

**McFadden, D., Train, K., Mixed MNL models for discrete response, Journal of Applied Econometrics, pp.447-470, 2000.**

**離散選択のMixed MNLモデル**

M1 瀧口洋平

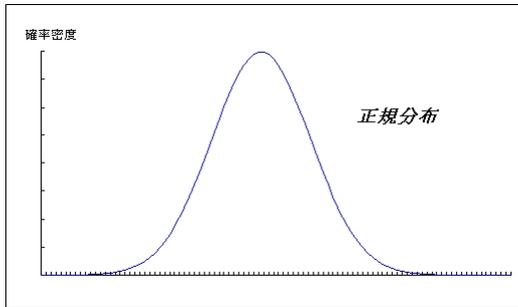
# 発表の構成

1. MMNL(Mixed MNL)とはなにか
2. 近似: 確率効用最大化(RUM)理論に従う離散選択モデルの選択確率の近似解を得られる.
3. 推定: シミュレーションによる推定手法
4. 実験: 車種選択問題への適用

# 1-1 MMNLについて

- Mixed Multinomial Logit Model(MMNL)とは？
  - 嗜好の異質性, 系列相関などの制約を全て緩和したモデル.

$$U_{nj} = \beta'_n x_{nj} + \varepsilon_{nj} \quad \dots(1)$$



$\beta_n$  : サンプル $n$ について確率分布 $f(\beta)$ に従うパラメータ  
 $x_{nj}$  : サンプル $n$ , 選択肢 $j$ に関する特性変数ベクトル  
 $\varepsilon_{nj}$  : IID(独立で同一な)ガンベル分布  
→MNLでは $\beta$ は全サンプルで一定の値をとる

パラメータ $\beta$ が1つ選ばれて与えられたときの選択確率はロジット型であり

$$L_{ni}(\beta) = \frac{e^{V_{ni}(\beta)}}{\sum_{j=1}^J e^{V_{nj}(\beta)}} \quad \dots(2)$$

# 1-1 MMNLについて

- $\beta$ が確率的に分布する時, 標準選択確率は

$$P_{ni} = \int L_{ni}(\beta) f(\beta) d\beta = \int \left( \frac{e^{\beta' x_{ni}}}{\sum_j e^{\beta' x_{nj}}} \right) f(\beta) d\beta \quad \dots(3)$$

- パラメータ $\beta$ を与える分布 $f(\beta)$ を推定することになる.
  - 一般的には分布の平均値, 共分散を調べる.
  - 分布は正規分布, 一様分布, ガンマ分布など様々
  - 適切な分布を用いて様々な効用最大化行動を表現可能
- 積分が残るのでMNLのように簡単に推定できない
  - シミュレーションを用いる

# 1-2 RUMについて

- RUM (Rundam Utility Maximization) モデルとは、個人の効用を確率変数として捉え、その効用を最大化すると考えるモデル。
  - 選択結果も確率的に(選択確率として)出る。
- 効用関数は次のように書ける。

$$U_{nj} = \alpha'_n z_{nj} \quad \dots(4)$$

または

$$U_{nj} = \beta'_n x_{nj} + \varepsilon_{nj} \quad \text{ここで } z'_{nj} = \langle x'_{nj}, d_j \rangle, \alpha' = \langle \beta'_n, \varepsilon_{nj} \rangle$$

⋯(5)

$n$ : 選択者  
 $j$ : 選んだ選択肢  
 $\alpha$ : パラメータ  
 $z$ : 説明変数

$x, d$ : 説明変数の要素  
 $\beta$ : 確定項の係数  
 $\varepsilon$ : 確率項の係数

# 1-2 RUMについて

- 選択肢*i*の条件付き選択確率

- パラメータ $\alpha$ が与えられたとき, 選択確率は0か1

$$q_{ni}(\alpha) = I(\alpha'_n z_{ni} > \alpha'_n z_{nj} \quad \forall j \neq i) \quad \dots(6)$$

$I$ : 条件を満たすとき1, その例外は0を取る

- $\alpha$ の確率分布を考慮すると選択確率は

$$Q_{ni} = \int I(\alpha'_n z_{ni} > \alpha'_n z_{nj} \quad \forall j \neq i) f(\alpha) d\alpha \quad \dots(7)$$

RUMモデル中で確率項を考慮することでロジットモデル(ガンベル分布), プロビットモデル(正規分布)などが導出される.

# 1-3 MMNLとの違い

- MMNLは式(4)の確定項の一部をIID誤差項と考える
  - IID (independently and identically, 独立で同一な)
  - ガンベルに従う誤差項を確率分布から分離する
  - 平均値0で適宜設定する分布を持つ誤差項

$$U_{nj} = \alpha'_n z'_{nj} + \text{IID誤差項} \quad \dots(8)$$

$z'_{nj}$ :  $z_{nj}$ からIID誤差項を分離した変数

- スケールパラメータ $\lambda$ を導入した選択確率

$$P_{ni} = \int \left( \frac{e^{(\alpha/\lambda)' z_{ni}}}{\sum_j e^{(\alpha/\lambda)' z_{nj}}} \right) f(\alpha) d\alpha \quad \dots(9)$$

$\lambda$ を変化させて式(7)と式(9)を等価にしたい

# 1-4 誤差項を無視するという事

- 例

- $\lambda$ を小さくすると $\alpha/\lambda$ は大きくなる

- すると式(9)の $P_{ni}$ は1か0に近づくので    ex)  $\int e^{ax} dx = (1/a) e^{ax} + C$

$$P_{ni} = \int \left( \frac{e^{(\alpha/\lambda)' z_{ni}}}{\sum_j e^{(\alpha/\lambda)' z_{nj}}} \right) f(\alpha) d\alpha$$
$$\doteq Q_{ni} = \int I(\alpha'_n z_{ni} > \alpha'_n z_{nj} \quad \forall j \neq i) f(\alpha) d\alpha$$

- (8)式は次式で表され, IID誤差項は確率に影響しない

$$U_{nj} = \frac{\alpha_n}{\lambda} z_{nj} + \text{IID誤差項} \quad \dots(10)$$

$U_1(\alpha/\lambda)$ より $U_2(\alpha/\lambda)$ が5大きい時, 誤差による変化が $\pm 3$ とすると, 選択結果は変わりうる.  $\lambda$ を10倍した時両者の差は5になり, 誤差によって選択結果は変わらず

# 1-5 近似のまとめ

- つまりスケール $\lambda$ を調整することで実質的にRUMモデルとMMNLは等価なモデルになる
- だが普通はあえてこの等価性を示すことは無く、誤差項に分布系を仮定することががそのままRUMとの近似と考えることもある
  - RUMの効用にもIID誤差は存在するため
  - 確定項と確率項を分離するのが難しいため
  - 経験的にはスケールをIID誤差項の分散と考える

# 1-6 近似の例

- Nested Logitとの近似

- NLは, 入れ子内の選択肢間にだけ相関がある
- MMNLの効用を次のように書く

$$U_{nj} = \alpha' x_{nj} + \mu'_n z_{nj} + \varepsilon_{nj} \quad \dots(11)$$

$\alpha$ : 固定のパラメータ

$\mu_n$ : サンプル $n$ のパラメータで平均値ゼロの確率項

$x_{nj}, z_{nj}$ : サンプル $n$ , 選択肢 $j$ に関する説明変数の値ベクトル

$\varepsilon_{nj}$ : IID(独立で同一な)ガンベル分布

- 誤差項を次式で考えるとNLと似た階層構造になる

$$\mu'_n z_{nj} = \sum_{k=1}^K \mu_{nk} d_{jk} \quad \dots(12)$$

$d_{jk}$ は $j$ が入れ子内の時1,  
それ以外で0のダミー変数とする  
 $\mu_{nk}$ は正規分布 $N(0, \sigma_k)$ とする

# 1-6 近似の例

- 式(4)に式(5)を代入

$$U_{nj} = \alpha' x_{nj} + \sum_{k=1}^K \mu_{nk} d_{jk} + \varepsilon_{nj} \quad \dots(13)$$

$\mu_{nk}$ : 正規分布の分散 $\sigma_k$ は $k$ ごとに決まる

- NLの効用関数

– サンプル $n$ が入れ子 $B_k$ 内の選択肢 $i$ を選ぶ

$$U_{nj} = W_{nk} + Y_{nj} + \varepsilon_{nj} \quad , \quad j \in B_k \quad \dots(14)$$

$W_{nk}$ : 入れ子 $k$ 内で共通の属性(相関を表す項)

$Y_{nj}$ : 選択肢 $j$ に固有の属性

$\varepsilon_{nj}$ : IID(独立で同一な)ガンベル分布

# 2-1 最尤推定法(MLE)

- ロジットモデルのパラメータ推定方法

- ロジットモデルの選択確率は

$$P_{ni} = \frac{\exp(V_{in})}{\sum_{j=1}^J \exp(V_{in})}, i = 1, \dots, J \quad \dots(15)$$

- データの対数尤度は

$$\ln L = \sum_{n=1}^N \sum_{j=1}^J d_{in} \ln P_{ni} \quad \dots(16)$$

- これを最大化するようにパラメータを計算する.

- 未知パラメータで微分して極値0として連立方程式を解く

## 2-2 最尤推定法の限界

- しかしプロビットモデルやMMNLのように選択確率に積分が残されている場合は計算が困難

$$P_{ni} = \int L_{ni}(\beta) f(\beta) d\beta = \int \left( \frac{e^{\beta' x_{ni}}}{\sum_j e^{\beta' x_{nj}}} \right) f(\beta) d\beta \quad \dots(3)$$

MMNLの選択確率(再掲)

- シミュレーションにより近似的に選択確率を求める
  - 繰り返し計算結果を平均したものとして求める
  - 求めた確率からパラメータを推定する
  - シミュレーション最尤推定法という

## 2-3 シミュレーション最尤推定法(MSLE)

1.  $f(\beta|\theta)$ から $\beta$ をR回抽出する. ( $\beta^r, r = 1 \dots R$ )
  - $f(\beta|\theta)$ : パラメータ密度関数
  - $\theta$ :  $f$ の分散や平均を表すパラメータ
2.  $\beta^r$ を用いて $L_{ni}(\beta)$ をR回繰り返し計算する.
3.  $L_{ni}(\beta)$ の平均値 $\hat{P}_{ni} = \frac{1}{R} \sum_{r=1}^R L_{ni}(\beta^r) \dots (16)$ を求める
4. シミュレーション対数尤度(SLL)は次式で表される

$$\text{SLL} = \sum_{n=1}^N \sum_{j=1}^J d_{nj} \ln \hat{P}_{ni} \dots (17)$$

- $d_{in}$ : 選択者nが選択肢jを選ぶとき1, それ以外は0
- これを最大化する $\theta$ の値を推定する.
- 計算回数は $R \times J \times N$ になると考えられる

## 2-3 シミュレーション最尤推定法

- ここで  $\hat{P}_{ni}$  は  $P_{ni}$  の不偏推定量であるが、 $\ln \hat{P}_{ni}$  は  $\ln P_{ni}$  の不偏推定量ではない。
  - 偏り: 推定する量(分布)と異なる平均値を持つ統計量(分布)を推定量(分布)として用いてしまう事
- $\ln \hat{P}_{ni}$  の偏りはドロー回数(抽出回数  $R$ )を増やすほど減っていく。そのためドロー回数は偏りを減らすような条件を満たす数となる。
- ここでドロー(抽出)手法にも何種類かある。

## 2-4 ドロー(抽出)手法

- ランダムドロー法
  - 正規分布や一様分布から変数を抽出する
  - 独立かつランダムにドローする
  - カバー範囲が狭くなる, 多くのドロー回数が必要
- ハルトンシーケンス法(ハルトン数列)
  - 一連のドローが負の相関を持つ素数を用いたアルゴリズム
  - ベースとなる素数を選び,  $(0,1)$ 区間をその数に分割することを繰り返す.
  - $1/3, 2/3, 1/9, 4/9, 7/9, 2/9, 5/9, 8/9$
  - 広範囲を早くカバーできる優れた準乱数を発生する.

## 2-5 サンプルサイズとドロー回数

- サンプルサイズ $N$ , ドロー回数 $R$ とする
  - ドロー回数とは, サンプル1個あたりの繰り返し計算数
- $R$ は $N$ によらない固定値とすると,  $\ln \hat{P}_{ni}$ が不連続になってしまう.
- MSLEがMLE(最尤推定法)と漸近的に等価になる条件は,  $\sqrt{N} < R$ である.

# 3-1 実験結果

- 6肢車種選択(サンプル数4654)にMMNLを適用
  - Sports utility vehicle, Sports car, Station wagon, Truck, Van, EV
- 確定項を21, 確率項を4種入れてMLSEで推定
- これを同一の確定項だけを入れたMNLモデルと比較

	MMNL	MNL
確定項	21種	21種
確率項	4種	なし
最終尤度	-7375.34	-7391.83

- 初期尤度は等しいので尤度比は最終尤度が大きい方(=MMNL)が高くなる→説明力が高い

## 3-2 人工変数の追加

- MNLにmixingの妥当性を判定するための人工変数を適当に12種類追加する.

- 人工変数は次の式で定義される.  $t$ は選択肢  $i$ の属性ベクトル  $x_i$ 中の要素,  $C$ は選択肢集合とする.

$$z_{ti} = \frac{1}{2}(x_{ti} - x_{tC})^2 \quad \text{with} \quad x_{tC} = \sum_{j \in C} x_{tj} \cdot L_C(j; \mathbf{x}, \hat{\alpha}) \quad \dots(18)$$

L: MNLの選択確率

- この変数が有意であれば, 選択要素  $t$ はmixingを持つと考えられる (mixingがないという帰無仮説を棄却する).
- ただし変数の独立性が無く, 非観測属性間にも相関があると考えられるためmixingがあることを必ずしも保証するわけではない.

# 3-3 人工変数を加えたMNL推定結果

人工変数	パラメータ	標準誤差	t値
Price/log(income)	0.0019	0.0927	0.02
Range	-0.0349	0.0551	-0.63
Acceleration	-1.3728	2.1388	-0.64
Top speed	-0.2071	0.6383	-0.32
Pollution	0.0977	0.6764	0.14
Size	21.5773	9.5	2.27*
"Big enough"	0.2837	0.3832	0.74
Luggage space	3.8731	3.4638	1.12*
Operating cost	4.2245	0.8369	5.05*
Station availability	0.6741	0.3781	1.78*
EV	2.3476	0.5704	4.12*
CNG	1.2364	0.4798	2.58*
最終尤度	-7356.61	*は $ T >1$ の変数	

- 尤度比は上昇し, 6種類の変数が $T > 1$ . つまり mixingが生じていると考えられる. これを確率項としてMMNLに導入して再び推定する.

# 3-4 改良MMNL推定結果

- 確定項は同じなので省略する. 推定結果は以下.

<u>Random Effects</u>	Parameter Estimates	SE
Non-EV	3.3802	0.7647
Non-CNG	1.1042	0.4990
Size	8.0788	2.7021
Luggage space	7.6220	1.7153
Operating cost	4.4532	0.8014
Station availability	1.3987	0.5730

- 確率項のパラメータから相関はあると考えられる

	MMNL	MNL	改良MMNL
確定項	21種	21種	21種
確率項	4種	なし	6種
最終尤度	-7375.34	-7391.83	-7358.93

- 尤度を比較すると高くなることがわかる
  - Mixingは有効と考えられる.

## 3-5 推定回数による結果の違い

- 2節で述べたようにMLSEで推定すると標準誤差にシミュレーションノイズが影響してしまう
  - 繰り返し計算回数が増えると一般的に誤差は減る
  - しかし普通の誤差 $\Delta_N(\theta_N)$ では誤差が増えてしまう
- Newey & McFadden(1994)で提案された, Robustな共分散行列の推定値を用いる

$$\Gamma_N(\theta_N)^{-1} \Delta_N(\theta_N) \Gamma_N(\theta_N)^{-1} \quad \dots(19)$$

# 3-6 実験結果 (MMNL)

- 50回→250回で通常 (Asymptotic)の誤差は増えているが、共分散行列の推定値(Robust)は全部減っている。
- 共分散行列の推定値で誤差を表現するのは有効である。

Table 2: Mixed Logit for Alternative-Fueled Vehicle Choice

Variables	Parameter Estimates	Standard Error 250 replications		Standard Error 50 replications	
		Asymptotic	Robust	Asymptotic	Robust
Price/log(income)	-0.264	0.0435	0.0452	0.0412	0.0525
Range	0.517	0.0581	0.0685	0.0511	0.1022
Acceleration	-1.062	0.1859	0.1990	0.1738	0.2519
Top speed	0.307	0.1150	0.1184	0.1131	0.1188
Pollution	-0.608	0.1392	0.1420	0.1357	0.1546
Size	1.435	0.5082	0.4991	0.4945	0.5156
"Big Enough"	0.224	0.1126	0.1166	0.1113	0.1220
Luggage Space	1.702	0.4822	0.5854	0.4314	0.8971
Operating Cost	-1.224	0.1593	0.2069	0.1393	0.2998
Station availability	0.615	0.1452	0.1536	0.1410	0.1757
Sports utility vehicle	0.901	0.1484	0.1486	0.1482	0.1493
Sports car	0.700	0.1625	0.1513	0.1626	0.1518
Station wagon	-1.500	0.0674	0.0645	0.0674	0.0659
Truck	-1.086	0.0556	0.0520	0.0555	0.0556
Van	-0.816	0.0558	0.0468	0.0557	0.0471
EV	-1.032	0.4249	0.5022	0.3777	0.6035
Commute < 5 & EV	0.372	0.1660	0.1763	0.1608	0.1927
College & EV	0.766	0.2182	0.2374	0.2073	0.2796
CNG	0.626	0.1482	0.1670	0.1391	0.2139
Methanol	0.415	0.1464	0.1474	0.1440	0.1534
College & Methanol	0.313	0.1243	0.1256	0.1223	0.1308
<u>Random Effects</u>					
Non-EV	2.464	0.5414	0.7184	0.4428	1.0252
Non-CNG	1.072	0.3773	0.4109	0.2781	0.5711
Size	7.455	1.8194	2.0408	1.5538	2.4734
Luggage Space	5.994	1.2483	1.6617	1.0483	2.7719
<u>Log Likelihood</u>					
	-7375.34				

Note: Parameter estimates are from Brownstone & Train (1996); standard error estimates are from this study.

# まとめ

- MMNLという概念についての解説を行った
- MMNLの普遍的な近似性を示した
- 推定手法であるMLSEを解説した
- MMNLを用いる妥当性を示した
- 実データを用いた実験から有効性を示した