

統計・非集計モデルの基礎

—最尤法, t値, MNL, NL—

2016/04/25(月)

スタートアップゼミ#2

B4 後藤祥孝

目次

0. 統計学の導入
1. 最尤法
2. t値の意味
3. 非集計モデルの導入
4. MNLの導出
5. NLの導出
6. まとめ

0. 統計学導入

推測統計学

ある母集団からランダムにサンプリングされたデータを用いて母集団の特性値 (=パラメータ) を推測したい

推定： パラメータが未知の時に値をデータから求める.

検定： パラメータに対して2つの仮説を立てた上でそのどちらを選ぶかを決定する.

1. 最尤法

最尤法： 推定法の1つ.

尤度関数を最大化するようなパラメータを求める.

ランダムサンプル X_i とその値 x_i が与えられたときにその生起確率は母集団の未知のパラメータ θ を用いて

$f_n(x_i; \theta)$ と表現される.

n 個のサンプル (X_1, \dots, X_n) が与えられたときそれらが同時に起こる確率は

$$\begin{aligned} f_n(x_1, \dots, x_n; \theta) &= f(x_1; \theta) \cdots f(x_n; \theta) \\ &= \prod_{i=1}^n f(x_i; \theta) \end{aligned}$$

1. 最尤法

$$\begin{aligned} f_n(x_1, \dots, x_n; \theta) &= f(x_1; \theta) \cdots f(x_n; \theta) \\ &= \prod_{i=1}^n f(x_i; \theta) \end{aligned}$$

→ x_i はデータが与えられたという意味で定数
 θ は未知パラメータ
と考えると

$$L(\theta) = f_n(\theta; x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(\theta; x_i)$$

として θ の関数 $L(\theta)$ が作られる.

1. 最尤法

得られたデータは最も起こりやすいものが起こったと考える

↓

x_i を固定して θ を動かして $L(\theta)$ が最大となる θ を求める

$L(\theta)$: 尤度関数 (θ の尤もらしさを表す関数)

$L(\theta)$ を最大化する θ : 最尤推定量

また $L(\theta)$ は積であることから対数を取り和に直されることもある.

$$\begin{aligned} l(\theta) &= \ln L(\theta) \\ &= \sum \ln f(\theta; x_i) \quad : \text{対数尤度関数} \end{aligned}$$

2. t 値の意味

- t 値 :
- ・ 推定などにより得られたパラメータをそのパラメータの推定標準偏差で除したもの
 - ・ t 値は t 分布に従う

t 検定は得られた t 値が t 分布上の棄却域に含まれているかどうかで検定を行う。

棄却域の値は求める有意水準とサンプル数によって決まる。

ex) あるパラメータが十分なサンプル数から得られたとき

t 値の絶対値が1.960を上回ると、
得られたパラメータは95%で有意となる。

3. 非集計モデルの導入

確率効用最大化モデル

- ・ 個人が利用可能な選択肢から最も望ましい選択肢を選ぶ。（離散選択，効用最大化）
- ・ 効用は選択肢特性と個人属性によって決まるが，以下のことなどにより確率的に変動する。（確率効用）
 - ・ 全てを観測するのは不可能
 - ・ 観測誤差の存在
 - ・ 行動者の認知誤差
 - ・ 効用の関数形による誤差

以上のことから効用を定式化すると・・・

3. 非集計モデルの導入

$$U_{in} = \underbrace{\beta_1 x_{1in} + \beta_2 x_{2in} + \cdots + \beta_K x_{Kin}} + \varepsilon_{in}$$
$$= \underbrace{V_{in}}_{\text{確定項}} + \underbrace{\varepsilon_{in}}_{\text{確率項}}$$

U_{in} : 確率効用

V_{in} : 個人nの選択肢iに対する効用の確定部分

β_k : k番目の未知パラメータ

x_{kin} : 個人nの選択肢iに対するk番目の説明変数

ε_{in} : 効用の確率項

3. 非集計モデルの導入

2項選択モデル

$$\begin{aligned} P_n(i) &= \Pr[U_{in} \geq U_{jn}] \\ &= \Pr[V_i + \varepsilon_i \geq V_j + \varepsilon_j] \\ &= \Pr[\varepsilon_i = \varepsilon, \varepsilon_j \leq \rho + V_i - V_j], -\infty < \varepsilon < \infty \end{aligned}$$

ε_i がどのような確率分布に従うかによって
 $P_n(i)$ の式は異なる.

プロビットモデル

中心極限定理によって正規分布を仮定する.

しかし, 選択確率に積分形が残ってしまい計算負荷が重い.

(5/16に説明予定)

→ロジットモデルの導入

4. MNL

ロジットモデル

- 誤差項 ε_i にガンベル分布を仮定
- 選択確率の式に積分形が残らない（クローズドフォーム）

ガンベル分布

- 累積分布関数

$$F(\varepsilon) = \exp(-\exp(-\mu(\varepsilon - \eta)))$$

- 確率密度関数

$$f(\varepsilon) = F'(\varepsilon) = \mu \exp(-\mu(\varepsilon - \eta)) \exp(-\exp(-\mu(\varepsilon - \eta)))$$


μ :スケールパラメータ (ε のばらつきの程度)

η :ロケーションパラメータ (分布の位置 (=最頻値))

平均: $\eta + \gamma/\mu$

分散: $\pi^2/6\mu^2$

($\gamma \approx 0.577$: オイラー定数)



4. MNL

ガンベル分布の性質

$$F(\varepsilon) = \exp(-\exp(-\mu(\varepsilon - \eta)))$$

$$f(\varepsilon) = \mu \exp(-\mu(\varepsilon - \eta)) \exp(-\exp(-\mu(\varepsilon - \eta)))$$

性質 1 : $\varepsilon_1, \varepsilon_2$ が $(\eta_1, \mu), (\eta_2, \mu)$ のガンベル分布に従うとき,
 $\varepsilon = \varepsilon_1 - \varepsilon_2$ は以下のロジスティック分布に従う.

$$F(\varepsilon) = \frac{1}{1 + \exp(\mu(\eta_2 - \eta_1 - \varepsilon))}$$

性質 2 : $\varepsilon_1, \dots, \varepsilon_i, \dots, \varepsilon_I$ がそれぞれ (η_i, μ) に従うとき,
最大値 $\max(\varepsilon_1, \dots, \varepsilon_I)$ はガンベル分布に従う
パラメータ: $(\frac{1}{\mu} \ln \sum_{i=1}^I \exp(\mu\eta_i), \mu)$

4. MNL

2項ロジットモデル続き (簡単のため $\eta = 0, \mu = 1$ とする)

確率項の累積分布関数

$$\begin{aligned}\psi(\varepsilon) &= \Pr[\varepsilon_1 \leq \varepsilon] \\ &= \exp[\exp(-\varepsilon)]\end{aligned}$$

を適用すると

$$\begin{aligned}P_n(i) &= \Pr[\varepsilon_1 = \varepsilon, \varepsilon_2 < \varepsilon + V_1 - V_2], -\infty < \varepsilon < \infty \\ &= \Pr[\varepsilon_1 = \varepsilon] \Pr[\varepsilon_2 < \varepsilon + V_1 - V_2] \\ &= \int_{-\infty}^{\infty} \psi'(\varepsilon) \psi(\varepsilon + V_1 - V_2) d\varepsilon \\ &= \int_{-\infty}^{\infty} \exp(\varepsilon) \underbrace{\psi(\varepsilon) \psi(\varepsilon + V_1 - V_2)}_{= y \text{ と置く}} d\varepsilon\end{aligned}$$

4. MNL

すると

$$y = \exp[-\exp(-\varepsilon)(1 + \exp(V_2 - V_1))]$$

$$\frac{dy}{d\varepsilon} = y \exp(-\varepsilon)(1 + \exp(V_2 - V_1))$$

より

$$\begin{aligned} P_n(i) &= \int_{-\infty}^{\infty} y \exp(\varepsilon) d\varepsilon \\ &= \int_0^1 \frac{y \exp(\varepsilon)}{y \exp(\varepsilon)(1 + \exp(V_2 - V_1))} dy \\ &= \left[\frac{y}{1 + \exp(V_2 - V_1)} \right]_0^1 \\ &= \frac{1}{1 + \exp(V_2 - V_1)} \\ &= \frac{\exp(V_1)}{\exp(V_1) + \exp(V_2)} \end{aligned}$$

4. MNL

多項ロジットの導出

$$\begin{aligned} P_n(i) &= \Pr[U_{in} > U_{jn}, j \in J_n, i \neq j] \\ &= \Pr[V_{in} + \varepsilon_{in} > V_{jn} + \varepsilon_{jn}, j \in J_n, i \neq j] \\ &= \Pr[V_{in} + \varepsilon_{in} > \underbrace{\max_j (V_{jn} + \varepsilon_{jn})}_{j}, i \neq j] \end{aligned}$$

i以外の選択肢の中で最大の効用を与えるものよりもiの効用が大きい。

ガンベル分布の性質2より

$\max_j U_{jn} = U_n^*$ とすると

U_n^* は $\left(\frac{1}{\mu} \ln \sum_{j \in J_n} \exp(\mu V_{jn}), \mu\right)$ のガンベル分布に従う。

$U_n^* = V_n^* + \varepsilon_n^*$ とし $V_n^* = \frac{1}{\mu} \ln \sum \exp(\mu V_{jn})$ とおく。

$\Rightarrow \varepsilon_n^*$ はパラメータ $(0, \mu)$ のガンベル分布に従う。

4. MNL

$$\begin{aligned} P_n(i) &= \Pr[V_{in} + \varepsilon_{in} \geq V_n^* + \varepsilon_n^*] \\ &= \Pr[\varepsilon_{in} - \varepsilon_n^* \geq V_n^* - V_{in}] \\ &= \frac{1}{1 + \exp(\mu(V_n^* - V_{in}))} \\ &= \frac{\exp(\mu V_{in})}{\exp(\mu V_{in}) + \exp(\mu V_n^*)} \\ &= \frac{\exp(\mu V_{in})}{\exp(\mu V_{in}) + \exp(\mu \cdot \frac{1}{\mu} \ln \sum_{j \neq i} \exp(\mu V_{jn}))} \\ &= \frac{\exp(\mu V_{in})}{\exp(\mu V_{in}) + \sum_{j \neq i} \exp(\mu V_{jn})} \\ &= \frac{\exp(\mu V_{in})}{\sum \exp(\mu V_{jn})} \end{aligned}$$

ガンベル分布の
性質 1 より

4. MNL

IIA特性 (Independence of Irrelevant Alternative)

- 「選択確率比の文脈独立」とも呼ばれる。
- 無関係な選択肢から選択確率が独立であること。
- 例えば $\frac{P_{in}}{P_{jn}} = \exp(V_{in} - V_{jn})$ となり選択肢 i, j の効用確定項のみから決まり, i, j 以外の選択肢から影響を受けない。

○長所

選択肢集合に含まれる全ての選択肢ではなく, 部分集合を用いて推定しても推定値にバイアスが生じない。

×短所


類似した選択肢が存在し, 誤差項が独立であるという仮定が誤っているとき, 類似した選択肢の選択確率が過大になってしまう。

=> 赤バス・青バス問題


4. MNL

赤バス・青バス問題

車・赤バス：効用の確定項が全く同じ
が選択肢として存在する場合，選択確率は



青バス：車・赤バスと効用の確定項が全く同じ
を先ほどの選択肢に加えて導入すると，選択確率は



バス全体で効用は変化
しないため

$\frac{1}{2}$, $\frac{1}{4}$, $\frac{1}{4}$
が正しいのでは？

5. NL

MNLのIIA特性を緩和したい.

→ すなわち, 効用の誤差項に相関のありそうな場合について考えたい


Ex)目的地と交通手段の組み合わせの選択問題



選択肢が {市街地, 車} {市街地, バス} {郊外, 車} {郊外, バス} とすれば, 交通手段を選択するネストで誤差項の相関が生まれる.

→NL(Nested Logit)モデルの導入

5. NL



上位ネストの選択肢： d

下位ネストの選択肢： i

として下位ネストの選択肢間に誤差項の相関があると考える。

5. NL

選択肢 d i の組み合わせの効用は


$$U_{di} = V_d + V_i + V_{di} + \varepsilon_d + \varepsilon_{di}$$

(個人を表す n の添え字は省略)

- U_{di} : 選択肢 d i の組み合わせによる効用
- V_d : 選択肢 d による効用の確定項
- V_i : 選択肢 i による効用の確定項
- V_{di} : 選択肢 d i の組み合わせによる効用の確定項
- ε_d : 選択肢 d による効用の確率項 ($\max(U_{di})$ がスケールパラメータ μ_d を持つガンベル分布になるような分布に従うと仮定
- ε_{di} : 選択肢 d i による効用の確率項 (スケールパラメータ μ を持つ互いに独立なガンベル分布に従うと仮定

選択肢 d i の選択確率は条件付き確率を用いて

$$P(d, i) = P(d|i) \cdot P(d)$$



上位ネストの選択肢: d
下位ネストの選択肢: i
として下位ネストの選択肢間に誤差項の相関があると考える.

5. NL

$$P(d) = \Pr \left[\underbrace{\max_i U_{di}} > \underbrace{\max_{i, d' \neq i} U_{d'i}} \right]$$

dを選んだ時の
最大効用

d'を選んだ時の
最大効用

$$\begin{aligned} &= \Pr[V_d + \varepsilon_d + \max_i (V_i + V_{di} + \varepsilon_{di}) \\ &\quad \geq V_{d'} + \varepsilon_{d'} + \max_{i, d' \neq d} (V_i + V_{d'i} + \varepsilon_{d'i}), d' \neq d] \end{aligned}$$

ε_{di} の分布の仮定により

$\max_i (V_i + V_{di} + \varepsilon_{di})$ はスケールパラメータ μ のガンベル分布に従う

⇒ ガンベル分布のロケーションパラメータ V'_d とすると

$$V'_d = \frac{1}{\mu} \ln \sum (\exp(\mu(V_i + V_{di})))$$

ログサム変数

5. NL

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

$(\varepsilon'_d \equiv \max_i (V_i + V_{di} + \varepsilon_{di}) - V'_d \text{ とした})$

⇒ 確定項 $V_d + V'_d$, 誤差項 $\varepsilon_d + \varepsilon'_d$

の離散選択問題

ε_d : 確率式内の不等式の左辺の確率項がスケールパラメータ μ_d のガンベル分布に従うように仮定

⇒ 周辺確率 $P(d)$ は

$$P(d) = \frac{\exp(\mu_d(V_d + V'_d))}{\sum_{d'} \exp(\mu_d(V_{d'} + V'_{d'}))}$$

5. NL

$$\begin{aligned} P(i|d) &= \Pr[U_{di} \geq U_{di'}, i' \neq i | d] \\ &= \Pr[V_i + V_{di} + \varepsilon_{di} \geq V_{i'} + V_{di'} + \varepsilon_{di'}, i' \neq i] \end{aligned}$$

スケールパラメータ μ の
ガンベル分布に従う

$$P(i|d) = \frac{\exp(\mu(V_i + V_{di}))}{\sum_i \exp(\mu(V_i + V_{di}))}$$

5. NL

ここまでの $P(i|d)$, $P(d)$ の結果を用いて

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

$$= \frac{\exp(\mu(V_i + V_{di}))}{\sum_i \exp(\mu(V_i + V_{di}))} \cdot \frac{\exp(\mu_d(V_d + V'_d))}{\sum_d \exp(\mu_d(V_d + V'_d))}$$

6. まとめ

最尤法, t 値とモデルの関係 (MNLを例に)

- MNLによって選択確率と効用の関係が表現された.
- データは各個人の選択結果と説明変数の値.
- 求めたいのは説明変数に対するパラメータ.

個人 n の選択肢 i の効用確定項と選択確率を次のように表す.

$$V_{in} = \sum_{k=1}^K \theta_k X_{ink}$$
$$P_{in} = \frac{\exp(V_{in})}{\sum_{j \in J_n} \exp(V_{jn})}$$

6. まとめ

θ_k を求めるための尤度関数は次のようになる。

$$L(\theta_1, \dots, \theta_K) = \prod_{n=1}^N \prod_{i \in I_n} P_{in}^{\delta_{in}}$$

δ_{in} は個人 n が i を選択している場合1, そうでなければ0

対数尤度関数にすると

$$\begin{aligned} l(\theta_1, \dots, \theta_K) &= \ln L(\theta_1, \dots, \theta_K) \\ &= \sum_{n=1}^N \sum_{i \in I_n} \delta_{in} \ln(P_{in}) \end{aligned}$$

この式の最大化を考えてパラメータを求める。

6. まとめ

t 値を求めてパラメータの検定を行う。
→推定値 θ の推定標準偏差を求める必要がある。

推定値 θ の母分散共分散行列の推定値はヘッセ行列に推定値 θ を代入した値に等しくなることを利用する。

推定値 θ'_k の母分散共分散行列

k 番目の要素 θ'_k の母分散 $E(\theta'_k - \theta_k)^2$ を k 番目の対角要素
 θ'_k と θ'_l の母共分散 $E(\theta'_k - \theta_k)(\theta'_l - \theta_l)$ を (k, l) 要素とする行列

ヘッセ行列

$L(\theta_1, \dots, \theta_K)$ に対して $\frac{\partial L}{\partial \theta_k \partial \theta_l}$ を (k, l) 要素に持つ行列