

確率統計基礎講義 A

2013 年前期

1 序章

1.1 確率空間の定義と性質

定義 1.1 (確率空間)

(Ω, \mathcal{B}, P) が, 次の (i), (ii) を満たすとき確率空間と呼ぶ.

- (i) \mathcal{B} が, 集合 Ω の σ -集合体である, すなわち \mathcal{B} は Ω の部分集合からなる集合族であって, 次の (B1) ~ (B3) を満たす.

$$(B1) \quad \Omega \in \mathcal{B}.$$

$$(B2) \quad A \in \mathcal{B} \Rightarrow A^c \in \mathcal{B}.$$

$$(B3) \quad A_1, A_2, \dots \in \mathcal{B} \Rightarrow \bigcup_{i=1}^{\infty} A_i \in \mathcal{B}.$$

このとき, Ω を標本空間, (Ω, \mathcal{B}) を可測空間と呼ぶ. また, \mathcal{B} に含まれる Ω の部分集合を事象と呼ぶ.

- (ii) P は, (Ω, \mathcal{B}) 上の確率測度である, すなわち P は \mathcal{B} 上の実数値関数であって, 次の (P1 ~ P3) を満たす.

$$(P1) \quad \text{任意の } A \in \mathcal{B} \text{ に対して } 0 \leq P(A) \leq 1.$$

$$(P2) \quad P(\Omega) = 1.$$

- (P3) P は完全加法的である. すなわち $A_1, A_2, \dots \in \mathcal{B}$ で, $A_i \cap A_j = \emptyset$ ($i \neq j$) ならば

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i).$$

定理 1.1 (確率の基本性質)

P を (Ω, \mathcal{B}) 上の確率とし, $\{A_n\}$ を \mathcal{B} に属する事象列とする. このとき, 次が成り立つ.

- (1) (劣加法性)

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) \leq \sum_{n=1}^{\infty} P(A_n).$$

- (2) $\{A_n\}$ が単調増加列のとき

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n).$$

- (3) $\{A_n\}$ が単調減少列のとき

$$P\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n).$$

- (4) (連続性) $\overline{\lim}_{n \rightarrow \infty} A_n = \underline{\lim}_{n \rightarrow \infty} A_n$ のとき

$$P(\lim_{n \rightarrow \infty} A_n) = \lim_{n \rightarrow \infty} P(A_n).$$

問題 1.1

定理 1.1 を証明せよ.

定理 1.2 (ボレル-カンテリの第一定理)

$\{A_n\}$ を事象列とする. $\sum_{n=1}^{\infty} P(A_n) < \infty$ ならば, $P(\overline{\lim}_{n \rightarrow \infty} A_n) = 0$, すなわち $P(\underline{\lim}_{n \rightarrow \infty} A_n^c) = 1$ である.

定理 1.3 (ボレル-カンテリの第二定理)

$\{A_n\}$ を独立な事象列とする. $\sum_{n=1}^{\infty} P(A_n) = \infty$ ならば, $P(\overline{\lim}_{n \rightarrow \infty} A_n) = 1$, すなわち $P(\lim_{n \rightarrow \infty} A_n^c) = 0$ である.

定義 1.2 (確率収束)

確率空間 (Ω, \mathcal{B}, P) 上の確率変数列 $\{X_n\}$ と X が次を満たすとき, X_n は X に確率収束するといひ, $X_n \xrightarrow{P} X (n \rightarrow \infty)$ とかく.

$$\forall \delta > 0, \lim_{n \rightarrow \infty} P(|X_n - X| > \delta) = 0.$$

例 1.1 (大数の弱法則)

X_1, X_2, \dots , を独立に同じ分布に従う (Ω, \mathcal{B}, P) 上の確率変数列とし, $E[X_i] = \mu, \text{Var}[X_i] = \sigma^2$ が有限であるとすると, $\bar{X}_n := \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} \mu (n \rightarrow \infty)$.

問題 1.2

チェビシェフの不等式を用いて, 例 1.1 を証明せよ.

定義 1.3 (概収束)

確率空間 (Ω, \mathcal{B}, P) 上の確率変数列 $\{X_n\}$ と X に対して, $\Omega_0 \subset \Omega$ で, 次を満たすものが存在するとき, X_n は X に概収束するといひ, $\xrightarrow{a.s.} X$ とかく.

$$P(\Omega_0) = 1, \quad \forall \omega \in \Omega_0, \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$$

1.2 大数の法則

定理 1.4 (コロモゴロフの不等式)

$\{X_n\}$ を確率空間 (Ω, \mathcal{B}, P) 上の独立な確率変数列とする. $S_j = X_1 + \dots + X_j$ とおく. $E[X_j] = 0, j = 1, \dots, n$ ならば

$$P(\max_{i=1, \dots, n} |S_i| \geq a) \leq \frac{E(S_n^2)}{a^2}, \quad a > 0. \quad (1.1)$$

定理 1.5 (独立和の収束)

$\{X_n\}$ を確率空間 (Ω, \mathcal{B}, P) 上の独立な確率変数列とする. $E[X_n] = 0, n = 1, 2, \dots$, $\sum_{n=1}^{\infty} \text{Var}[X_n] < \infty$ ならば $S_n = \sum_{k=1}^n X_k$ は概収束する.

補題 1.1 (クロネッカーの補題)

$\{m_n\}$ は $n \rightarrow \infty$ のとき ∞ に発散する正数の単調増加列とする. 数列 $\{x_n\}$ について,

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{x_k}{m_k} \text{ が存在すれば } \lim_{n \rightarrow \infty} \frac{1}{m_n} \sum_{k=1}^n x_k = 0.$$

定理 1.6

$\{X_n\}$ を確率空間 (Ω, \mathcal{B}, P) 上の独立な確率変数列とする. $E[X_n] = 0$ かつ $\sum_{n=1}^{\infty} \frac{E[X_n^2]}{n^2} < \infty$ ならば $\frac{1}{n} \sum_{k=1}^n X_n \xrightarrow{a.s.} 0 (n \rightarrow \infty)$.

定理 1.7 (コロモゴロフの大数の法則)

$\{X_n\}$ を確率空間 (Ω, \mathcal{B}, P) 上の独立な確率変数列とする. $E[X_n] = a, \text{Var}[X_n] \leq v, n = 1, 2, \dots$ ならば, $\frac{1}{n} \sum_{k=1}^n X_n \xrightarrow{a.s.} a (n \rightarrow \infty)$.

問題 1.3

コロモゴロフの大数の法則を証明せよ.

定理 1.8 (ヒンチン)

X_1, X_2, \dots を同じ分布に従う (Ω, \mathcal{B}, P) 上の確率変数列とする. $2 > p \geq 1$ に対し

$$n^{-1/p} \sum_{k=1}^n (X_k - m) \xrightarrow{a.s.} 0 \quad (1.2)$$

となる必要十分条件は

$$E[|X_1|^p] < \infty \text{ かつ } m = E[X_1] \quad (1.3)$$

である.

1.3 中心極限定理

定義 1.4 (特性関数)

確率変数 X に対して, \mathbb{R} 上で定義された関数

$$\varphi_X(t) = E[e^{itX}]$$

を X の特性関数と呼ぶ.

定理 1.9

X の特性関数 $\varphi_X(t)$ について、次が成り立つ。

- (1) $\varphi_X(0) = 1$.
- (2) $|\varphi_X(t)| \leq 1$.
- (3) $\varphi_X(t)$ は一様連続である.
- (4) $\varphi_{cX+d}(t) = e^{itd}\varphi_X(ct)$. ただし, c, d は定数.
- (5) $E(|X|^n) < \infty$ ならば, $\varphi_X(t)$ は C^n クラスで,

$$\left. \frac{d^n}{dt^n} \varphi_X(t) \right|_{t=0} = i^n E(X^n).$$

問題 1.4

定理 1.9 を証明せよ.

補題 1.2

(1) $\forall y \geq 0$ に対して,

$$0 \leq (\operatorname{sgn} \alpha) \int_0^y \frac{\sin \alpha x}{x} dx \leq \int_0^\pi \frac{\sin x}{x} dx.$$

(2) $\int_0^\infty \frac{\sin \alpha x}{x} dx = \frac{\pi}{2} \operatorname{sgn} \alpha$.
ただし

$$\operatorname{sgn} \alpha = \begin{cases} 1, & \alpha > 0 \\ 0, & \alpha = 0 \\ -1, & \alpha < 0. \end{cases}$$

定理 1.10 (反転公式)

確率変数 X の分布関数, 特性関数をそれぞれ, F_X, φ_X とする. このとき, F_X の連続点 a, b ($a < b$) において

$$F_X(b) - F_X(a) = \lim_{T \rightarrow \infty} \frac{1}{2\pi} \int_{-T}^T \frac{e^{-ita} - e^{-itb}}{it} \varphi_X(t) dt$$

が成り立つ.

定理 1.11 (一意性定理)

確率変数 X_1, X_2 の確率分布をそれぞれ μ_1, μ_2 とする. また, それらの特性関数をそれぞれ φ_1, φ_2 とする. このとき

$$\varphi_1 = \varphi_2 \Leftrightarrow \mu_1 = \mu_2$$

が成り立つ.

問題 1.5

次の確率密度関数によって定まる連続型分布を, 位置母数 μ , 尺度母数 σ のコーシー分布と呼び, $Ca(\mu, \sigma)$ と書く.

$$f(x; \mu, \sigma) = \frac{\sigma}{\pi \{ \sigma^2 + (x - \mu)^2 \}}$$

(1) $Ca(0, 1)$ の特性関数を求めよ. (ヒント: 留数定理)

(2) $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} Ca(\mu, 1)$ ならば $\bar{X}_n \sim Ca(\mu, 1)$ であることを示せ.

定義 1.5 (分布収束)

確率変数列 $X_n, n = 1, 2, \dots$ と X の分布関数を, それぞれ $F_n(x), F(x)$ とする. F の任意の連続点 x で $\lim_{n \rightarrow \infty} F_n(x) = F(x)$ が成り立つとき, X_n は X (X の分布) に分布収束するといひ, $X_n \xrightarrow{d} X$, あるいは, $X_n \xrightarrow{d} F$ とかく.

補題 1.3

$X_n \xrightarrow{d} X$ ($n \rightarrow \infty$) ならば, 任意の有界かつ連続な関数 $g(x)$ に対して $\lim_{n \rightarrow \infty} E\{g(X_n)\} = E\{g(X)\}$ が成り立つ.

定理 1.12 (レヴィの連続定理)

X_n ($n = 1, 2, \dots$) の特性関数を φ_n ($n = 1, 2, \dots$) とする. $\varphi_n(t)$ が各点で $\varphi(t)$ に収束し, $\varphi(t)$ が $t = 0$ で連続ならば $\varphi(t)$ は, ある確率分布 P_X の特性関数であって $X_n \xrightarrow{d} P_X$ ($n \rightarrow \infty$).

補題 1.4

定理 1.12 の条件の下で, 任意の正数 ε に対して

$$P(|X_n| \leq A) > 1 - \varepsilon, \quad n = 1, 2, \dots \quad (1.4)$$

が成り立つような A が存在する.

補題 1.5

任意の実数値 x に対して

$$\left| e^{ix} - \sum_{k=0}^{n-1} \frac{(ix)^k}{k!} \right| \leq \frac{|x|^n}{n!}$$

定理 1.13 (中心極限定理)

各 n に対し, $X_{n,1}, X_{n,2}, \dots, X_{n,n}$ は独立で, $E[X_{n,k}] = 0, \sum_{k=1}^n \text{Var}[X_{n,k}] = 1$ とする.

$$\forall \tau > 0, \lim_{n \rightarrow \infty} \sum_{k=1}^n E[X_{n,k}^2 1_{|X_{n,k}| > \tau}] = 0 \quad (1.5)$$

であれば, $Z_n := \sum_{k=1}^n X_{n,k} \xrightarrow{d} N(0, 1)$.

定理 1.14 (中心極限定理)

X_1, \dots, X_n は互いに独立に同一分布に従う確率変数で

$$E(X_j) = \mu, \text{Var}(X_j) = \sigma^2, \quad j = 1, \dots, n$$

とする. このとき

$$Z_n = \frac{1}{\sqrt{n}\sigma} \sum_{j=1}^n (X_j - \mu) = \frac{\sqrt{n}(\bar{X} - \mu)}{\sigma}$$

の分布は標準正規分布に分布収束する. すなわち

$$\lim_{n \rightarrow \infty} P(\sqrt{n}(\bar{X} - \mu)/\sigma \leq x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-t^2/2} dt = \Phi(x).$$

問題 1.6

定理 1.14 を証明せよ.

2 最尤推定量の分布

定義 2.1 (標本と母集団分布)

確率変数 X_1, \dots, X_n が互いに独立で, 同一の確率分布 P に従うとき, X_1, \dots, X_n は, 分布 P からの, 大きさ n 無作為標本といい, P を母集団分布という.

定義 2.2 (統計モデル)

母集団分布が, ある確率分布の集まり

$$\mathcal{P} = \{P_\theta; \theta \in \Theta\}, \quad \Theta \subset \mathbb{R}^p \quad (p \text{ はある自然数})$$

に属すると想定されるとき, \mathcal{P} を母集団分布の統計モデルという. このとき, θ を母数, Θ を母数空間と呼ぶ.

例 2.1

小学校 6 年男児 n 人の身長 X_1, \dots, X_n (cm) を測定するとする. このとき, X_1, \dots, X_n の母集団分布は正規分布 $N(\mu, \sigma^2)$ からの無作為標本と考えられる. このとき, 母数は, $\theta = (\mu, \sigma^2)$, 母数空間は $\Theta = \mathbb{R} \times (0, \infty)$ となる. 平均 μ , 分散 σ^2 の値がわかれば, 例えば, 小学 6 年男児の内, 身長が 130cm 以下の人数の比率は

$$\frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{130} \exp\left\{-\frac{(x-\mu)^2}{\sigma^2}\right\} dx$$

によって近似することができる.

定義 2.3 (カルバック-ライブラーの擬距離)

X の確率密度関数を $f(x)$ とする. 確率密度関数 $g(x)$ に対して

$$\text{KL}(f; g) = E\left[\frac{f(X)}{g(X)}\right]$$

をカルバック-ライブラーの擬距離と呼ぶ. ただし, $P(f(X) > 0, g(X) = 0) > 0$ のときは, $\text{KL}(f; g) = \infty$ と定義する.

補題 2.1

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.

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} f(x; \theta_0), \theta_0 \in \Theta$ とし, 次の仮定 (A0) が成り立つとする.

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

大数の法則から

$$\frac{1}{n} \sum_{i=1}^n \log \frac{f(X_i; \theta)}{f(X_i; \theta_0)} \xrightarrow{a.s.} -\text{KL}(f(*; \theta_0); f(*; \theta)) \quad (n \rightarrow \infty)$$

である. 仮定 (A0) が成り立つとき, 右辺は $\theta = \theta_0$ のときのみ最大値をとることから, 左辺, すなわち $\prod_{i=1}^n f(X_i, \theta)$ を最大とする θ を $\hat{\theta}_n = \hat{\theta}_n(\mathbf{X})$ とすると, $\hat{\theta}_n$ は, $n \rightarrow \infty$ のとき θ_0 に収束することが期待される.

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

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

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

$$L(\theta; \mathbf{x}) \quad (= f(\mathbf{x}; \theta)) \quad (2.6)$$

と表し, 尤度関数とよぶ.

定義 2.4

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

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

また, $\hat{\theta}(\mathbf{X})$ を θ の最尤推定量という.

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

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

の解として与えられる.

問題 2.1

- (1) $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} B(1, \theta)$, $\theta \in (0, 1)$, すなわち $P(X_i = 1) = 1 - P(X_i = 0) = \theta$, $i = 1, \dots, n$ とする. θ の最尤推定量を求めよ.
- (2) $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} N(\mu, \sigma^2)$, $\theta = (\mu, \sigma^2)$ とする. μ, σ^2 の最尤推定量を求めよ.
- (3) $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} U(0, \theta)$ (区間 $(0, \theta)$ 上の一様分布) とする. θ の最尤推定量を求めよ.

補題 2.2

$\{X_n\}$ を (Ω, \mathcal{B}, P) 上の確率変数列とすると, $X_n \xrightarrow{a.s.} X$ であるための必要十分条件は $A_n(\varepsilon) = \{\omega; |X_n - X| \leq \varepsilon\}$ とするとき,

$$\forall \varepsilon > 0, P(\lim_{n \rightarrow \infty} A_n(\varepsilon)) = 1$$

である.

定理 2.1 (最尤推定量の一致性)

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} P_{\theta_0}$, P_{θ} は確率密度関数, あるいは確率関数 $f(x; \theta)$, $\theta \in \Theta \subset \mathbb{R}$ を持ち, 次の (A1), (A2) を仮定する.

(A1) 任意の θ_* ($\theta_* \neq \theta_0$) に対して正数 $\delta = \delta(\theta_*)$ が存在して

$$\eta(\theta_*) := E \left[\sup_{\theta \in U_{\theta_*, \delta}} \log \frac{f(X_1; \theta)}{f(X_1; \theta_0)} \right] < 0.$$

ただし, $U_{\theta_*, \delta} = \{\theta \in \Theta; \|\theta - \theta_*\| < \delta\}$.

(A2) Θ のコンパクト部分集合 K が存在して

$$\eta_K := E \left[\sup_{\theta \in K^c} \log \frac{f(X_1; \theta)}{f(X_1; \theta_0)} \right] < 0.$$

このとき, 各 n に対して確率 1 で最尤推定量 $\hat{\theta}_n$ が存在するならば $\hat{\theta}_n \xrightarrow{a.s.} \theta_0$ ($n \rightarrow \infty$).

定理 2.2 (漸近正規性 ; クラームルの十分条件)

X_1, \dots, X_n を確率密度関数 $f(x; \theta_0)$ を持つ連続型分布からのランダム標本とする. ただし, $\theta_0 \in \Theta \subset \mathbb{R}$, Θ は開集合である. また, θ_0 の近傍 U , 関数 $F_1(x)$, $F_2(x)$, $H(x)$ と定数 M が存在して次の条件が成り立つと仮定する.

(A1) $f(x; \theta)$ は θ に関して 3 回微分可能である.

(A2) $\theta \in U$ で, $\left| \frac{\partial f(x; \theta)}{\partial \theta} \right| < F_1(x)$, $\left| \frac{\partial^2 f(x; \theta)}{\partial \theta^2} \right| < F_2(x)$, かつ, $\left| \frac{\partial^3 \log f(x; \theta)}{\partial \theta^3} \right| < H(x)$ である. また, $F_1(x)$, $F_2(x)$ は可積分で, H, M は

$$E_{\theta_0}\{H(X)\} \leq M$$

を満たす.

(A3) フィッシャー情報量 $J(\theta_0)$ は有限かつ正である.

このとき, 任意の正数 ε, δ に対して N が存在して, $n \geq N$ ならば $1 - \varepsilon$ より大きい確率で, 尤度方程式 $\partial l(\theta, \mathbf{X})/\partial \theta = 0$ は, $(\theta_0 - \delta, \theta_0 + \delta)$ 内に解を持つ. この解を $\hat{\theta}_n$ とすると

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N(0, J(\theta_0)^{-1}) \quad (2.7)$$

が成り立つ.

例 2.2

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} Ca(\theta_0, 1)$ とする. 以下, $\theta_0 = 0$ とする.

$$\log \frac{f(x; \theta)}{f(x; 0)} = \log \frac{1 + x^2}{1 + (x - \theta)^2}$$

$0 < \delta_0 < \theta_*$ とする. $|\theta - \theta_*| < \delta$ のとき

$$0 \leq (x - \theta)^2 \leq \max\{(\theta_* + \delta - x)^2, (x - \theta_* + \delta)^2\}$$

であるから

$$\begin{aligned} & \sup_{\theta \in U_{\theta_*, \delta_0}} \left| \log \frac{1 + x^2}{1 + (x - \theta)^2} \right| \\ & \leq \log(1 + x^2) + \log(1 + (x - \theta_* + \delta)^2) \\ & \quad + \log(1 + (x - \theta_* - \delta)^2), \end{aligned}$$

$$E_{\theta_0}[\log\{1 + (X_1 - \alpha)^2\}] < \infty$$

であるからルベーグの収束定理より

$$\lim_{\delta \rightarrow 0} E_{\theta_0} \left[\sup_{\theta \in U_{\theta_*, \delta}} \log \frac{f(X; \theta)}{f(X; \theta_0)} \right] = E_{\theta_0} \left[\log \frac{f(X; \theta_*)}{f(X; \theta_0)} \right]$$

また, 補題 2.1 より, $\theta_* \neq \theta_0$ ならば $E_{\theta_0}[\log \frac{f(x; \theta_*)}{f(x; \theta_0)}] < 0$. したがって, 定理 2.1 の (A1) を満たす.

$$\begin{aligned} \sup_{|\theta| > k} \log \frac{f(x; \theta)}{f(x; \theta_0)} &= \sup_{|\theta| > k} \log \frac{1 + x^2}{1 + (x - \theta)^2} \\ &= \begin{cases} \log(1 + x^2), & |x| > k \\ \log \frac{1 + x^2}{1 + (x - k)^2}, & 0 \leq x \leq k \\ \log \frac{1 + x^2}{1 + (x + k)^2}, & 0 > x \geq -k \end{cases} \end{aligned}$$

$$\begin{aligned} & E \left[\sup_{|\theta| > k} \log \frac{f(X_1; \theta)}{f(X_1; \theta_0)} \right] \\ &= E[\log(1 + X_1^2)] - E[1_{0 \leq X_1 \leq k} \log\{1 + (k - X_1)^2\}] \\ & \quad - E[1_{0 > X_1 \leq -k} \log\{1 + (k + X_1)^2\}] \\ &= E[\log(1 + X_1^2)] \\ & \quad - 2E[1_{0 \leq X_1 \leq k} \log\{1 + (k - X_1)^2\}] \end{aligned}$$

$k \geq 1$ のとき

$$\begin{aligned} & E[1_{0 \leq X_1 \leq k} \log\{1 + (k - X_1)^2\}] \\ & \geq E[1_{0 \leq X_1 \leq 1} \log\{1 + (k - X_1)^2\}] \\ & \geq E[1_{0 \leq X_1 \leq 1} \log\{1 + (k - 1)^2\}] \\ &= \log\{1 + (k - 1)^2\} P(0 \leq X_1 \leq 1) \\ & \rightarrow \infty \quad (k \rightarrow \infty) \end{aligned}$$

であるから 定理 2.1 の (A2) が成り立つ.

対数尤度関数は

$$l(\theta, \mathbf{X}) = - \sum_{i=1}^n \log\{1 + (X_i - \theta)^2\} - n \log \pi$$

であり, $\lim_{\theta \rightarrow \pm\infty} l(\theta, \mathbf{X}) = -\infty$, $l(\theta, \mathbf{X}) \leq -n \log \pi$ であるから, 確率 1 で最尤推定量 $\hat{\theta}_n$ は存在し, 定理 2.1 より $\hat{\theta}_n \xrightarrow{a.s.} \theta_0$ である.

例 2.3

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} Ca(\theta_0, 1)$, $\theta_0 = 0$ とする.

$$\begin{aligned} \frac{\partial f(x; \theta)}{\partial \theta} &= \frac{2(x - \theta)}{\pi\{1 + (x - \theta)^2\}^2}, \\ \frac{\partial^2 f(x; \theta)}{\partial \theta^2} &= -\frac{8}{\pi\{1 + (x - \theta)^2\}^3} + \frac{6}{\pi\{1 + (x - \theta)^2\}^2}, \\ \frac{\partial \log f(x; \theta)}{\partial \theta} &= \frac{2(x - \theta)}{\pi\{1 + (x - \theta)^2\}} \\ \frac{\partial^3 \log f(x; \theta)}{\partial \theta^3} &= -\frac{16(x - \theta)}{\pi\{1 + (x - \theta)^2\}^3} + \frac{4(x - \theta)}{\pi\{1 + (x - \theta)^2\}^2} \end{aligned}$$

$$\begin{aligned} \sup_{|\theta| < \delta} \left| \frac{x - \theta}{\{1 + (x - \theta)^2\}^k} \right| &\leq \sup_{|\theta| < \delta} \frac{1}{\{1 + (x - \theta)^2\}^{k-1/2}} \\ &= H_k(x; \delta) := \begin{cases} 1, & |x| < \delta \\ \frac{1}{\{1 + (x - \delta)^2\}^{k-1/2}}, & x > \delta \\ \frac{1}{\{1 + (x + \delta)^2\}^{k-1/2}}, & x < -\delta \end{cases} \\ \int_{-\infty}^{\infty} H_k(x; \delta) dx &= 2\delta + 2 \int_0^{\infty} \frac{dx}{\{1 + x^2\}^{k-1/2}} \end{aligned}$$

より $k > 1$ ならば $\int_{-\infty}^{\infty} H_k(x; \delta) dx < \infty$. $\frac{\partial^3 \log f(x; \theta)}{\partial \theta^3}$ は有界であるから、定理 2.2 の (A1), (A2) が成り立つ。また、 $J(\theta_0) = \frac{1}{2}$ となるので (A3) も成り立つ。

尤度方程式の解は一意ではないが、例 2.2 で、最尤推定量の概収束を示しており、最尤推定量も尤度方程式の解となっているので、定理 2.2 で存在が保証されている解が最尤推定量であり、したがって最尤推定量の漸近正規性が示される。

3 検定計量の分布

3.1 仮説検定の基礎

$$\begin{aligned} \mathbf{X} &= (X_1, \dots, X_n)', \quad X_1, X_2, \dots, X_n \stackrel{i.i.d.}{\sim} P_\theta \\ P_\theta &\in \mathcal{P} = \{P_\theta; \theta \in \Theta\}, \Theta \subset \mathbb{R}^p \end{aligned}$$

とする。 \mathbf{X} の実現値 $\mathbf{x} = (x_1, \dots, x_n)'$ から、仮説

$$H_0 : \theta \in \Theta_0 \quad (\Theta_0 \subset \Theta)$$

が正しいかどうか判定する問題を仮説検定問題と呼ぶ。 H_0 を帰無仮説、また、

$$H_1 : \theta \in \Theta \setminus \Theta_0$$

を対立仮説と呼ぶ。

仮説検定法は、 \mathbf{X} の値域 (\mathbb{R}^n) の部分集合 \mathcal{W} を指定することによって与えられる。実際、 \mathcal{W} に対して

$$\mathbf{x} \in \mathcal{W} \Rightarrow H_0 \text{ を棄却する}$$

$$\mathbf{x} \notin \mathcal{W} \Rightarrow H_0 \text{ を棄却しない}$$

とすれば良い。このとき、 \mathcal{W} を、これによって与えられる検定の棄却域と呼ぶ。

H_0 が正しいのに H_0 を棄却する誤りを、第 1 種の過誤、 H_1 が正しいのに H_0 を棄却しない誤りを、第 2 種の過誤と呼ぶ。

$$\beta(\theta; \mathcal{W}) = P_\theta(\mathbf{X} \in \mathcal{W})$$

とすると、第 1 種、第 2 種の過誤の起こる確率は、それぞれ

$$\beta(\theta; \mathcal{W}) \quad (\theta \in \Theta_0),$$

$$1 - \beta(\theta; \mathcal{W}) \quad (\theta \notin \Theta_0)$$

と表される。 $\beta(\theta; \mathcal{W})$ ($\theta \notin \Theta_0$) を検出力と呼ぶ。実用上は第 1 種の過誤は、それによって被る被害が大きい場合が多いので、通常は、第 1 種の過誤確率の上限として 0.05 や 0.01 など小さな値を設定する。 $\sup_{\theta \in \Theta_0} \beta(\theta; \mathcal{W}) \leq \alpha$ となるような検定を有意水準 α の検定と呼ぶ。

最適化問題 $0 < \alpha < 1$ とし、

$$\sup_{\theta \in \Theta_0} \beta(\theta; \mathcal{W}) \leq \alpha$$

の条件下で、 $\theta \in \Theta \setminus \Theta_0$ に対して、検出力 $\beta(\theta; \mathcal{W})$ を最大とする \mathcal{W} を求める。そのような検定を最強力検定と呼ぶ。最強力検定は一般に $\theta \notin \Theta_0$ に依存するが、任意の $\theta \notin \Theta_0$ に対して検出力を最大にする検定があれば、それを一様最強力検定と呼ぶ。

単純仮説の検定 $\Theta_0 = \{\theta_0\}$ のとき、 H_0 を単純仮説と呼ぶ。

$\Theta = \{\theta_0, \theta_1\}$ ($\theta_0 \neq \theta_1$), $\Theta_0 = \{\theta_0\}$ とする。このとき、帰無仮説、対立仮説はともに単純仮説で、

$$H_0 : \theta = \theta_0, \quad H_1 : \theta = \theta_1 \quad (3.8)$$

となる。

定理 3.1 (ネイマン–ピアソンの基本定理)

\mathbf{X} の確率密度関数を $f(\mathbf{x}; \theta)$ とし, (3.8) に対する有意水準 α の検定問題を考える.

$$\mathcal{W}_c = \{\mathbf{x}; f(\mathbf{x}; \theta_1) \geq c f(\mathbf{x}; \theta_0)\}$$

とし,

$$P_{\theta_0}(\mathbf{X} \in \mathcal{W}_c) = \alpha$$

を満たす c が存在すると仮定する. このとき, \mathcal{W}_c を棄却域とする検定は最強力検定である.

対立仮説が複合仮説であるとき, 各 $\theta \in \Theta \setminus \theta_0$ に対して, 定理 3.1 により, 最強力検定が決定されるが, 一般に, 最強力検定は θ ごとに異なる. 最強力検定が θ に依存しないとき, その検定は, 一様最強力検定となる.

例 3.1 (正規母集団の母平均に関する検定)

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} N(\mu, 1)$ とし

$$H_0 : \mu = 0, \quad H_1 : \mu > 0$$

の検定を考える.

3.2 $\theta = \theta_0$ の検定

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} P_{\theta}$, P_{θ} は確率密度関数 $f(x; \theta)$, $\theta \in \Theta \subset \mathbb{R}^p$ を持つとし

$$\text{帰無仮説 } H_0 : \theta = \theta_0, \quad \text{対立仮説 } H_1 : \theta \neq \theta_0$$

の検定問題を考える.

本節では, 第 2 節で与えた定理のように, 最尤推定量 $\hat{\theta}_n$ が存在して, 尤度方程式

$$s_n(\theta) = \sum_{i=1}^n \frac{\log \partial f(X_i; \theta)}{\partial \theta} = \mathbf{0} \tag{3.9}$$

の解であるとする. このとき, 尤度比基準は

$$\lambda = \frac{\prod_{i=1}^n f(X_i; \theta_0)}{\prod_{i=1}^n f(X_i; \hat{\theta}_n)}$$

となり, 適当な正則条件の下で

$$-2 \log \lambda \xrightarrow{d} \chi_p^2 \quad n \rightarrow \infty$$

ワルド検定統計量は

$$T_W = n(\hat{\theta}_n - \theta_0)' J(\hat{\theta}_n)(\hat{\theta}_n - \theta_0)$$

と定義される. 適当な正則条件の下で

$$T_W \xrightarrow{d} \chi_p^2 \quad n \rightarrow \infty$$

スコア検定統計量は

$$T_S = \frac{1}{n} \mathbf{s}_n(\theta_0)' J(\theta_0)^{-1} \mathbf{s}_n(\theta_0)$$

と定義される. 適当な正則条件の下で

$$T_S \xrightarrow{d} \chi_p^2 \quad n \rightarrow \infty$$

3.3 関数構造の検定

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} P_{\theta}$, P_{θ} は確率密度関数 $f(x; \theta)$, $\theta \in \Theta \subset \mathbb{R}^p$ を持つとする. $\Theta_0 = \{\theta(\xi); \xi \in \Xi \subset \mathbb{R}^q\}$, $q < p$ とするとき

$$\text{帰無仮説 } H_0 : \theta \in \Theta_0, \quad \text{対立仮説 } H_1 : \theta \notin \Theta_0$$

の検定問題を考える. ここで, $\theta(\xi)$ は Ξ 上で定義された Θ 内に値をとる C^3 -級のベクトル値関数とし, ξ は未知であるとする.

帰無仮説が正しく, 真のパラメータが $\theta_0 = \theta(\xi_0)$ であると仮定する. また, Θ 全体での最尤推定量を $\hat{\theta}_n$, 帰無仮説の下での ξ の最尤推定量を $\hat{\xi}_n$ とする. このとき, 尤度比基準は

$$\lambda = \frac{\prod_{i=1}^n f(X_i; \theta(\hat{\xi}_n))}{\prod_{i=1}^n f(X_i; \hat{\theta}_n)}$$

となる.

ワルド検定統計量, スコア検定統計量はそれぞれ,

$$T_W = n\{\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n)\}' J(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))\{\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n)\},$$

$$T_S = \frac{1}{n} \mathbf{s}_n(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))' J(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))^{-1} \mathbf{s}_n(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))$$

と定義される. このとき, 適当な正則条件の下で

$$-2 \log \lambda \sim T_W \sim T_S \xrightarrow{d} \chi_{p-q}^2$$

3.4 関数制約仮説の検定

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} P_{\boldsymbol{\theta}}$, $P_{\boldsymbol{\theta}}$ は確率密度関数 $f(x; \boldsymbol{\theta})$, $\boldsymbol{\theta} \in \Theta \subset \mathbb{R}^p$ を持つとし

帰無仮説 $H_0 : \mathbf{h}(\boldsymbol{\theta}) = \mathbf{0}$, 対立仮説 $H_1 : \mathbf{h}(\boldsymbol{\theta}) \neq \mathbf{0}$

の検定問題を考える. ここで, \mathbf{h} は q 次元ベクトル値関数とする.

帰無仮説の下での $\boldsymbol{\theta}$ の最尤推定量は多くの場合, ラグランジュの未定乗数法により, $\boldsymbol{\theta}, \boldsymbol{\lambda}$ に関する次の連立方程式の解として求められる.

$$\begin{aligned} \mathbf{s}_n(\boldsymbol{\theta}) + H(\boldsymbol{\theta})\boldsymbol{\lambda} &= \mathbf{0}, \\ \mathbf{h}(\boldsymbol{\theta}) &= \mathbf{0}. \end{aligned} \quad (3.10)$$

ただし

$$\mathbf{s}_n(\boldsymbol{\theta}) = \sum_{i=1}^n \frac{\log \partial f(X_i; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}}, \quad H(\boldsymbol{\theta}) = \frac{\partial \mathbf{h}'(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}}$$

である.

補題 3.1

$\mathbf{g}(\mathbf{z})$ を \mathbb{R}^p 上で定義された p 次元ベクトル値連続関数で, $\|\mathbf{z}\| = \delta$ ならば常に $\mathbf{z}'\mathbf{g}(\mathbf{z}) < 0$ を満たすものとする. このとき, $\|\mathbf{z}_0\| < \delta$, $\mathbf{g}(\mathbf{z}_0) = \mathbf{0}$ を満たす \mathbf{z}_0 が少なくともひとつ存在する.

定理 3.2

$\boldsymbol{\theta}_0$ を真値とし, $\mathbf{h}(\boldsymbol{\theta}_0) = \mathbf{0}$ とする.

$\boldsymbol{\theta}_0$ の近傍 U_0 , 関数 $F_1(\mathbf{x}), F_2(\mathbf{x}), K(\mathbf{x})$ と定数 κ_1, κ_2 が存在して以下の (F1), (F2), (F3), (H1), (H2), (H3) が成り立つと仮定する.

(F1) $f(\mathbf{x}; \boldsymbol{\theta})$ は $\boldsymbol{\theta}$ について 3 回微分可能.

(F2) $\boldsymbol{\theta} \in U_0$ で $\left| \frac{\partial f(\mathbf{x}; \boldsymbol{\theta})}{\partial \theta_i} \right| \leq F_1(x)$, $\left| \frac{\partial^2 f(\mathbf{x}; \boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \right| \leq F_2(x)$, $\left| \frac{\partial^3 \log f(\mathbf{x}; \boldsymbol{\theta})}{\partial \theta_i \partial \theta_j \partial \theta_k} \right| \leq K(x)$ かつ, $F_1(x), F_2(x)$ は可積分,

$$\sup_{\boldsymbol{\theta} \in U_0} E\{K(X_1)\} \leq 2\kappa_1.$$

(F3) $J(\boldsymbol{\theta}_0) = \text{Var}\left\{ \frac{\partial \log f(X_1; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right\}$ は有限かつ正定値.

(H1) $h(\boldsymbol{\theta})$ は 2 回微分可能.

(H2) $\boldsymbol{\theta} \in U_0$ で $\left| \frac{\partial^2 h(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \right| \leq 2\kappa_2$.

(H3) $\text{rank} H(\boldsymbol{\theta}_0) = q$.

このとき, 任意の正数 ε, δ に対して N が存在し $n \geq N$ ならば $1 - \varepsilon$ より大きい確率で (3.10) は $\boldsymbol{\theta}_0$ の δ -近傍内に解を持つ.

$J(\hat{\boldsymbol{\theta}}_0) = J$, $H(\hat{\boldsymbol{\theta}}_0) = H$ と略記するとワルド検定統計量は

$$T_W \sim n^{-1} \mathbf{s}_n(\hat{\boldsymbol{\theta}}_0)' J^{-1} H (H' J^{-1} H)^{-1} H' J^{-1} \mathbf{s}_n(\hat{\boldsymbol{\theta}}_0)$$

と定義され, 帰無仮説の下で

$$T_W \xrightarrow{d} \chi_q^2$$

ラグランジュ未定乗数法検定統計量 T_{LM} は

$$T_{LM} \sim n^{-1} \hat{\boldsymbol{\lambda}}' H' J^{-1} H \hat{\boldsymbol{\lambda}}$$

と定義され,

$$T_{LM} \xrightarrow{d} \chi_q^2$$

ラグランジュの未定乗数と区別して, 尤度比基準を Λ と表すと

$$\Lambda = \frac{\prod_{i=1}^n f(X_i; \hat{\boldsymbol{\theta}}_0)}{\prod_{i=1}^n f(X_i; \hat{\boldsymbol{\theta}}_n)}$$

となり,

$$-2 \log \Lambda \xrightarrow{d} \chi_q^2$$

4 中心極限定理の精密化

4.1 エッジワース展開

X_1, \dots, X_n は互いに独立に同一分布に従う確率変数で

$$E(X_j) = \mu, \quad \text{Var}(X_j) = \sigma^2, \quad j = 1, \dots, n,$$

さらに, $E(X_j^4) < \infty$ と仮定し,

$$\kappa^{(3)} = \frac{1}{\sigma^3} \frac{1}{i^3} \left(\frac{d}{dt^3} \right) \log E[e^{itX_j}]|_{t=0} \quad : \text{歪度}$$

$$\kappa^{(4)} = \frac{1}{\sigma^4} \frac{1}{4^3} \left(\frac{d}{dt^3} \right) \log E[e^{itX_j}]|_{t=0} \quad : \text{尖度}$$

とする. さらに, クラメル条件

$$\limsup_{|t| \rightarrow \infty} |E(e^{itX_j})| < 1$$

が成り立つとき,

$$Z_n = \frac{1}{\sqrt{n}} \sum_{j=1}^n \frac{X_j - \mu}{\sigma}$$

の確率密度関数を $f_n(z)$ とすると $n \rightarrow \infty$ のとき

$$f_n(z) = \frac{1}{\sqrt{2\pi}} e^{-z^2/2} \left[1 + \frac{\kappa^{(3)}}{3! \sqrt{n}} H_3(z) + \frac{1}{n} \left\{ \frac{\kappa^{(4)}}{24} H_4(z) + \frac{(\kappa^{(3)})^2}{72} H_6(z) \right\} \right] + o(n^{-1})$$

ただし, H_k は k 次のエルミート多項式と呼ばれ, 次で定義される.

$$\left(\frac{d}{dx} \right)^k e^{-x^2/2} = (-1)^k e^{-x^2/2} H_k(x)$$

4.2 サドルポイント近似

X_1, \dots, X_n は互いに独立に同一分布に従う連続型確率変数で, F, f, M, K をそれぞれ, 分布関数, 確率密度関数, 積率母関数, キュムラント母関数とする.

$$M(t) = e^{K(t)} = \int_{-\infty}^{\infty} e^{tx} f(x) dx$$

$M(\tau) < \infty$ とし,

$$\sigma_\tau^2 = K^{(2)}(\tau), \quad z_\tau = \sqrt{n} \frac{\bar{x} - K'(\tau)}{\sigma_\tau}, \quad a_k = \frac{K^{(k+2)}(\tau)}{(k+2)!} \quad (4.11)$$

とおく. $\bar{X} = \frac{1}{n} \sum_{j=1}^n X_j$ の確率密度関数は

$$f_n(\bar{x}) = \frac{\sqrt{n}}{\sigma_\tau} e^{nK(\tau) - n\tau\bar{x}} \left[\frac{1}{\sqrt{2\pi}} e^{-z_\tau^2/2} \left\{ 1 + \frac{\theta_3(\tau)}{\sqrt{n}} H_3(z_\tau) + \frac{1}{n} \left(\theta_4(\tau) H_4(z_\tau) + \frac{\{\theta_3(\tau)\}^2}{2} H_6(z_\tau) \right) \right\} + O(n^{-3/2}) \right], \quad (4.12)$$

ただし,

$$\theta_k(\tau) = \frac{K^{(k)}(\tau)}{k! \sigma_\tau^k} \quad (k = 3, 4, \dots). \quad (4.13)$$

$K'(\tau_0) = \bar{x}$ となる τ_0 はサドルポイントと呼ばれる. τ_0 が存在するとき, (4.12) において $\tau = \tau_0$ ととると, $z_\tau = 0, H_3(0) = 0, H_4(0) = 3, H_6(0) = -15$ であるから

$$f_n(\bar{x}) = \frac{\sqrt{n}}{\sqrt{2\pi}\sigma_{\tau_0}} e^{n(K(\tau_0) - \tau_0\bar{x})} \left[1 + \frac{1}{n} \left\{ 3\theta_4(\tau_0) - \frac{15\{\theta_3(\tau_0)\}^2}{2} \right\} + O(n^{-2}) \right] \quad (4.14)$$

が得られ, $1/n$ のべきによる展開式が得られる.

$\tau = 0$ ととると

$$f_n(\bar{x}) = \frac{\sqrt{n}}{\sqrt{2\pi}\sigma_0} \left[\exp\left\{ -\frac{n\{K'(0) - \bar{x}\}^2}{2\sigma_0^2} \right\} \cdot \left\{ 1 + \frac{1}{\sqrt{n}} \frac{K^{(3)}(0)}{6\sigma_0^3} H_3\left[\frac{\sqrt{n}(\bar{x} - K'(0))}{\sigma_0} \right] + \frac{1}{n} \left(\frac{K^{(4)}(0)}{24\sigma_0^4} H_4\left[\frac{\sqrt{n}(\bar{x} - K'(0))}{\sigma_0} \right] + \frac{(K^{(3)}(0))^2}{72\sigma_0^6} H_6\left[\frac{\sqrt{n}(\bar{x} - K'(0))}{\sigma_0} \right] \right) \right\} + O(n^{-3/2}) \right]$$

となるが, これは \bar{X} の確率密度関数のエッジワース展開に一致する.

レポート

課題：問題 1.1～問題 1.6, および, 問題 2.1

提出締め切り：8月9日(金)

提出場所：数学事務室カウンター前のボックス