling Alone	-0.1657	-1.70	-0.7226	-4.07		
	Weekend Travel	0.2423	0.65	1.5326	4.71		
	Trip Distance	-0.0047	-5.91	-0.0030	-3.79		
Segment Size		0.4866		0.1220		0.3914	

式(4)

Note: The log-likelihood value at zero is -3947.3; the log-likelihood value for the unsegmented model with only alternative specific constants is -3648.2. The log-likelihood value at convergence for the three segment solution is -2100.5.

5. 実装

・ 内生セグメンテーションモデルの結果

- ・ S = 3 での推定結果：人口統計学的特性とトリップの特徴に関する変数

Table 3 Qualitative Characterization of Mode Choice Preferences and Socio-Demographic/Trip Attributes of Segments

Preferences/Attributes	Characteristic	Segment 1	Segment 2	Segment 3
Mode Choice Preferences	Intrinsic Preference for	Car; if trip originates or ends in large city, air is preferred	Train	Air
	Sensitivity to Frequency	Low	High	Low
	Sensitivity to Cost	Medium	High	Low
	Sensitivity to IVTT	Medium (Money Value = \$26/hour)	Low (Money Value = \$1.05/hour)	High (Money Value = \$237/hour)
	Sensitivity to OVTT	Medium (Money Value = \$44/hour)	Low (Money Value = \$8.30/hour)	High (Money Value = \$588/hour)
Socio-Demographic and Trip Attributes	Income	About average market income	Lower than average market income	Higher than average market income
	Sex	High proportion of males	High proportion of females	Same proportion as overall market
	Travel Group Size	Same proportion as overall market	High proportion of individuals traveling in a group	High proportion of individuals traveling alone
	Day of Travel	High proportion of weekday travelers	High proportion of weekend travelers	High proportion of weekday travelers
	Trip Distance	Short	Medium	Long

Note: MV stands for “money value of time”

2 と 3 の中間 頻度の価値が高い 時間の価値が高い

5. 実装

- ・ 内生セグメンテーションモデルの結果
- ・ $S = 3$ での推定結果：セグメンテーション変数の平均値

Table 4. Mean Values of Demographic and Trip Variables in Each Segment

Variable	Segment 1	Segment 2	Segment 3	Overall Market
Income ($\times 10^3$ Can\$)	52.16	44.09	60.28	54.36
Female	0.13	0.48	0.20	0.20
Traveling Alone	0.69	0.57	0.77	0.70
Weekend Travel	0.20	0.62	0.19	0.25
Trip Distance (km)	311.80	373.37	444.76	371.35

式(5)

■ 表3の結果と一致している！

5. 実装



・ 他のアプローチとの比較

・ 他のアプローチ：
効用関数制限モデル (RUFMS法)
有限次元の外生市場セグメンテーションモデル (LDEMS法)

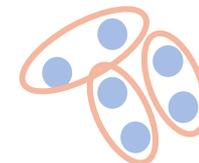


Table 5. Empirical Comparison of the Endogenous Segmentation Model with Refined Utility Function Specification Models

Statistic	First-order preference interactions	First-order preference and first-order response interactions		Second-order preference and first-order response interactions	
		Full version	Preferred version	Full version	Preferred version
Number of parameters	18	46	24	66	32
Log-likelihood at convergence	-2299.38	-2199.07	-2211.48	-2154.09	-2174.71
Adjusted likelihood ratio index, \bar{p}^{21}	0.4129	0.4312	0.4337	0.4376	0.4409
Result of non-nested likelihood ratio index test with endogenous segmentation model	Reject very strongly the hypotheses that any (and each) of the above models is as good as the endogenous segmentation model.				

Note: The likelihood value at convergence for the endogenous segmentation model is -2100.5 and the adjusted likelihood ratio index for this model is 0.4587 (number of parameters in the model is 36).

内生セグメンテーションモデルの方がよくフィットする！

5. 実装



・ 他のアプローチとの比較

・ 他のアプローチ： { 効用関数制限モデル (RUFMS法)
有限次元の外生市場セグメンテーションモデル (LDEMS法)

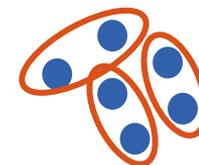


Table 6. Empirical Comparison of the Endogenous Segmentation Model with Limited-Dimensional Exogenous Segmentation Models

Segmentation variable	Number of Segms.	Number of parms.	LL at converg.	\bar{p}^{-2}_1	\bar{p}^{-2}_{fin}	Two-way segmentation with...	Number of Segms.	Number of parms.	LL at converg.	\bar{p}^{-2}	\bar{p}^{-2}_{fin}
Income ⁺	3	52	-2242.9	0.4186	0.4272	Sex	6	92	-2214.8	0.4156	0.4298
						Group size	6	92	-2208.9	0.4186	0.4313
						Day of travel	6	92	-2216.6	0.4151	0.4293
						Trip distance	9	156	-2108.1	0.4264	0.4568
Sex	2	32	-2287.4	0.4124	0.4160	Group size	4	64	-2262.0	0.4107	0.4178
						Day of travel	4	64	-2260.1	0.4112	0.4183
						Trip distance	6	96	-2179.7	0.4235	0.4387
Group size	2	32	-2278.5	0.4147	0.4182	Day of travel	4	64	-2250.9	0.4135	0.4206
						Trip distance	6	96	-2163.2	0.4277	0.4429
Day of travel	2	32	-2279.3	0.4145	0.4180	Trip distance	6	96	-2172.3	0.4253	0.4406
Trip distance	3	54	-2212.4	0.4258	0.4350	-	-	-	-	-	-

Note: The adjusted likelihood ratio index for the endogenous segmentation model is 0.4587 and the number of parameters in this model is 36.

内生セグメンテーションモデルの方が当てはまりが良い！

5. 実装

・ハイブリッドEM-DFPアルゴリズム

■ 推定アルゴリズム

① EMアルゴリズム

繰り返し過程で単調増加

安定性○， スピード×

② DFPアルゴリズム

4セグメント：収束しない
3セグメント：2/5の確率
2セグメント：3/5の確率

安定性×， スピード○

③ ハイブリッドEM-DFPアルゴリズム (EM→DFP)

安定性○， スピード○

一般的にはスピード速い

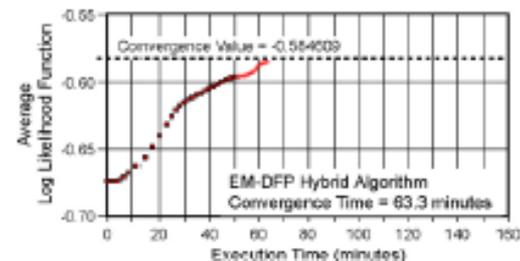
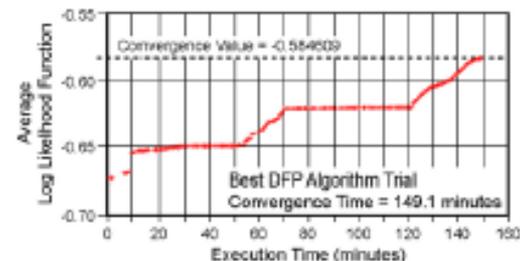
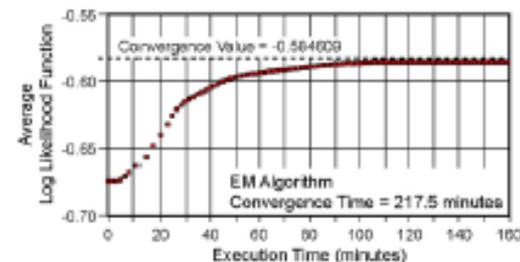


Figure 1. Performance of alternative algorithms for the three-segment solution

6. 評価

- モード選択の弾力性と政策への影響
- モード選択の弾力性
= 鉄道のサービスレベルの変数が1%増えることでモードのシェア率が何%変わるか

Table 7. Choice Elasticities (in Response to Change in Rail Service) and Mode Choice Shares from the Endogenous Segmentation Mode

Rail Level of Service Attribute	Segment 1			Segment 2			Segment 3			Market ¹		
	Rail	Air	Car	Rail	Air	Car	Rail	Air	Car	Rail	Air	Car
Frequency	0.15	-0.01	-0.04	0.20	-0.03	-0.04	0.06	-0.01	-0.01	0.41	-0.05	-0.10
Cost	-0.57	0.06	0.14	-0.77	0.14	0.15	-0.14	0.03	0.03	-1.48	0.22	0.31
IVTT ²	-0.32	0.01	0.09	-0.03	0.00	0.00	-0.51	0.07	0.12	-0.86	0.09	0.21
OVTT ³	-0.35	0.03	0.09	-0.18	0.03	0.04	-0.67	0.08	0.16	-1.20	0.14	0.29
Mode Choice Shares ⁴	0.07	0.20	0.73	0.80	0.07	0.13	0.06	0.76	0.18	0.15	0.40	0.44

- この弾力性はセグメント間のサービスレベルへの反応の違いを反映している

6. 評価



- ・ モード選択の弾力性と政策への影響
- ・ 政策への影響
 - 弾力性によって、**鉄道のサービス改善のターゲティング**ができるようになる
 - 鉄道の頻度の改善や運賃の低下は、低収入、女性、グループで旅行(セグメント 2)の人々をターゲットにすることが最も効率的である。
 - もし一番の目的が**高速道路での車の渋滞を減らす**ことならば、平均ぐらいの収入の男性にターゲットを絞り、平日・短距離の旅行市場(セグメント 1)での頻度を改善し、費用の低下に重きを置くことが最適である。
 - 高収入の人(セグメント 3)に対しては旅行時間の改善がベストである。

7. 結論

- ・ 本論文では旅行需要の推定に内生セグメンテーションモデルを使うことを提案した
- ・ このモデルによって、外生セグメンテーションモデルの弱点を解消できる
- ・ 個人レベルの弾力性を考察すると、内生セグメンテーションモデルはMNLのIIA特性を持っていないことがわかる
- ・ セグメンテーションモデルの推定にはハイブリッドEM-DFPアルゴリズムを提案
- ・ 内生セグメンテーションモデルをトロント～モントリオール間の旅行モード選択の推定に適用した
- ・ BIC (ベイズ情報量規準)よりセグメント数は3つが適切だと見つけた
- ・ 内生セグメンテーションモデルは都市での旅行状況における、都市間の交通渋滞緩和戦略の効果を評価する重要な方法論である