

確率・統計 B

標本分布・推定

若木宏文

wakaki@hiroshima-u.ac.jp

<http://home.hiroshima-u.ac.jp/wakaki/lecture/probstatB17/index.shtml>

2017.11.1

table of contents

順序統計量

点推定

最小 2 乗法と単回帰モデル

順序統計量 (1/7)

定義 6.12

X_1, \dots, X_n を大きさ n のランダム標本とする. これを大きさの順に並べて $X_{(1)} \leq \dots \leq X_{(n)}$ とするとき

$$X_{(1)}, \dots, X_{(n)}$$

をこの標本の順序統計量といい, $X_{(i)}$ を第 i 順序統計量とよぶ.

例. $n = 4$, X_1, X_2, X_3, X_4 の実現値が

$$X_1 = 3, X_2 = 4, X_3 = 1, X_4 = 5$$

$$\Rightarrow X_{(1)} = 1, X_{(2)} = 3, X_{(3)} = 4, X_{(4)} = 5$$

順序統計量 (2/7)

ランダム標本の特性量

(1) 標本メディアン (中央値)

$$\tilde{X} = \begin{cases} X_{(k)} & n = 2k - 1 \\ (X_{(k)} + X_{(k+1)})/2 & n = 2k \end{cases}$$

(2) 標本範囲

$$R = X_{(n)} - X_{(1)}$$

(3) 標本中点

$$(X_{(1)} + X_{(n)})/2$$

(4) $100\alpha\%$ 調整平均

$$\frac{1}{n - 2k} \sum_{i=k+1}^{n-k} X_{(i)}, \quad k = [n\alpha]$$

($[a]$ は a を超えない最大の整数, ガウス記号と呼ばれる)

順序統計量 (3/7)

命題 1 (最大値・最小値の分布)

$F(x)$: 母集団分布の分布関数

$f(x)$: 母集団分布の確率密度関数 (連続型の場合)

(1) $X_{(n)} = \max\{X_1, \dots, X_n\}$ の分布関数と確率密度関数

$$G_n(y) = P(X_{(n)} \leq y) = \{F(y)\}^n,$$

$$g_n(y) = \frac{d}{dy}G_n(y) = nf(y)\{F(y)\}^{n-1}$$

(2) $X_{(1)} = \min\{X_1, \dots, X_n\}$ の分布関数と確率密度関数

$$G_1(y) = P(X_{(1)} \leq y) = 1 - \{1 - F(y)\}^n,$$

$$g_1(y) = \frac{d}{dy}G_1(y) = nf(y)\{1 - F(y)\}^{n-1}$$

(証明は板書で)

メモ用紙

メモ用紙

順序統計量 (4/7)

定理 6.11 (順序統計量の分布)

$F(x)$: 母集団分布の分布関数

$f(x)$: 母集団分布の確率密度関数 (連続型の場合)

$$(1) \quad P(X_{(i)} \leq y) = \sum_{k=i}^n \frac{n!}{k!(n-k)!} \{F(y)\}^k \{1 - F(y)\}^{n-k}.$$

(2) $g_i(y)$: $X_{(i)}$ の確率密度関数

$$g_i(y) = \frac{n!}{(i-1)!(n-i)!} \{F(y)\}^{i-1} \{1 - F(y)\}^{n-i} f(y).$$

順序統計量 (5/7)

定理 6.11 (順序統計量の分布 (つづき))

(3) $i < j$, $y_i \leq y_j$ のとき

$$\begin{aligned} & P(X_{(i)} \leq y_i, X_{(j)} \leq y_j) \\ &= \sum_{k=j}^n \sum_{l=i}^k \frac{n! \{F(y_i)\}^l \{F(y_j) - F(y_i)\}^{k-l} \{1 - F(y_j)\}^{n-k}}{l!(k-l)!(n-k)}. \end{aligned}$$

(4) $g_{ij}(y_i, y_j) : (X_{(i)}, X_{(j)})$ の同時確率密度関数
 $y_i < y_j$ のとき

$$\begin{aligned} & g_{ij}(y_i, y_j) \\ &= \frac{n! F(y_i)^{i-1} \{F(y_j) - F(y_i)\}^{j-i-1} \{1 - F(y_i)\}^{n-j} f(y_i) f(y_j)}{(i-1)!(j-i-1)!(n-j)!} \end{aligned}$$

順序統計量 (6/7)

定理 6.11 の証明 (1) と (2) のみ

$$\begin{aligned} P(X_{(i)} \leq y) &= P(X_1, \dots, X_n \text{ のうち少なくとも } i \text{ 個が } y \text{ 以下}) \\ &= \sum_{k=i}^n P(X_1, \dots, X_n \text{ のうち丁度 } k \text{ 個が } y \text{ 以下}) \\ &= \sum_{k=i}^n \frac{n!}{k!(n-k)!} \{F(y)\}^k \{1-F(y)\}^{n-k} \\ g_i(y) &= \frac{d}{dy} \sum_{k=i}^n \frac{n!}{k!(n-k)!} \{F(y)\}^k \{1-F(y)\}^{n-k} \\ &= \sum_{k=i}^n \frac{n!}{k!(n-k)!} \{k \{F(y)\}^{k-1} \{1-F(y)\}^{n-k} \\ &\quad - (n-k) \{F(y)\}^k \{1-F(y)\}^{n-k-1}\} f(y) \end{aligned}$$

順序統計量 (7/7)

定理 6.11 の証明 (続き)

$$\begin{aligned} &= \sum_{k=i}^n \frac{n}{(k-1)!(n-k)!} \{F(y)\}^{k-1} \{1-F(y)\}^{n-k} f(y) \\ &\quad - \sum_{k=i}^{n-1} \frac{n}{k!(n-k-1)!} \{F(y)\}^k \{1-F(y)\}^{n-k-1} f(y) \\ &= \sum_{\ell=i-1}^{n-1} \frac{n}{\ell!(n-\ell-1)!} \{F(y)\}^{\ell} \{1-F(y)\}^{n-\ell-1} f(y) \\ &\quad - \sum_{k=i}^{n-1} \frac{n}{k!(n-k-1)!} \{F(y)\}^k \{1-F(y)\}^{n-k-1} f(y) \\ &= \frac{n}{(i-1)!(n-i)!} \{F(y)\}^{i-1} \{1-F(y)\}^{n-i} f(y) \end{aligned}$$

7. 推定

点推定 (1/7)

$\mathbf{X} = (X_1, \dots, X_n)$: 標本変量 (確率変数)

$\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$: 統計モデル

$$\mathbf{X} \sim P \in \mathcal{P}$$

$f(\mathbf{x}; \theta)$: P_θ の確率密度関数 (確率関数)

$$\mathcal{X} = \{\mathbf{x} = (x_1, \dots, x_n \mid f(\mathbf{x}; \theta)) > 0\}$$

パラメータ $\gamma = \gamma(\theta)$ の点推定 :

各 $\mathbf{x} \in \mathcal{X}$ に γ の推定値 $\hat{\gamma} = \hat{\gamma}(\mathbf{x})$ を対応させる方法

$\hat{\gamma}(\mathbf{x})$: 推定値, $\hat{\gamma}(\mathbf{X})$: 推定量

点推定 (2/7)

例 7.1

 $X_1, \dots, X_{10} \stackrel{i.i.d.}{\sim} B(1, \theta), \theta \in (0, 1)$

$$(1) \hat{\theta}_1 = (X_1 + \dots + X_{10})/10$$

$$(2) \hat{\theta}_2 = 1/2$$

$$(3) \hat{\theta}_3 = X_1$$

例 7.2

繰り返し測定モデル $X_i = \mu + \varepsilon_i, (i = 1, \dots, n)$

 $\varepsilon_1, \dots, \varepsilon_n \stackrel{i.i.d.}{\sim} \varepsilon, \mathbf{E}(\varepsilon) = 0, \mathbf{Var}(\varepsilon) = \sigma^2$ $\theta = (\mu, \sigma^2)$

$$(1) \gamma(\theta) = \mu : \hat{\mu} = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$$(2) \gamma(\theta) = \sigma^2 : \hat{\sigma}^2 = S_n = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

点推定 (3/7)

良さの基準

- (1) 偏り: $\text{Bias}(\hat{\gamma}) = E(\hat{\gamma}) - \gamma.$
- (2) 分散: $\text{Var}(\hat{\gamma}) = E[\{\hat{\gamma} - E(\hat{\gamma})\}^2].$
- (3) 平均 2 乗誤差: $\text{MSE}(\hat{\gamma}) = E\{(\hat{\gamma} - \gamma)^2\}.$
- (4) 集中確率: $P(|\hat{\gamma} - \gamma| \leq a), \quad a > 0.$
- (5) 一致性: $n \rightarrow \infty$ のとき, $\hat{\gamma} \xrightarrow{p} \gamma.$

平均 2 乗誤差, 分散, 偏りの 2 乗の間の関係 :

$$\text{MSE}(\hat{\gamma}) = E[\{\hat{\gamma} - E(\hat{\gamma}) + E(\hat{\gamma}) - \gamma\}^2] = \text{Var}(\hat{\gamma}) + \text{Bias}(\hat{\gamma})^2.$$

点推定 (4/7)

定義 7.1

$\hat{\gamma} = \hat{\gamma}(\mathbf{X})$: パラメータ $\gamma = \gamma(\theta)$ の推定量

- (1) $\forall \theta \in \Theta$ に対して, $E(\hat{\gamma}) = \gamma$ となるとき, $\hat{\gamma}$ は**不偏推定量**であるという.
- (2) γ の不偏推定量が存在するとき, γ は**推定可能**であるという.
- (3) γ の不偏推定量 $\hat{\gamma}$ が, 任意の不偏推定量 $\tilde{\gamma}$ に対して

$$\forall \theta \in \Theta \text{ に対して, } \text{Var}_{\theta}(\hat{\gamma}) \leq \text{Var}_{\theta}(\tilde{\gamma})$$

を満たすとき, $\hat{\gamma}$ は γ の**一様最小分散不偏推定量** (UMVUE: Uniformly Minimum Variance Unbiased Estimator) であるという.

点推定 (5/7)

例 7.3 (例 7.1 の続き)

$$(1) E(\hat{\theta}_1) = \theta, \text{Var}(\hat{\theta}_1) = \theta(1 - \theta)/10.$$

$$(2) E(\hat{\theta}_2) = 1/2, \text{Var}(\hat{\theta}_2) = 0.$$

$$(3) E(\hat{\theta}_3) = \theta, \text{Var}(\hat{\theta}_3) = \theta(1 - \theta).$$

点推定 (6/7)

例 7.4

 $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} X, E(X) = \mu, \text{Var}(X) = \sigma^2$ (1) μ の推定

$$\hat{\mu}_{\mathbf{c}} = c_1 X_1 + \dots + c_n X_n$$

$$E(\hat{\mu}_{\mathbf{c}}) = c_1 \mu + \dots + c_n \mu = (c_1 + \dots + c_n) \mu$$

$\hat{\mu}_{\mathbf{c}}$ が不偏であるための必要十分条件は $c_1 + \dots + c_n = 1$

$$\text{Var}(\hat{\mu}_{\mathbf{c}}) = (c_1^2 + \dots + c_n^2) \sigma^2.$$

条件 $c_1 + \dots + c_n = 1$ のもとで $c_1^2 + \dots + c_n^2$ が最小となるのは

$$c_1 = \dots = c_n = \frac{1}{n}$$

メモ用紙

点推定 (7/7)

例 7.4 (続き)

(2) σ^2 の推定

標本分散 $S_n^2 = (n-1)^{-1} \sum_{i=1}^n (X_i - \bar{X})^2$ は σ^2 の不偏推定量

$$E \left\{ \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right\} = \frac{n-1}{n} \sigma^2$$

$n^{-1} \sum_{i=1}^n (X_i - \bar{X})^2$ は σ^2 の不偏推定量ではない。

最小 2 乗法と単回帰モデル (1/8)

最小 2 乗法 モデル

$$y_i = g_i(\theta_1, \dots, \theta_p) + \varepsilon_i, \quad i = 1, \dots, n$$

g_i : 既知関数

$\boldsymbol{\theta} = (\theta_1, \dots, \theta_p)'$: パラメータ

$\varepsilon_1, \dots, \varepsilon_n$: 誤差, 互いに独立で, 平均 0, 分散 σ^2

$$\text{残差平方和 : } \sum_{i=1}^n \{y_i - g_i(\theta_1, \dots, \theta_p)\}^2$$

を最小にするような $\boldsymbol{\theta} = \hat{\boldsymbol{\theta}}$ を求める方法を**最小 2 乗法**, $\hat{\boldsymbol{\theta}}$ を**最小 2 乗推定量**という

最小 2 乗法と単回帰モデル (2/8)

単回帰モデル

$(y_1, x_1), \dots, (y_n, x_n)$: データ

$$y_i = \alpha + \beta x_i + \varepsilon_i, \quad i = 1, \dots, n$$

を単回帰モデルと呼ぶ.

仮定

- (1) (α, β) : 未知パラメータ
- (2) x_1, \dots, x_n : 既知定数
- (3) $\varepsilon_1, \dots, \varepsilon_n$: 互いに独立な確率変数
- (4) $E(\varepsilon_i) = 0, \text{Var}(\varepsilon_i) = \sigma^2, i = 1, \dots, n$

y_i を目的変数 (応答変数), x_i を説明変数, β を回帰係数 と呼ぶ

最小 2 乗法と単回帰モデル (3/8)

残差平方和

$$Q(\alpha, \beta) = \sum_{i=1}^n \{y_i - \alpha - \beta x_i\}^2$$

(α, β) の最小 2 乗推定量は

$$\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}, \quad \hat{\beta} = \frac{s_{xy}}{s_x^2},$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i,$$

$$s_{xy} = \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}), \quad s_x^2 = s_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2,$$

最小 2 乗法と単回帰モデル (4/8)

証明

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}, \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \boldsymbol{\theta} = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}$$

とおくと,

$$\begin{aligned} Q(\alpha, \beta) &= \|\mathbf{Y} - \mathbf{X}\boldsymbol{\theta}\|^2 \\ &= \|\mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} + \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} - \mathbf{X}\boldsymbol{\theta}\|^2 \\ &= \|\mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}\|^2 + \|\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} - \mathbf{X}\boldsymbol{\theta}\|^2 \\ &\quad + 2\mathbf{Y}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{X}\{(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} - \boldsymbol{\theta}\} \\ &= \|\mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}\|^2 + \|\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} - \mathbf{X}\boldsymbol{\theta}\|^2 \end{aligned}$$

 $\boldsymbol{\theta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$ で最小となる.

最小 2 乗法と単回帰モデル (5/8)

$$\begin{aligned}
 (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} &= \begin{pmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i y_i \end{pmatrix} \\
 &= \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{pmatrix} \sum_{i=1}^n x_i^2 & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & n \end{pmatrix} \begin{pmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i y_i \end{pmatrix} \\
 &= \frac{1}{\sum_{i=1}^n x_i^2 - n(\bar{x})^2} \begin{pmatrix} \sum_{i=1}^n x_i^2 & -n\bar{x} \\ -n\bar{x} & n \end{pmatrix} \begin{pmatrix} \bar{y} \\ \frac{1}{n} \sum_{i=1}^n x_i y_i \end{pmatrix} \\
 &= \frac{1}{s_{ss}} \begin{pmatrix} \bar{y}(s_{xx} + n\bar{x}^2) - \bar{x} \sum_{i=1}^n x_i y_i \\ \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \end{pmatrix} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \end{pmatrix}
 \end{aligned}$$

$$\therefore s_{xx} = \sum_{i=1}^n x_i^2 - n\bar{x}^2, \quad s_{xy} = \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}$$

最小 2 乗法と単回帰モデル (6/8)

定理 7.1

$$(1) E(\hat{\alpha}) = \alpha, E(\hat{\beta}) = \beta$$

$$(2) \text{Var}(\hat{\alpha}) = \sigma^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{s_{xx}} \right), \quad \text{Var}(\hat{\beta}) = \frac{\sigma^2}{s_{xx}}, \quad \text{Cov}(\hat{\alpha}, \hat{\beta}) = -\frac{\sigma^2 \bar{x}}{s_{xx}}$$

補題 1

確率行列 $\mathbf{X} = (X_{ij})$ ($m \times n$) の平均は、次のように定義される。

$$E(\mathbf{X}) = \begin{pmatrix} E(X_{11}) & \cdots & E(X_{1n}) \\ \vdots & & \vdots \\ E(X_{m1}) & \cdots & E(X_{mn}) \end{pmatrix}$$

\mathbf{A} ($p \times m$), \mathbf{B} ($n \times q$), \mathbf{C} ($p \times q$) を定数行列とすると,
 $E(\mathbf{AXB} + \mathbf{C}) = \mathbf{AE}(\mathbf{X})\mathbf{B} + \mathbf{C}$ が成り立つ。

(証明は板書で)

最小 2 乗法と単回帰モデル (7/8)

定理 7.1 の証明

$$\hat{\boldsymbol{\theta}} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \end{pmatrix}, \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

とおくと,

$$E[\mathbf{Y}] = E[\mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}] = \mathbf{X}\boldsymbol{\theta}$$

$$E[\hat{\boldsymbol{\theta}}] = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\boldsymbol{\theta} = \boldsymbol{\theta}$$

$$\begin{aligned} & E[(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})'] \\ &= E[\{(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}) - \boldsymbol{\theta}\}\{(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}) - \boldsymbol{\theta}\}'] \\ &= E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}] \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}(\sigma^2\mathbf{I}_n)\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1} \\ &= \frac{\sigma^2}{nS_{xx}} \begin{pmatrix} \sum_{i=1}^n x_i^2 & -n\bar{x} \\ -n\bar{x} & n \end{pmatrix} \end{aligned}$$

最小 2 乗法と単回帰モデル (8/8)

定理 7.2 (ガウス–マルコフの定理)

単回帰モデル $y_i = \alpha + \beta x_i + \varepsilon_i$ ($i = 1, \dots, n$)
において

$$E(\varepsilon_i) = 0, \quad \text{Var}(\varepsilon_i) = \sigma^2, \quad \text{Cov}(\varepsilon_i, \varepsilon_j) = 0 \quad (i \neq j = 1, \dots, n)$$

とする. 定数 l_1, l_2 に対して

- (1) $\hat{\theta} = l_1 \hat{\alpha} + l_2 \hat{\beta}$ は, $\theta = \theta(\alpha, \beta) = l_1 \alpha + l_2 \beta$ の線形不偏推定量
- (2) 任意の θ の線形不偏推定量 $\tilde{\theta}$ に対して

$$\text{Var}(\hat{\theta}) \leq \text{Var}(\tilde{\theta})$$

注. ここでの線形不偏推定量とは, y_1, \dots, y_n の一次結合 $a_1 y_1 + \dots + a_n y_n$ で, θ の不偏推定量となるもののこと.

(証明は省略. テキスト 9 章を参照)