

効用最大化理論と 確率的意決定モデル

愛媛大学
倉内慎也

1

はじめに

- 行動は選択の帰結
- 行動のモデル化 ≡ 選択のモデル化
- 選択の種類
 - ✓ 連続量の選択 例)ある場所での滞在時間
 - ✓ 離散量の選択 例)交通手段, 目的地, 経路
- 離散量の選択を表すモデルとして, **ランダム効用最大化に基づく非集計離散選択モデル**, を説明する
 - ✓ ロジットモデル, プロビットモデル, ネスティッドロジットモデル

2

合理的選択と効用最大化

合理的選択

完備性: {車, 鉄道} → (車 ≥ 鉄道) and/or (鉄道 ≥ 車)

推移性: (車 > バス) & (バス > 鉄道) ⇔ (車 > 鉄道)

複数の選択肢を**選好(望ましき)**の順に並べることができる

例) {A, B, C, D, E}

(A > B), (B > C), (C > D), (D < E), (C > E)

(A > B > C > E > D)



効用最大化: 「人は最大の効用を与える選択肢を選ぶ」

Aさん: 車を選択 ⇔ U(車) > U(バス), U(鉄道)

3

ランダム効用(1)

効用を構成する要因 (例)交通手段選択

- 代替案の属性: 料金, 所要時間, 乗換え回数etc.
- 個人属性: 性別, 年齢, 免許の有無etc.
- トリップ属性: トリップ目的, 時間帯etc.

$$\begin{aligned}
 U(car) &= \beta_1 + \beta_3 * time_{car} + \beta_4 * cost_{car} + \beta_5 * carown + \epsilon_{car} \\
 U(bus) &= \beta_2 + \beta_3 * time_{bus} + \beta_4 * cost_{bus} + \beta_6 * age60 + \epsilon_{bus} \\
 U(rail) &= \beta_3 * time_{rail} + \beta_4 * cost_{rail} + \epsilon_{rail}
 \end{aligned}$$

確定項(V)

誤差項

分析者にとって意思決定者のもつ真の効用は不明
→ランダム(誤差)項を用いて効用を確率的に表す

4

ランダム効用(2)

誤差項に含まれるもの

- **非観測属性**: 快適性, 移動の自由度etc.
- **測定誤差**: 駅までのアクセス時間etc.
- **情報の不完全性**: 認知所要時間と実際の所要時間のずれetc.
- **Instrumental (proxy) variables**:

$$U(\text{rail}) = \beta_3 * \text{time}_{\text{rail}} + \beta_4 * \text{cost}_{\text{rail}} + \beta_5 * \text{conf}_{\text{rail}}$$

$$\text{conf}_{\text{rail}} = \beta'_5 * \text{seat}_{\text{rail}} + v$$

confの代理変数

$$U(\text{rail}) = \beta_3 * \text{time}_{\text{rail}} + \beta_4 * \text{cost}_{\text{rail}} + \beta_5'' * \text{seat}_{\text{rail}} + \beta_5 * v$$

5

ランダム効用(3)

誤差項に含まれるもの

- **非観測異質性**: 快適性, 移動の自由度etc.

$$U(\text{rail}) = \beta_n * \text{time}_{\text{rail}}$$

$$U(\text{rail}) = \beta_n * \text{time}_{\text{rail}}$$

$$\beta_n = \bar{\beta} + v_n$$

$$\beta_n = \alpha * \text{income}_n + v_n$$

観測不可能な嗜好の異質性

観測可能な嗜好の異質性

$$U(\text{rail}) = \bar{\beta} * \text{time}_{\text{rail}} + v_n * \text{time}_{\text{rail}} \quad U(\text{rail}) = (\alpha * \text{income}_n) * \text{time}_{\text{rail}} + v_n * \text{time}_{\text{rail}}$$

- **効用最大化以外の意思決定ルールによる影響**:

$$U(\text{car}) = \beta_1 + \beta_3 * \text{time}_{\text{car}} + \beta_4 * \text{cost}_{\text{car}} + \beta_5 * \text{carown} + \varepsilon_{\text{car}}$$

$$U(\text{bus}) = \beta_2 + \beta_3 * \text{time}_{\text{bus}} + \beta_4 * \text{cost}_{\text{bus}} + \beta_6 * \text{age60} + \varepsilon_{\text{bus}}$$

$$U(\text{rail}) = \beta_3 * \text{time}_{\text{rail}} + \beta_4 * \text{cost}_{\text{rail}} + \varepsilon_{\text{rail}}$$

6

誤差項の分布とモデル(1)

$$U(\text{car}) = V_{\text{car}} + \varepsilon_{\text{car}}$$

$$U(\text{rail}) = V_{\text{rail}} + \varepsilon_{\text{rail}}$$

誤差項は確率的に変動

→分析者から見て効用が最大となる選択肢は確率的

→分析者から見た意思決定者の選択行動は確率的

$$\text{choice} = \text{car} \Leftrightarrow U(\text{car}) > U(\text{rail})$$

$$\Leftrightarrow V_{\text{car}} + \varepsilon_{\text{car}} > V_{\text{rail}} + \varepsilon_{\text{rail}}$$

$$\Leftrightarrow \varepsilon_{\text{rail}} - \varepsilon_{\text{car}} < V_{\text{car}} - V_{\text{rail}}$$


$$\Leftrightarrow \varepsilon < V$$

7

誤差項の分布とモデル(2)

$$\text{Pr ob}(\text{choice} = \text{car}) = \text{Pr ob}(\varepsilon < V)$$

$$= F_{\varepsilon}(V)$$



選択確率はεとVに依存

8

誤差項の分布とモデル(3)

$$U(car) = \beta X_{car} + \varepsilon_{car}$$

$$U(bus) = \beta X_{bus} + \varepsilon_{bus}$$

$$U(rail) = \beta X_{rail} + \varepsilon_{bus}$$

ε の分布形は？

$\varepsilon \sim$ IIDガンベル分布	→ 多項ロジットモデル
$\varepsilon \sim$ 一般化極値 (GEV) 分布	→ GEVモデル (NL, PCL, CNL, GNL等)
$\varepsilon \sim$ 多変量正規分布	→ 多項プロビットモデル
$\varepsilon \sim$ GEVと正規分布などの合成分布	→ ミックスロジットモデル


9

多項プロビット (MNP) モデル(1)

$$U(car) = \beta X_{car} + \varepsilon_{car}$$

$$U(bus) = \beta X_{bus} + \varepsilon_{bus} \quad \varepsilon \sim \text{多変量正規分布}$$

$$U(rail) = \beta X_{rail} + \varepsilon_{bus}$$



ε が非常に多くの要因を含む
→ 中心極限定理より分布の正規性は意味あり

10

多項プロビット (MNP) モデル(2)

$$U(car) = \beta X_{car} + \varepsilon_{car}$$

$$U(bus) = \beta X_{bus} + \varepsilon_{bus} \quad \varepsilon \sim \text{多変量正規分布}$$

$$U(rail) = \beta X_{rail} + \varepsilon_{bus}$$

$$\begin{aligned}
 U(car) &= \beta X_{car} + \theta_{car} \varepsilon_{delay} + \varepsilon_{car, other} \\
 U(bus) &= \beta X_{bus} + \theta_{bus} \varepsilon_{delay} + \omega_{bus} \varepsilon_{access} + \varepsilon_{bus, other} \\
 U(rail) &= \beta X_{rail} + \omega_{rail} \varepsilon_{access} + \varepsilon_{rail, other}
 \end{aligned}
 \rightarrow
 \begin{matrix}
 \text{Cov}(U) \\
 \left[\begin{array}{ccc}
 \sigma_{car}^2 & \sigma_{car, bus} & \sigma_{car, rail} \\
 \sigma_{car, bus} & \sigma_{bus}^2 & \sigma_{bus, rail} \\
 \sigma_{car, rail} & \sigma_{bus, rail} & \sigma_{rail}^2
 \end{array} \right]
 \end{matrix}$$

ε は互いに分散が異なり相関も持つ
→ 多変量正規分布は最も一般的

11

多項プロビット (MNP) モデル(3)

$$U(car) = \beta X_{car} + \varepsilon_{car}$$

$$U(bus) = \beta X_{bus} + \varepsilon_{bus} \quad \varepsilon \sim \text{多変量正規分布}$$

$$U(rail) = \beta X_{rail} + \varepsilon_{bus}$$

$$P(i) = \int_{\varepsilon_1=-\infty}^{\varepsilon_i+V_i-\varepsilon_1} \cdots \int_{\varepsilon_i=-\infty}^{\infty} \cdots \int_{\varepsilon_j=-\infty}^{\varepsilon_i+V_i-\varepsilon_j} \phi(\varepsilon) d\varepsilon_j \cdots d\varepsilon_1$$

$$\phi(\varepsilon) = \frac{1}{(\sqrt{2\pi})^J |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} \varepsilon \Sigma^{-1} \varepsilon'\right)$$

- Open-formのため計算コストが高い
- Identificationの問題から推定可能なパラメータは限られており解釈が困難

12

多項ロジット(MNL)モデル(1)

$$U(car) = \beta X_{car} + \varepsilon_{car}$$

$$U(bus) = \beta X_{bus} + \varepsilon_{bus} \quad \varepsilon \sim \text{IIDガンベル分布}$$

$$U(rail) = \beta X_{rail} + \varepsilon_{bus}$$




図2.1 正規分布とガンベル分布の確率密度関数

正規分布に似ている
→特に2項ロジットモデルは2項プロビットモデルとほとんど同じ

13

多項ロジット(MNL)モデル(2)

$$U(car) = \beta X_{car} + \varepsilon_{car}$$

$$U(bus) = \beta X_{bus} + \varepsilon_{bus} \quad \varepsilon \sim \text{IIDガンベル分布}$$

$$U(rail) = \beta X_{rail} + \varepsilon_{bus}$$

$$P(car) = \frac{\exp(\mu V(car))}{\exp(\mu V(car)) + \exp(\mu V(bus)) + \exp(\mu V(rail))}$$

$$P(i) = \frac{\exp(\mu V_i)}{\sum_{j \in C} \exp(\mu V_j)} \quad \text{Cov}(U) = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} \quad \sigma^2 = \frac{\pi^2}{6\mu^2}$$

- シェア型モデルであるため直感的にわかりやすい
- closed-formのため計算コストが安い

14

ロジットモデルとIIA特性

- 無関係な選択肢からの選択確率の独立
(Independence from Irrelevant Alternatives)

$$P(i|C) = \frac{\exp(V_i)}{\sum_{j \in C} \exp(V_j)}$$

$$\frac{P(i|C)}{P(j|C)} = \frac{\exp(V_i)}{\exp(V_j)} = \frac{P(i|A)}{P(j|A)} \quad i, j \in A \subseteq C$$



$$P(car) : P(bus) = 2 : 1, P(bus) : P(rail) = 1 : 1$$



$$P(car) = \frac{1}{2}, P(bus) = \frac{1}{4}, P(rail) = \frac{1}{4}$$


15

IIA特性の利点

- 選択肢の全集合を考える必要がないため調査設計が楽(一対比較を考えればよい)
- 選択肢の部分集合を用いて推定してもパラメータ推定値にバイアスが生じない
→推定計算が楽(選択肢集合が大きい/不確定な場合)
例)ゾーン数400の目的地選択
実際に選択した目的地+残り399の中から9個をランダムサンプリングして推定
- 代替案の追加や削除が容易
→新規代替案の影響評価などが簡単


16

IIA特性の問題点(1) ～赤バス/青バス問題～



17

IIA特性の問題点(2)



18

IIA特性を避けるには？

●効用関数の確定項をより良く特定化する

- ・説明変数を加える
- ・異質性を考慮



- IIAテストを実行する
- 誤差項の相関構造を考慮したモデルを適用する

19

ネスティッドロジットモデル(1)

□ 目的地・交通手段選択の例

- 目的地選択の選択肢 d : $d = \{C: \text{中心部}, S: \text{郊外}\}$
- 手段選択の選択肢 m : $m = \{A: \text{自動車}, R: \text{鉄道}\}$

□ 同時選択の選択肢 dm の効用関数

$$U_{dm} = V_d + V_m + V_{dm} + \varepsilon_d + \varepsilon_m + \varepsilon_{dm}$$

- V_d : 目的地選択肢 d に固有な効用の確定項 (例) 店舗密度
- V_m : 手段選択肢 m に固有な効用の確定項 (例) 自動車保有 D
- V_{dm} : 目的地選択肢 d と手段選択肢 m の組み合わせで決まる効用の確定項 (例) 所要時間

20

ネスティッドロジットモデル(2)

□ 同時選択の選択肢 dm の効用関数

$$U_{dm} = V_d + V_m + V_{dm} + \varepsilon_d + \varepsilon_m + \varepsilon_{dm}$$

- ε_d : 目的地選択肢 d に固有な効用の誤差項
- ε_m : 手段選択肢 m に固有な効用の誤差項
- ε_{dm} : 目的地選択肢 d と手段選択肢 m の組み合わせで決まる効用の誤差項

□ 誤差項に関する仮定

- ε_m : $\text{Var}(\varepsilon_m) = 0$
- ε_d : $\max_{m \in \{A, R\}} U_{dm}$ がスケールパラメータ μ^d をもつガンベル分布
- ε_{dm} : スケールパラメータ μ^m をもつIIDガンベル分布

21

ネスティッドロジットモデル(3)

□ 同時選択の選択肢 dm の効用関数

$$U_{dm} = V_d + V_m + V_{dm} + \varepsilon_d + \varepsilon_{dm}$$

□ 選択肢間の相関

- 中心部(C)に自動車(A): $U_{CA} = V_C + V_A + V_{CA} + \varepsilon_C + \varepsilon_{CA}$
- 中心部(C)に鉄道(R): $U_{CR} = V_C + V_R + V_{CR} + \varepsilon_C + \varepsilon_{CR}$
- 郊外(C)に自動車(A): $U_{SA} = V_S + V_A + V_{SA} + \varepsilon_S + \varepsilon_{SA}$
- 郊外(C)に鉄道(R): $U_{SR} = V_S + V_R + V_{SR} + \varepsilon_S + \varepsilon_{SR}$

■ Joint Logitモデルは不適

中心部・自動車 中心部・鉄道 郊外・自動車 郊外・鉄道

ネスティッドロジットモデル(4)

□ 同時選択の選択肢 dm の効用関数

$$U_{dm} = V_d + V_m + V_{dm} + \varepsilon_d + \varepsilon_m + \varepsilon_{dm}$$

□ 乗法定理

$$P(d, m) = P(m|d)P(d)$$

□ 周辺確率 $P(d)$

$$P(d) = \Pr \left[\max_{m \in \{A, R\}} U_{dm} \geq \max_{m \in \{A, R\}} U_{d'm}, d \neq d' \right]$$

$$= \Pr \left[\begin{aligned} &V_d + \varepsilon_d + \max_{m \in \{A, R\}} (V_m + V_{dm} + \varepsilon_{dm}) \\ &\geq V_{d'} + \varepsilon_{d'} + \max_{m \in \{A, R\}} (V_m + V_{d'm} + \varepsilon_{d'm}), d \neq d' \end{aligned} \right]$$

ネスティッドロジットモデル(5)

□ 周辺確率

$$P(d) = \Pr \left[\begin{aligned} &V_d + \varepsilon_d + \max_{m \in \{A, R\}} (V_m + V_{dm} + \varepsilon_{dm}) \\ &\geq V_{d'} + \varepsilon_{d'} + \max_{m \in \{A, R\}} (V_m + V_{d'm} + \varepsilon_{d'm}), d \neq d' \end{aligned} \right]$$

□ 誤差項に関する仮定

- ε_{dm} : スケールパラメータ μ^m をもつIIDガンベル分布

□ $\max_{m \in \{A, R\}} (V_m + V_{dm} + \varepsilon_{dm})$ はガンベル分布に従う

- スケールパラメータ: μ^m
- ロケーションパラメータ: $V'_d = \frac{1}{\mu^m} \ln \sum_{m \in \{A, R\}} \exp\{\mu^m (V_m + V_{dm})\}$

ネスティッドロジットモデル(6)

□ 周辺確率

$$P(d) = \Pr[V_d + \varepsilon_d + V'_d + \varepsilon'_d \geq V_{d'} + \varepsilon_{d'} + V'_{d'} + \varepsilon'_{d'}, d \neq d']$$

$$\varepsilon'_d \equiv \max_{m \in \{A, R\}} (V_m + V_{dm} + \varepsilon_{dm}) - V'_d$$

□ 誤差項に関する仮定

- ε_d : $\max_{m \in \{A, R\}} U_{dm}$ がスケールパラメータ μ^d をもつガンベル分布
- $\varepsilon_d + \varepsilon'_d$ はスケールパラメータ μ^d をもつガンベル分布

□ 周辺確率

$$P(d) = \frac{\exp\{\mu^d(V_d + V'_d)\}}{\sum_{d' \in \{C, S\}} \exp\{\mu^d(V_{d'} + V'_{d'})\}} \quad V'_d = \frac{1}{\mu^m} \ln \sum_{m \in \{A, R\}} \exp\{\mu^m(V_m + V_{dm})\}$$

ネスティッドロジットモデル(7)

□ 同時選択の選択肢 dm の効用関数

$$U_{dm} = V_d + V_m + V_{dm} + \varepsilon_d + \varepsilon_m + \varepsilon_{dm}$$

□ 乗法定理

$$P(d, m) = P(m|d)P(d)$$

□ 条件付き確率 $P(m|d)$

$$P(m|d) = \Pr[U_{dm} \geq U_{dm'}, m \in \{A, R\}, m \neq m'|d] \\ = \Pr[V_m + V_{dm} + \varepsilon_{dm} \geq V_{m'} + V_{dm'} + \varepsilon_{dm'}, m \neq m'|d]$$

□ 誤差項に関する仮定

- ε_{dm} : スケールパラメータ μ^m をもつIIDガンベル分布

ネスティッドロジットモデル(8)

□ 条件付き確率 $P(m|d)$


$$P(m|d) = \frac{\exp\{\mu^m(V_m + V_{dm})\}}{\sum_{m' \in \{A, R\}} \exp\{\mu^m(V_{m'} + V_{dm'})\}}$$

□ 同時確率

$$P(d, m) = P(m|d)P(d) \\ = \frac{\exp\{\mu^m(V_m + V_{dm})\}}{\sum_{m' \in \{A, R\}} \exp\{\mu^m(V_{m'} + V_{dm'})\}} \frac{\exp\{\mu^d(V_d + V'_d)\}}{\sum_{d' \in \{C, S\}} \exp\{\mu^d(V_{d'} + V'_{d'})\}} \\ V'_d = \frac{1}{\mu^m} \ln \sum_{m \in \{A, R\}} \exp\{\mu^m(V_m + V_{dm})\}$$

ネスティッドロジットモデル(9)



誤差項の相関構造 $P(d, m) = P(m|d)P(d)$




$$\text{Var}(\varepsilon_d + \varepsilon'_d) > \text{Var}(\varepsilon_{dm}) \iff 0 \leq \frac{\mu^d}{\mu^m} \leq 1$$

ネスティッドロジットモデル(10)

NLモデルの誤差構造



ミックストロジット(MXL)モデル(1)



プロビットタイプのフレキシブルな誤差項 (Flexible error term of probit type)

IIDガンベル分布 (IID Gumbel distribution)

$$\varepsilon = \begin{bmatrix} \sigma^2_{car} & \sigma_{car,bus} & \sigma_{car,rail} \\ \sigma_{car,bus} & \sigma^2_{bus} & \sigma_{bus,rail} \\ \sigma_{car,rail} & \sigma_{bus,rail} & \sigma^2_{rail} \end{bmatrix} + \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$$

ミックストロジット(MXL)モデル(2)

$$\begin{aligned} U_{car} &= \beta X_{car} + \eta_{car} + v_{car} \\ U_{bus} &= \beta X_{bus} + \eta_{bus} + v_{bus} \\ U_{rail} &= \beta X_{rail} + \eta_{rail} + v_{rail} \end{aligned}$$

ロジットモデルの操作性 (Operability of logit model)

IIDガンベル分布 (IID Gumbel distribution)

$$\Lambda(car|\eta) = \frac{e^{\beta X_{car} + \eta_{car}}}{e^{\beta X_{car} + \eta_{car}} + e^{\beta X_{bus} + \eta_{bus}} + e^{\beta X_{rail} + \eta_{rail}}}$$

$$P(car) = \iiint_{\eta} \Lambda(car|\eta) f(\eta) d\eta$$

ηはunknown

ミックストロジット(MXL)モデル(3)

$$P(car) = \iiint_{\eta} \Lambda(car|\eta) f(\eta) d\eta$$

open-form → どうやって推定? (How to estimate?)

シミュレーション法 (Simulation method)

$$\hat{P}(car) = \frac{1}{D} \sum_{d=1}^D \frac{e^{\beta X_{car} + \eta_{car}^d}}{e^{\beta X_{car} + \eta_{car}^d} + e^{\beta X_{bus} + \eta_{bus}^d} + e^{\beta X_{rail} + \eta_{rail}^d}}$$

- Step1: 分布f(η)に従う乱数ηを発生 (Generate random numbers η following distribution f(η))
- Step2: それを用いて選択確率を計算 (Calculate choice probabilities using them)
- Step3: これをD回繰り返し選択確率の平均値を計算 (Repeat this D times and calculate the average choice probability)
- Step4: それを尤度として最尤推定法により未知パラメータを推定 (Estimate unknown parameters using maximum likelihood estimation with this as the likelihood)