

# 確率・統計 B 標本分布・推定

若木宏文

wakaki@math.sci.hiroshima-u.ac.jp

2013.12.18

## table of contents

最小 2 乗法と単回帰モデル

一様最小分散推定量

十分統計量

最尤法

復習

# 最小 2 乗法と単回帰モデル (1/7)

## 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

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

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

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  $\theta = \hat{\theta}$  を求める方法を **最小 2 乗法**,  $\hat{\theta}$  を **最小 2 乗推定量** という

# 一様最小分散不偏推定量 (7/10, 8/10 より)

## 定理 7.3 (クラーメルーラオの不等式)

$$\mathbf{X} = (X_1, \dots, X_n) \sim P \in \{P_{\theta} \mid \theta \in \Theta\}, \quad \Theta \subset \mathbb{R}^p$$

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

$\gamma(\theta)$  : 微分可能な関数 (推定したい値)

$\gamma(\theta)$  の任意の不偏推定量  $\hat{\gamma}(\mathbf{X})$  に対して

$$\text{Var}\{\hat{\gamma}(\mathbf{X})\} \geq \dot{\gamma}(\theta)' J(\theta)^{-1} \dot{\gamma}(\theta)$$

が成り立つ. (等号が成立するとき **有効推定量** という.)

ただし,  $\dot{\gamma}(\theta) = \partial \gamma(\theta) / \partial \theta$ ,  $J(\theta)$  は **フィッシャー情報量行列** :

$$J(\theta) = E_{\theta} \left[ \left\{ \frac{\partial}{\partial \theta} \log f(\mathbf{X}, \theta) \right\} \left\{ \frac{\partial}{\partial \theta} \log f(\mathbf{X}, \theta) \right\}' \right]$$

# 一様最小分散不偏推定量 (9/10)

## 例 7.5 (単回帰モデル)

$$y_i = \beta_0 + \beta_1(x_i - \bar{x}) + \varepsilon_i, \quad i = 1, \dots, n$$

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon},$$

$$\mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, X = \begin{pmatrix} 1 & x_1 - \bar{x} \\ \vdots & \vdots \\ 1 & x_n - \bar{x} \end{pmatrix}, \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}$$

※.  $\boldsymbol{\beta}$  の最小 2 乗推定量は,  $\hat{\boldsymbol{\beta}} = (X'X)^{-1}X'\mathbf{y}$  と表わさる.

誤差に正規性を仮定すると,  $\mathbf{y}$  の同時確率密度関数は

$$f(\mathbf{y}; \boldsymbol{\beta}, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} (\mathbf{y} - X\boldsymbol{\beta})' (\mathbf{y} - X\boldsymbol{\beta}) \right\}$$

## 一様最小分散不偏推定量 (10/10)

例 7.5 (単回帰モデル (つづき))

$\theta = (\beta', \sigma^2)'$  のフィッシャー情報量行列は

$$J(\theta) = \begin{pmatrix} \frac{1}{\sigma^2} X'X & O \\ O & \frac{n}{2\sigma^4} \end{pmatrix}$$

$\ell = (\ell_1, \ell_2)'$  とするとクラメールーラオの不等式より,,  
 $\gamma(\beta) = \ell' \beta$  の任意の不偏推定量に対して

$$\text{Var}\{\hat{\gamma}(y)\} \geq \sigma^2 \ell' (X'X)^{-1} \ell$$

一方,  $\beta$  の最小 2 乗推定量:  $\hat{\beta} = (X'X)^{-1} X'y$  の分散は

$$\text{Var}\{\ell' \hat{\beta}\} = \sigma^2 \ell' (X'X)^{-1} \ell.$$

$\ell' \hat{\beta}$  は,  $\ell' \beta$  の有効推定量であり, したがって一様最小分散不偏推定量でもある.

# 十分統計量

# 十分統計量 (1/8)

## 定義 7.2

$\mathbf{X} = (X_1, \dots, X_n)' \sim \mathbb{P}$ ,  $\mathbb{P} \in \mathcal{P} = \{\mathbb{P}_\theta; \theta \in \Theta\}$  とする. 統計量  $T = T(\mathbf{X})$  は,  $T = t$  を与えたときの  $\mathbf{X}$  の条件付き分布が  $\theta$  に無関係であるとき,  $\theta$  あるいは, 分布族  $\mathcal{P}$  の十分統計量であるという.

## 例 7.6

$$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} B(1, p), \quad T = \sum_{i=1}^n X_i \sim B(n, p)$$

$x_i = 0$  または  $1$ ,  $t = \sum_{i=1}^n x_i$  とすると

$$\begin{aligned} \mathbb{P}(X_1 = x_1, \dots, X_n = x_n | T = t) &= \frac{\mathbb{P}(X_1 = x_1, \dots, X_n = x_n, T = t)}{\mathbb{P}(T = t)} \\ &= \frac{p^t (1-p)^{n-t}}{n C_t p^t (1-p)^{n-t}} = \frac{1}{n C_t} \end{aligned}$$

したがって,  $T$  は  $p$  の十分統計量

## 十分統計量 (2/8)

定理 7.4 (ラオーブラックウェルの定理)

$$\mathbf{X} = (X_1, \dots, X_n)' \sim P, P \in \mathcal{P} = \{P_{\theta}; \theta \in \Theta\}$$

$T = T(\mathbf{X})$  : 十分統計量

$\hat{\gamma}(\mathbf{X})$  :  $\gamma(\theta)$  の不偏推定量

$\gamma^*(T) = E\{\hat{\gamma}(\mathbf{X})|T\}$  と定義すると

$$E\{\gamma^*(T)\} = \gamma(\theta) \text{ かつ } \text{Var}\{\gamma^*(T)\} \leq \text{Var}\{\hat{\gamma}(\mathbf{X})\}$$

が成立する. (証明は板書で)

注.  $\gamma^*(T)$  は  $\theta$  に無関係であるので, 推定量として用いることができる.

## 十分統計量 (3/8)

### 定理 7.5 (分解定理)

$f(\mathbf{x}; \boldsymbol{\theta}) : \mathbf{X} = (X_1, \dots, X_n)'$  の確率密度関数

$T(\mathbf{X})$  が  $\boldsymbol{\theta}$  の十分統計量であるための必要十分条件は、

$f$  が非負値関数  $g, h$  を用いて

$$f(\mathbf{x}; \boldsymbol{\theta}) = g(\mathbf{x})h(T(\mathbf{x}); \boldsymbol{\theta})$$

と書けること。 (証明は省略, テキスト p153 参照)

## 十分統計量 (4/8)

### 定義 7.3 (完備十分統計量)

$T$  は  $\theta$  の十分統計量であるとする.

任意の  $\theta \in \Theta$  に対して,  $E_\theta\{g(T(\mathbf{X}))\} = 0 \Rightarrow$  確率 1 で  
 $g(T(\mathbf{X})) = 0$

が成り立つとき  $T$  は完備であるという.

### 例 7.6 (続き)

$$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} B(1, p), \quad T = \sum_{i=1}^n X_i \sim B(n, p)$$

$T$  は  $p$  の完備十分統計量である. (証明は板書で)

# 十分統計量 (5/8)

## 定理 7.6

$\{f_{\theta}; \theta \in \Theta\}$  を次で与えられる分布族とする.

$$f_{\theta}(\mathbf{x}) = \exp \left\{ \sum_{i=1}^p \eta_i(\theta) T_i(\mathbf{x}) + D(\theta) + S(\mathbf{x}) \right\}.$$

$\mathbf{x} \in \mathbb{R}^q$ ,  $\theta = (\theta_1, \dots, \theta_p)' \in \Theta$ ,  $\Theta$  は  $\mathbb{R}^p$  の開区間,

$T_1, \dots, T_p, S : \mathbb{R}^q$  上で定義された関数

$D$  は  $\Theta$  上で定義された関数

$p \leq q$  であり,  $\eta(\theta) = (\eta_1(\theta), \dots, \eta_p(\theta))'$  による  $\Theta$  の像  $\eta(\Theta)$  が,  
 $\mathbb{R}^p$  の開集合を含むとすると

$$\mathbf{T} = (T_1(\mathbf{X}), \dots, T_p(\mathbf{X}))'$$

は  $\theta$  の完備十分統計量.

## 十分統計量 (6/8)

**定理 7.7 (完備十分統計量と一様最小分散不偏推定量)**

$$\mathbf{X} = (X_1, \dots, X_n)' \sim P, P \in \mathcal{P} = \{P_\theta; \theta \in \Theta\}$$

$$\mathbf{T} = \mathbf{T}(\mathbf{X}) : \theta \text{ の完備十分統計量}$$

$\hat{\gamma}(\mathbf{T})$  が  $\gamma(\theta)$  の不偏推定量

$\Rightarrow \hat{\gamma}(\mathbf{T})$  は一様最小分散不偏推定量

(証明は板書で)

### 例 7.7

$X_1, \dots, X_n$  を正規母集団  $N(\mu, \sigma^2)$  からのランダム標本とする.

$X_1, \dots, X_n$  の同時確率密度関数は

$$f(x_1, \dots, x_n; \mu, \sigma^2)$$

$$= \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \left( \sum_{i=1}^n (x_i - \bar{x}_n)^2 + n\bar{x}_n^2 \right) + \frac{n\mu}{\sigma^2} \bar{x}_n - \frac{n\mu^2}{2\sigma^2} \right\}$$

と表されるので

# 十分統計量 (7/8)

## 例 7.7 (続き)

$$\mathbf{T} = (T_1, T_2)' = \left( \sum_{i=1}^n (X_i - \bar{X}_n)^2 + n\bar{X}_n^2, \bar{X}_n \right)'$$

は完備十分統計量である。定理 6.8 より標本分散

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \frac{1}{n-1} (T_1 - nT_2)$$

は、 $\sigma^2$  の不偏推定量であり、  
定理 7.7 より、一様最小分散不偏推定量

## 十分統計量 (8/8)

### 例 7.7 (続き)

$N(\mu, \sigma^2)$  のフィッシャー情報量行列は

$$\begin{pmatrix} \frac{1}{\sigma^2} & 0 \\ 0 & \frac{1}{2\sigma^4} \end{pmatrix}$$

となるので、系 7.1 より、 $\sigma^2$  の不偏推定量  $\hat{\sigma}^2$  に関する情報量不等式は  $\text{Var}\{\hat{\sigma}^2\} \geq \frac{\sigma^4}{2n}$  となる。定理 6.8 と  $\chi_{n-1}^2$  の分散が  $2(n-1)$  となることから

$$\text{Var}(S_n^2) = \frac{2\sigma^4}{n-1}$$

となり、情報量不等式の下限より大きくなる。したがって、 $\sigma^2$  の有効推定量は存在しない。

# 最尤法

# 最尤法 (1/6)

## 定義 7.4

$f(\mathbf{x}) : \mathbf{X} = (X_1, \dots, X_n)'$  の確率密度関数  
確率密度関数  $g(x)$  に対して

$$\text{KL}(f; g) = -\mathbb{E} \left\{ \log \frac{g(\mathbf{X})}{f(\mathbf{X})} \right\}$$

を  $g$  の  $f$  からのカルバックーライブラーの擬距離とよぶ.

## 補題 7.1

任意の  $g$  に対して,  $\text{KL}(f; g) \geq 0$  が成り立ち, 等号は確率 1 で  
 $f(\mathbf{X}) = g(\mathbf{X})$  のときに限る.  
(証明は板書で)

## 最尤法 (2/6)

$$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} f(x; \boldsymbol{\theta}_0), \quad \boldsymbol{\theta}_0 \in \Theta \subset \mathbb{R}^p$$

(仮定 A0)  $\boldsymbol{\theta} \neq \boldsymbol{\theta}'$  ならば  $P(f(X; \boldsymbol{\theta}) \neq f(X; \boldsymbol{\theta}')) > 0$ .

大数の強法則から

$$\frac{1}{n} \sum_{i=1}^n \log \frac{f(X_i; \boldsymbol{\theta})}{f(X_i; \boldsymbol{\theta}_0)} \xrightarrow{a.s.} -\text{KL}(f(*; \boldsymbol{\theta}_0); f(*; \boldsymbol{\theta})) \quad (n \rightarrow \infty)$$

である.

補題 7.1 より 右辺は  $\boldsymbol{\theta} = \boldsymbol{\theta}_0$  で最大値をとる.

左辺を最大とする  $\boldsymbol{\theta} = \hat{\boldsymbol{\theta}}(X_1, \dots, X_n)$  は,  
 $n \rightarrow \infty$  のとき  $\boldsymbol{\theta}_0$  に収束 (A0 以外にも条件が必要)

## 最尤法 (3/6)

### 尤度関数

標本変量  $\mathbf{X} = (X_1, \dots, X_n)'$  に対する統計モデルを

$$\mathbb{P}(\mathbf{X} \in A) = \begin{cases} \sum_{\mathbf{x} \in A} f(\mathbf{x}; \boldsymbol{\theta}), & \mathbf{X} \text{ が離散型の場合} \\ \int_{\mathbf{x} \in A} f(\mathbf{x}; \boldsymbol{\theta}) d\mathbf{x}, & \mathbf{X} \text{ が連続型の場合} \end{cases}$$

とする。ここに,  $\boldsymbol{\theta} \in \Theta$ . 確率密度関数  $f(\mathbf{x}; \boldsymbol{\theta})$  を ( $\mathbf{x}$  を固定して)  
 $\boldsymbol{\theta}$  の関数とみなすとき

$$L(\boldsymbol{\theta}; \mathbf{x}) \quad (= f(\mathbf{x}; \boldsymbol{\theta})) \tag{1}$$

と表し, 尤度関数とよぶ.

## 最尤法 (4/6)

### 定義 7.5 (最尤推定量)

尤度関数  $L(\theta; x)$  の最大を実現する  $\theta$  を  $\hat{\theta} = \hat{\theta}(x)$  と表し,  $\theta$  の**最尤推定値**という.

$$L(\hat{\theta}; x) = \sup_{\theta \in \Theta} L(\theta; x).$$

$\hat{\theta}(X)$  を  $\theta$  の**最尤推定量**という.

対数尤度  $\log L(\theta; x)$  を  $\ell(\theta; x)$  と表す. 多くの場合, 最尤推定値は**尤度方程式**

$$\frac{\partial}{\partial \theta} \ell(\theta; x) = \mathbf{0}$$

の解として与えられる.

# 最尤法 (5/6)

## 例 7.7

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

尤度関数:  $L(\theta; \mathbf{x}) = \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}$

最尤推定値:  $\hat{\theta} = \bar{x} = \frac{1}{n}(x_1 + \dots + x_n)$

- (2)  $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} N(\mu, \sigma^2), \boldsymbol{\theta} = (\mu, \sigma^2)'$

尤度関数:  $L(\boldsymbol{\theta}; \mathbf{x}) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$

最尤推定値:  $\hat{\mu} = \bar{x}, \quad \hat{\sigma}^2 = s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$

- (3)  $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} U(0, \theta)$

尤度関数:  $L(\theta, x_1, \dots, x_n) = \frac{1}{\theta^n}, 0 < x_i \leq \theta, \theta \in \Theta = (0, \infty)$

最尤推定値:  $\hat{\theta} = \max_{i=1, \dots, n} x_i$

# 最尤法 (6/6)

## 最尤推定量の性質

(i) 不偏性

$$E(\hat{\theta}) = \theta$$

(ii) 一致性

$$\hat{\theta} \xrightarrow{p} \theta \quad (n \rightarrow \infty)$$

(iii) 漸近正規性

標準化すると  $n \rightarrow \infty$  のとき正規分布に分布収束する性質

## 例 7.8

	不偏性	一致性	漸近正規性
例 7.7(1)	○	○	○
例 7.7(2) $\hat{\mu}$	○	○	○
例 7.7(2) $\hat{\sigma}^2$	○	○	○
例 7.7(3)	×	○	×