

行動モデルの基礎 ～MMNLモデル～

愛媛大学
倉内慎也

kurauchi@cee.ehime-u.ac.jp

多項ロジットモデル


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

$$U(bus) = V_{bus} + \varepsilon_{bus}$$

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

$\varepsilon \sim$ IIDガンベル
独立で(Independently)
同一 (Identically) の分散を持つ
分布 (Distributed)

$$\text{Cov}(U) = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} \quad \sigma^2 = \frac{\pi^2}{6\mu^2}$$



$$f(\varepsilon) = \mu \exp\{-\mu(\varepsilon - \eta)\} \cdot \exp[-\exp\{-\mu(\varepsilon - \eta)\}]$$


$$F(\varepsilon) = \exp[-\exp\{-\mu(\varepsilon - \eta)\}]$$

多項ロジットモデル

- ◆ closed-formであるため計算が容易
 - ◆ 便益計算が簡便
- $$P(i) = \frac{\exp(\mu V_i)}{\sum_{j \in C} \exp(\mu V_j)}$$

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)



$$P(car|C) = \frac{\exp(V_{car})}{\exp(V_{car}) + \exp(V_{bus}) + \exp(V_{rail})}$$

$$P(car|A) = \frac{\exp(V_{car})}{\exp(V_{car}) + \exp(V_{bus}) + \exp(V_{rail}) + \exp(V_{walk}) + \exp(V_{bike})}$$

$$\frac{P(car|C)}{P(rail|C)} = \frac{\exp(V_{car})}{\exp(V_{rail})} = \frac{P(car|A)}{P(rail|A)}$$


選択確率の比は無関係な選択肢 (walk, bike) に影響を受けない

IIA特性の問題点(1)

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

$$U(RB) = \beta T + \varepsilon_{RB}$$

Before




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

$$U(RB) = \beta T + \varepsilon_{RB}$$


$$U(BB) = \beta T + \varepsilon_{BB}$$

After



ロジットモデル 1/3 1/3 1/3

IIA特性の問題点(2)



交差弾性値が等しい

IIA特性の問題を避けるには

◆ 誤差項間に相関が生じないようにする

- 調査等で影響要因を観測
- 確定項の関数型等の工夫

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

$$U(bus) = V_{bus} + \varepsilon_{bus}$$

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

誤差項には**確定項で説明できない要因**が含まれる

◆ 誤差相関を明示的に考慮したモデルの適用

効用関数の特定化の工夫(1)

◆ 個人間の異質性を考慮

- ◆ 個人属性をたくさん入れる/セグメンテーションを行う

$$U_{car,n} = \alpha_0 + \alpha_1 * male_n + \beta_1 T_{car,n} + \varepsilon_{car,n}$$

女性の定数項: α_0 男性の定数項: $\alpha_0 + \alpha_1$

$$U_{car,n} = \alpha_0 + \beta_1 * male_n * T_{car,n} + \beta_2 * (1 - male_n) * T_{car,n} + \varepsilon_{car,n}$$

女性のパラメータ: β_2 男性のパラメータ: β_1

$$U_{car,n}^{Group1} = \alpha_0^{Group1} + \beta_1^{Group1} T_{car,n} + \varepsilon_{car,n}^{Group1}$$

Group1のパラメータベクトル:

$$(\alpha_0^{Group1}, \beta_1^{Group1})$$


$$U_{car,n}^{Group2} = \alpha_0^{Group2} + \beta_1^{Group2} T_{car,n} + \varepsilon_{car,n}^{Group2}$$

Group2のパラメータベクトル:

$$(\alpha_0^{Group2}, \beta_1^{Group2})$$

7

効用関数の特定化の工夫(2)



	人数	バス	車		人数	鉄道	バス	車
男性	500人	20%	80%	男性	500人	10%	18%	72%
女性	500人	60%	40%	女性	500人	30%	42%	28%
合計	1,000人	40%	60%	合計	1,000人	20%	30%	50%

マーケットシェアの変化率は異なる

8

多項プロビットモデル

$$\begin{aligned}
 U(car) &= \beta X_{car} + \varepsilon_{car} \\
 U(bus) &= \beta X_{bus} + \varepsilon_{bus} \\
 U(rail) &= \beta X_{rail} + \varepsilon_{bus}
 \end{aligned}
 \quad \varepsilon \sim \text{多変量正規分布}
 \quad \begin{bmatrix} \sigma_{rail}^2 & \sigma_{bus,rail} & \sigma_{car,rail} \\ \sigma_{bus,rail} & \sigma_{bus}^2 & \sigma_{car,bus} \\ \sigma_{car,rail} & \sigma_{car,bus} & \sigma_{car}^2 \end{bmatrix}$$

多項プロビットモデル

- ◆ 中心極限定理より誤差項の仮定は尤もらしい
- ◆ open-formであるため計算負荷が大きい(J-1重積分)

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

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

ネスティッドロジット(NL)モデル(1)

$$\begin{aligned}
 U(car) &= \beta T + \varepsilon_{car} \\
 U(RB) &= \beta T + \varepsilon_{RB} \\
 U(BB) &= \beta T + \varepsilon_{BB}
 \end{aligned}
 \quad \begin{bmatrix} \text{Cov}(U) \\ \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} \quad \sigma^2 = \frac{\pi^2}{6\mu^2}$$

多項ロジットモデルの仮定: $\varepsilon \sim \text{IIDガンベル分布}$

ε_{RB} と ε_{BB} は共通の非観測属性を含んでいる

- 料金
- 快適性
- 利便性など

$$U(car) = \beta T + \alpha \text{cost}_{car} + \varepsilon'_{car} \quad \varepsilon_{car}$$

$$U(RB) = \beta T + \alpha \text{cost}_{bus} + \varepsilon'_{RB} \quad \varepsilon_{RB}$$

$$U(BB) = \beta T + \alpha \text{cost}_{bus} + \varepsilon'_{BB} \quad \varepsilon_{BB}$$

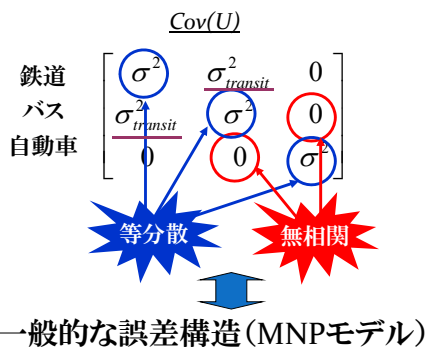

共通要因

相関



ネスティッドロジット(NL)モデル(2)

NLモデルの誤差構造



ミックストロジット(MMNL)モデル(1)

プロビットモデルの柔軟な誤差構造

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

ロジットモデルの操作性

プロビットタイプのフレキシブルな誤差項

IIDガンベル分布

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

ミックスロジット(MMNL)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

IIDガンベル分布

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

$$P(car) = \iiint_{\eta} \Lambda(car|\eta) f(\eta) d\eta \quad \leftarrow \eta \text{ は unknown}$$

ミックスロジット(MMNL)モデル(3)

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

open-form → どうやって推定?

シミュレーション法

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

- Step1: 分布f(η)に従う乱数ηを発生
- Step2: それを用いて選択確率を計算
- Step3: これをD回繰り返し選択確率の平均値を計算
- 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

ミックスロジット(MMNL)モデル(4)

Nested

$$\begin{aligned} U_{car} &= \beta X_{car} + v_{car} && \text{自動車} \\ U_{bus} &= \beta X_{bus} + \sigma_{transit} \eta_{transit} + v_{bus} && \text{バス} \\ U_{rail} &= \beta X_{rail} + \sigma_{transit} \eta_{transit} + v_{rail} && \text{鉄道} \end{aligned}$$

$\eta_{transit} \sim N(0,1)$

$$\begin{bmatrix} 0 & 0 & 0 \\ 0 & \sigma_{transit}^2 & \sigma_{transit}^2 \\ 0 & \sigma_{transit}^2 & \sigma_{transit}^2 \end{bmatrix} + \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 + \sigma_{transit}^2 & \sigma_{transit}^2 \\ 0 & \sigma_{transit}^2 & \sigma^2 + \sigma_{transit}^2 \end{bmatrix}$$

NLモデルとは違う!!

ミックスロジット(MMNL)モデル(5)

Cross-Nested

$$\begin{aligned} U_{car} &= \beta X_{car} + \sigma_{road} \eta_{road} + v_{car} && \text{自動車} \\ U_{bus} &= \beta X_{bus} + \sigma_{transit} \eta_{transit} + \sigma_{road} \eta_{road} + v_{bus} && \text{バス} \\ U_{rail} &= \beta X_{rail} + \sigma_{transit} \eta_{transit} + v_{rail} && \text{鉄道} \end{aligned}$$

$\eta_{transit}, \eta_{road} \sim N(0,1)$

$$\begin{bmatrix} \sigma_{road}^2 & \sigma_{road}^2 & 0 \\ \sigma_{road}^2 & \sigma_{transit}^2 + \sigma_{road}^2 & \sigma_{transit}^2 \\ 0 & \sigma_{transit}^2 & \sigma_{transit}^2 \end{bmatrix} + \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} = \begin{bmatrix} \sigma^2 + \sigma_{road}^2 & \sigma_{road}^2 & 0 \\ \sigma_{road}^2 & \sigma^2 + \sigma_{transit}^2 + \sigma_{road}^2 & \sigma_{transit}^2 \\ 0 & \sigma_{transit}^2 & \sigma^2 + \sigma_{transit}^2 \end{bmatrix}$$

CNLモデルとは違う!!

ミックスロジット(MMNL)モデル(6)

異分散

$$U_{car} = \beta X_{car} + \sigma_{car} \eta_{car} + v_{car}$$

$$U_{bus} = \beta X_{bus} + \sigma_{bus} \eta_{bus} + v_{bus}$$

$$U_{rail} = \beta X_{rail} + \sigma_{rail} \eta_{rail} + v_{rail}$$

$$\eta_{car}, \eta_{bus}, \eta_{rail} \sim N(0,1)$$

Identificationの問題で、一つのσは0に固定する必要あり

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

嗜好の異質性: ランダム係数モデル(2)


$$U_{car,n} = \beta_n T_{car,n} + v_{car,n}$$

$$\beta_n \sim N(\bar{\beta}, \sigma^2)$$

$$U_{car,n} = \bar{\beta} T_{car,n} + \sigma \eta_n T_{car,n} + v_{car,n}$$

$$U_{bus,n} = \bar{\beta} T_{bus,n} + \sigma \eta_n T_{bus,n} + v_{bus,n}$$

$$U_{rail,n} = \bar{\beta} T_{rail,n} + \sigma \eta_n T_{rail,n} + v_{rail,n}$$



IIDガンベル分布を仮定すればMXLモデル

$$\eta_n \sim N(0,1) \quad \bar{\beta}, \sigma : \text{unknown parameter}$$

嗜好の異質性: ランダム係数モデル(1)

$$U_{car,n} = \beta T_{car,n} + \varepsilon_{car,n}$$

βは母集団で同一⇔嗜好は母集団で同質と仮定

$$U_{car,n} = \beta_n T_{car,n} + \varepsilon_{car,n}$$

嗜好には異質性(個人差)が存在

観測異質性

非観測異質性

$$U_{car,n} = \alpha_0 + \alpha_1 * male_n + \beta_1 T_{car,n} + \varepsilon_{car,n}$$

女性の定数項: α₀ 男性の定数項: α₀ + α₁

$$U_{car,n} = \alpha_0 + \beta_1 * male_n * T_{car,n} + \beta_2 * (1 - male_n) * T_{car,n} + \varepsilon_{car,n}$$

女性のパラメータ: β₂ 男性のパラメータ: β₁

アプリオリ・マーケットセグメンテーション

$$U_{car,n}^{Group1} = \alpha_0^{Group1} + \beta_1^{Group1} T_{car,n} + \varepsilon_{car,n}^{Group1}$$

Group1のパラメータベクトル: (α₀^{Group1}, β₁^{Group1})

$$U_{car,n}^{Group2} = \alpha_0^{Group2} + \beta_1^{Group2} T_{car,n} + \varepsilon_{car,n}^{Group2}$$

Group2のパラメータベクトル: (α₀^{Group2}, β₁^{Group2})

でも、結局のところ...

- ◆ MMNLモデルもopen-formのモデル
- ◆ プロビットモデルやGEVモデルでよいのでは?
- ◆ 誤差相関を部分的かつ発見探索的に考える場合は有効
 - ◆ 対MNP: 計算負荷が少ない(特に選択肢数が多い場合)
 - ◆ 対GEV: 推定プログラムの変更が容易
- ◆ ランダム係数モデルとしての意義
 - ◆ 個人パラメータの算定, 再現性の向上

行動モデルの推定 ～シミュレーションによる推定と identificationの問題～

BESTGUY

山梨大学 佐々木邦明
愛媛大学 倉内慎也

BEhavior Study for Transportation Graduate school, Univ. of Yamanashi

モデル推定の意義

- 行動モデルにはパラメータが含まれることが多い

$$U_{in} = \beta_0 + \beta_1 time_{in} + \beta_c cost_{in} + \dots + \varepsilon_{in} = V_{in} + \varepsilon_{in}$$

$$P_n(i) = \frac{\exp(\mu V_{in})}{\sum_{j \in C} \exp(\mu V_{jn})}$$

- どのような要因が、どのような影響を及ぼすのか不明
- 現実のデータにもっとも良く適合するようにパラメータ値を決める
- これを通じて、「どのような要因が、どのような影響を及ぼすのか」等についての仮説検定

モデル推定の手順

1. モデルの選定

- ✓ ネスティッドロジットモデル

2. 効用関数の特定化

- ✓ (誤差分布のパラメータ)
- ✓ 説明変数の選定
 - 所要時間, 費用, 性別, 年齢, ...
- ✓ 効用関数の関数型

$$V_{in} = \beta_0 + \beta_1 time_{in} + \beta_c cost_{in} + \dots$$

$$V'_{in} = \beta'_0 + \beta'_1 \ln(time_{in}) + \beta'_c cost_{in} + \dots$$

3. パラメータ推定

4. 結果の考察

最尤推定法

- 点推定量を求める最もポピュラーな方法

$$L_n(\theta | x) = \prod_{i=1}^n f(x_i | \theta)$$

- 右上の式を θ の関数とみなしたものが尤度関数

データ(a, b)が得られたとき、全体の平均がいくつとするのがよいか
⇔平均がいくつだったら(a, b)が得られやすいか?

- 尤度関数を最大化する θ の値を最尤推定量とするのが最尤推定法


選択モデルの場合、 f が選択確率

↓
個人の選択確率を全員で掛け合わせる

$$MaxLikelihood = \max_{\theta \in \Theta} \prod_i P_i(x_i | \theta)$$

最大化アルゴリズムの考え方


- 対数尤度関数の段階的な最大化
 - 初期値を与える
 - 初期値周りで勾配(1次微分)等を用いて次の推定値の方向を決める
 - 初期値付近のステップサイズを1次微分, 2次微分を用いて適切に決めて次の推定値を決める
 - 収束基準(尤度関数の一階微分ベクトル)を判定し, 収束していない場合は, 現在の値を初期値として2に進む



代表的な繰り返し計算法

尤度関数を最大化: 尤度関数の一階微分=0を解く

- Newton-Raphson法
 - テイラー展開の1次近似を利用して進める
 - 解の収束が早い(ステップ数が少ない)
- 準Newton法 (BFGS法)
 - ヘッセ行列を逐次近似する.



$$\theta_{n+1} = \theta_n - H^{-1} g_1$$

H: 尤度関数の二階微分
ヘッセ行列
g: 尤度関数の一階微分



シミュレーションによる推定

ミックストロジットモデル

Nested

$$\begin{aligned}
 U_{car} &= \beta X_{car} + v_{car} && \text{自動車} \\
 U_{bus} &= \beta X_{bus} + \eta_{transit} + v_{bus} && \text{バス} \\
 U_{rail} &= \beta X_{rail} + \eta_{transit} + v_{rail} && \text{鉄道}
 \end{aligned}$$

$$\begin{matrix}
 \eta & v & \varepsilon \\
 \begin{bmatrix} 0 & 0 & 0 \\ 0 & \sigma^2_{transit} & \sigma^2_{transit} \\ 0 & \sigma^2_{transit} & \sigma^2_{transit} \end{bmatrix} + \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix} = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 + \sigma^2_{transit} & \sigma^2_{transit} \\ 0 & \sigma^2_{transit} & \sigma^2 + \sigma^2_{transit} \end{bmatrix}
 \end{matrix}$$

$$P(car) = \int \Lambda(car|\eta_{transit}) f(\eta_{transit}) d\eta_{transit}$$

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

シミュレーションによる尤度計算

$$P(car) = \int \Lambda(car|\eta_{transit}) f(\eta_{transit}) d\eta_{transit}$$

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

- Step1: 分布f(η)に従う(準)乱数ηを発生
 Step2: それを用いて選択確率を計算
 Step3: これをD回繰り返し選択確率の平均値を計算
 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


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

9

モデルの特定化とIDENTIFICATIONの問題

パラメータ推定がうまくいかない

- 収束するとは ϑ_{n+1} と ϑ_n が同じになる
 - g_1 が0になる
 - 収束しない
 - 無限に繰り返す
 - ϑ_2 が計算不能
 - 局所最適解
 - 見かけ上の最大化
- H^{-1} が存在しない(計算できない)
 - 変数が完全相関
 - 変数が効用関数に影響していない
 - 関数の近似状況
 - 2次関数近似
 - 初期値の問題
 - そもそも推定不可能
 - 推定プログラムに誤り



11

変数が完全相関

$$V_{car,n} = \alpha_0 + \alpha_1 * male_n + \alpha_2 * female_n + \beta_1 T_{car,n}$$

$$female_n = 1 - male_n$$

$$V_{car,n} = \alpha_0 + \alpha_1 * male_n + \alpha_2 * (1 - male_n) + \beta_1 T_{car,n}$$

$$= (\alpha_0 + \alpha_2) + (\alpha_1 - \alpha_2) * male_n + \beta_1 T_{car,n}$$

- 推定可能なパラメータは3つ ⇔ 未知パラメータは4つ
- 極めて相関が高い場合には推定できない場合も

そもそも推定不能

- 最大値において唯一解が求まらない可能性がある
(最大値となるパラメータベクトルが無数にある)

例

$$V_{rail} = \beta_1 + \beta_3 t_{rail} + \beta_4 c_{rail}$$

$$V_{car} = \beta_2 + \beta_3 t_{car} + \beta_4 c_{car}$$

定数項 1つは「0」に固定する

$$P(R) = \Pr[U(R) > U(C)]$$

$$= \Pr[\alpha_R + V(R) + \varepsilon_R > \alpha_C + V(C) + \varepsilon_C]$$

$$= \Pr[\varepsilon_C - \varepsilon_R < \alpha_R - \alpha_C + V(R) - V(C)]$$

これを満たす組み合わせは無数に存在

- 同様に個人属性も1つは0に固定

13

そもそも推定不能

- 1人も選択していない

例) 誰も鉄道を選択していない

$$V_{rail} = \beta_1 + \beta_3 t_{rail} + \beta_4 c_{rail}$$

$$V_{car} = \beta_3 t_{car} + \beta_4 c_{car}$$

- $\beta_1 \rightarrow -\infty$ とすれば完璧なモデル ($-\infty$ とは?)
- 同様に、ある代替案を選択した人が極めて少ない場合も危険

14

ベイズ推定

$$P(\theta | D) = \frac{P(D | \theta) P(\theta)}{P(D)}$$


事後分布

事前確率

尤度


乱数による最大値計算

- ある変数に対して乱数を発生させ、その時の関数の値を調べる
 - 単純な乱数だと効率が悪い
 - 尤度関数の値の大きさに、次のパラメータにあたりをつける
 - 尤度分布に基づく乱数を発生できれば、その頻度がパラメータの分布になる



MCMC法による推定


- Gibbs Sampling
 - 一つを除いて残りのパラメータを固定して考える
 - あるパラメータの事後分布を求め、パラメータをサンプリングする
 - 同様に事後分布から順々にサンプリング
- Metropolis-Hastings Sampling
 - あるパラメータに対する尤度を計算
 - パラメータをある方向(ランダムに)
 - 基本的には
 - 尤度が大きくなるような方向に
 - 尤度が小さくなるような方向に
 - 実際は一樣乱数との大小で採択を済
- 前の状態に基づいて(Markov Chain)新しいパラメータをランダムにサンプリング(Monte Carlo)する



平均値も計算可能

- 例
 - 平日一日の平均トリップ数が右の表のように与えられる
 - 分散の事前分布を逆ガンマ, 平均値の事前分布を正規分布とする

メトロポリス法のMCMCで平均値と分散の分布を計算してみる



6.0
8.1
7.2
3.9
4.5
2.5
6.6
4.1
2.0
5.5
続く

- この時 μ と σ の平均値は単純に平均で計算可能で5.01と2.17 (※1000まで廃棄)

ロジット・プロビットモデルのMCMC推定プログラム(兵藤2009)

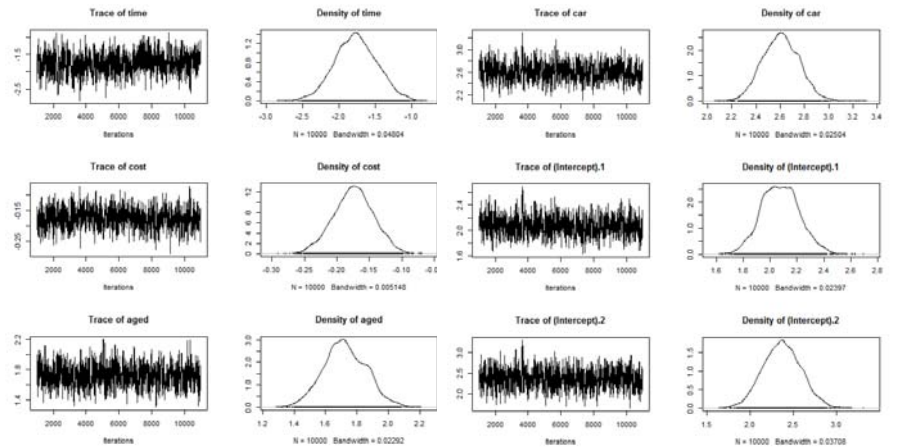
```

library(MCMCpack)
###データファイルの読み込み
Dat<-read.csv("H/2014/data.csv",header=TRUE)
hh<-nrow(Dat) ##データ数:Dataの行数を数える
rtime<-Dat[,6]/100; btime<-Dat[,9]/100; ctime<-Dat[,12]/100
rcoast<-Dat[,7]/100; bcoast<-Dat[,10]/100; ccoast<-Dat[,13]/100
raged<-matrix(0,nrow=hh,ncol=1); baged<-1*(Dat[,3]>=6); caged<-raged
rcar<-matrix(0,nrow=hh,ncol=1); bcar<-rcar; ccar<-1*(Dat[,4]>=2)
##選択結果
ch<-matrix(0,nrow=hh,ncol=3)
colnames(ch)<-c("1", "2", "3")
for (i in 1:hh)
{
  if (Dat[i,5]==0) ch[i,1]<-999
  if (Dat[i,2]==1) ch[i,1]<-1
  if (Dat[i,8]==0) ch[i,2]<-999
  if (Dat[i,2]==2) ch[i,2]<-1
  if (Dat[i,11]==0) ch[i,3]<-999
  if (Dat[i,2]==3) ch[i,3]<-1
}
post<-MCMCmcmc(
  choicevar(rtime,"time","1")+
  choicevar(btime,"time","2")+
  choicevar(ctime,"time","3")+
  choicevar(rcoast,"coast","1")+
  choicevar(bcoast,"coast","2")+
  choicevar(ccoast,"coast","3")+
  choicevar(raged,"aged","1")+
  choicevar(baged,"aged","2")+
  choicevar(caged,"aged","3")+
  choicevar(rcar,"car","1")+
  choicevar(bcar,"car","2")+
  choicevar(ccar,"car","3"),
  baseline="3", burnin=1000,
  mcmc_method="RWMC",
  bb=0, Bb=0, seed=2348,
  verbose=1000, mcmc=10000, B=0.001)
plot(post)
summary(post)
    
```

ロジット

プロビット

推定例(MHアルゴリズムでロジット)



兵藤 2009を用いた

ベイズ推定のメリットデメリット

- メリット
 - 解析的にはパラメータが求まらない複雑なモデルもパラメータ分布が求まる
 - 例: パネルデータの個人モデルを考慮した階層モデル
 - パラメータの分布がわかる
 - 多峰性の分布になったならばモデル構造を考え直す
- デメリット
 - 時間がかかる
 - MNLの推定 MCMC: 15秒 最尤推定: 7秒
 - パラメータの分布が収束しない場合もある

参考文献等

- 入門ベイズ統計学 松原望
- ベイズモデリングによるマーケティング分析 照井伸彦
- Rによる離散選択モデルの推定方法メモ 兵藤哲朗