

Probability and Mathematical Statistics A

(確率統計基礎講義 A)

Tuesday 3-4: SCI B501

April 18, 2017

1 Introduction

1.1 Definition and properties of probability space

Definition 1.1 (Probability space)

(Ω, \mathcal{B}, P) is called a *probability space* if the following conditions (i) and (ii) hold :

(i) \mathcal{B} is a σ -field of Ω , that is, \mathcal{B} is a family of subsets of Ω , and (B1) ~ (B3) are satisfied.

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

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

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

Ω and (Ω, \mathcal{B}) are called a *sample space* and a *measurable space*, respectively. Elements of \mathcal{B} (subsets of Ω) are called *events*.

(ii) P is a *probability measure* on (Ω, \mathcal{B}) , that is, P is a real valued function on \mathcal{B} , and (P1) ~ (P3) holds.

(P1) $0 \leq P(A) \leq 1$ for any $A \in \mathcal{B}$.

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

(P3) If $A_1, A_2, \dots \in \mathcal{B}$ and $A_i \cap A_j = \emptyset$ ($i \neq j$) $\Rightarrow P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$.

Theorem 1.1 (Properties of probability spaces)

(Ω, \mathcal{B}, P) : a probability space

$\{A_n\}_{n=1,2,\dots}$: a sequence of events in \mathcal{B}

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

$$(2) A_n \subset A_{n+1} \quad (n = 1, 2, \dots) \Rightarrow P\left(\bigcup_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n).$$

$$(3) \ A_n \supset A_{n+1} \ (n = 1, 2, \dots) \Rightarrow P\left(\bigcap_{n=1}^{\infty} A_n\right) = \lim_{n \rightarrow \infty} P(A_n).$$

$$(4) \ \overline{\lim}_{n \rightarrow \infty} A_n = \underline{\lim}_{n \rightarrow \infty} A_n \Rightarrow P(\lim_{n \rightarrow \infty} A_n) = \lim_{n \rightarrow \infty} P(A_n).$$

Problem 1.1

Prove Theorem 1.1.

Theorem 1.2 (The first Borel–Cantelli lemma)

$\{A_n\}_{n=1,2,\dots}$: a sequence of events.

$$\sum_{n=1}^{\infty} P(A_n) < \infty \Rightarrow P(\overline{\lim}_{n \rightarrow \infty} A_n) = 0 \ (P(\underline{\lim}_{n \rightarrow \infty} A_n^c) = 1).$$

Theorem 1.3 (The second Borel–Cantelli lemma)

$\{A_n\}_{n=1,2,\dots}$: a sequence of *independent* events.

$$\sum_{n=1}^{\infty} P(A_n) = \infty \Rightarrow P(\overline{\lim}_{n \rightarrow \infty} A_n) = 1 \ (P(\underline{\lim}_{n \rightarrow \infty} A_n^c) = 0).$$

Definition 1.2 (Borel field)

The minimum σ -field which includes all open subsets of \mathbb{R} is called the (one dimensional) *Borel field*, which is denoted by \mathbb{B} . The measurable space (\mathbb{R}, \mathbb{B}) is called the *Borel space*.

Definition 1.3 (Random variable)

(Ω, \mathcal{B}, P) : a probability space

$X : \Omega \mapsto \mathbb{R}$

If X is *Borel measurable*, X is called a *random variable* on (Ω, \mathcal{B}, P) , which means

$$\forall B \in \mathbb{B}, X^{-1}(B) := \{\omega \in \Omega \mid X(\omega) \in B\} \in \mathcal{B}.$$

Here $P_X : B \in \mathbb{B} \mapsto P(X^{-1}(B))$ becomes a probability measure on (\mathbb{R}, \mathbb{B}) , which is called the *distribution* of X .

Definition 1.4 (Expectation)

X : a random variable

f : a Borel measurable function ($\forall B \in \mathbb{B}, f^{-1}(B) \in \mathbb{B}$)

$E[f(X)] = \int f(x)dP_X(x)$ is called the *expectation* of $f(X)$.

$E[X]$: the *mean* of X , $\text{Var}[X] = E[(X - E[X])^2]$: the *variance* of X .

Lemma 1.1 (Chebyshev's inequality)

X : a random variable such that $E[X]$ exists.

$$\forall a > 0, P(|X - E[X]| \geq a) \leq \frac{\text{Var}[X]}{a^2}$$

Definition 1.5 (Convergence in probability)

$\{X_n\}_{n=1,2,\dots}$: a sequence of random variables defined on (Ω, \mathcal{B}, P) .

X : a random variable defined on (Ω, \mathcal{B}, P) .

We say “ X_n converges to X in probability”, and denote “ $X_n \xrightarrow{p} X \ (n \rightarrow \infty)$ ” if

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

Example 1.1 (Weak law of large numbers)

$\{X_n\}_{n=1,2,\dots}$: a sequence of independent random variables on (Ω, \mathcal{B}, P)
 $E[X_i] = \mu, \text{Var}[X_i] = \sigma^2$ ($i = 1, 2, \dots; \mu, \sigma^2 \in \mathbb{R}$)

$$\Rightarrow \bar{X}_n := \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} \mu \quad (n \rightarrow \infty).$$

Problem 1.2

Prove Example 1.1 with using Chebyshev's inequality.

Definition 1.6 (Almost sure convergence)

$\{X_n\}_{n=1,2,\dots}$: a sequence of random variables defined on (Ω, \mathcal{B}, P) .

X : a random variable defined on (Ω, \mathcal{B}, P) .

We say " X_n converges to X almost surely", and denote " $X_n \xrightarrow{a.s.} X$ ($n \rightarrow \infty$)" if

$$\exists \Omega_0 \in \Omega \text{ s.t. } P(\Omega_0) = 1, \text{ and } \forall \omega \in \Omega_0, \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$$

1.2 Strong law of large numbers

Thoerem 1.4 (Kolmogorov's inequality)

$\{X_n\}_{n=1,2,\dots}$: a sequence of independent random variables on (Ω, \mathcal{B}, P) .

$S_j = X_1 + \dots + X_j$.

$E[X_j] = 0, j = 1, \dots, n \Rightarrow$

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

Thoerem 1.5 (Convergence of the partial sum)

$\{X_n\}_{n=1,2,\dots}$: a sequence of independent random variables on (Ω, \mathcal{B}, P) .

$S_j = X_1 + \dots + X_j$.

$E[X_n] = 0, n = 1, 2, \dots$ and $\sum_{n=1}^{\infty} \text{Var}[X_n] < \infty$

$\Rightarrow S_n = \sum_{k=1}^n X_k$ converges to a certain random variable almost surely.

Lemma 1.2 (Kronecker's lemma)

$\{m_n\}_{n=1,2,\dots}$: a sequence of positive numbers such that $m_n \leq m_{n+1}$ ($n = 1, 2, \dots$) and
 $\lim_{n \rightarrow \infty} m_n = \infty$.

$\{x_n\}$: a sequence of real numbers.

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n \frac{x_k}{m_k} < \infty \Rightarrow \lim_{n \rightarrow \infty} \frac{1}{m_n} \sum_{k=1}^n x_k = 0.$$

Thoerem 1.6

$\{X_n\}_{n=1,2,\dots}$: a sequence of independent random variables on (Ω, \mathcal{B}, P) .

$$E[X_n] = 0 \text{ and } \sum_{n=1}^{\infty} \frac{E[X_n^2]}{n^2} < \infty \Rightarrow \frac{1}{n} \sum_{k=1}^n X_k \xrightarrow{a.s.} 0 \quad (n \rightarrow \infty).$$

Thoerem 1.7 (Kolmogorov's strong law)

$\{X_n\}_{n=1,2,\dots}$: a sequence of independent random variables on (Ω, \mathcal{B}, P) .

$$E[X_n] = a, \text{Var}[X_n] \leq v, n = 1, 2, \dots \Rightarrow \frac{1}{n} \sum_{k=1}^n X_k \xrightarrow{a.s.} a (n \rightarrow \infty).$$

Problem 1.3

Prove Kolmogorov's strong law. (You can use Theorem 1.6 without proof.)

Thoerem 1.8 (Khinchin)

X_1, X_2, \dots : independent identically distributed random variables on (Ω, \mathcal{B}, P)

p : real number such that $2 > p \geq 1$

$$n^{-1/p} \sum_{k=1}^n (X_k - m) \xrightarrow{a.s.} 0 \Leftrightarrow E[|X_1|^p] < \infty \text{ and } m = E[X_1]$$

Lemma 1.3

X_1, X_2, \dots : independent identically distributed random variables on (Ω, \mathcal{B}, P)

p : real number such that $2 > p \geq 1$

Assume

$$E[|X_1|^p] < \infty \text{ and } E[X_1] = 0.$$

Define

$$Y_n(\omega) = \begin{cases} X_n(\omega), & |X_n(\omega)| \leq n^{1/p} \\ 0, & |X_n(\omega)| > n^{1/p} \end{cases}.$$

Then

$$\sum_{n=1}^{\infty} P(X_n \neq Y_n) < \infty, \quad (1.2)$$

$$\sum_{n=1}^{\infty} n^{-2/p} E[Y_n^2] < \infty, \quad (1.3)$$

$$\lim_{n \rightarrow \infty} n^{-1/p} \sum_{k=1}^n E[Y_k] = 0. \quad (1.4)$$

1.3 Central limit theorem

Definition 1.7 (Characteristic function)

X : a random variable

$\varphi_X(t) = E[e^{itX}]$ is called the *characteristic function* of X .

Thoerem 1.9

Let $\varphi_X(t)$ be a characteristic function. Then we have

$$(1) \varphi_X(0) = 1.$$

$$(2) |\varphi_X(t)| \leq 1.$$

$$(3) \varphi_X(t) \text{ is uniformly continuous}$$

(4) $\varphi_{cX+d}(t) = e^{itd}\varphi_X(ct)$. where c, d are constants.

(5) If $E(|X|^n) < \infty$, then $\varphi_X(t)$ is C^n -class and

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

Problem 1.4

Prove Theorem 1.9.

Lemma 1.4

(1) $\forall y \geq 0$,

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

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

where

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

Theorem 1.10 (Inversion formulae)

X : a random variable

F_X : the distribution function of X

φ_X : the characteristic function of X

If F_X is continuous at a and b ($a < b$), it holds that

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

Theorem 1.11 (one-to-one correspondence)

X_1, X_2 : random variables

μ_k : the distribution of X_k ($k = 1, 2$)

φ_k : the characteristic function of X_k ($k = 1, 2$)

Then it holds that

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

Problem 1.5

Cauchy distribution with the location parameter μ and the scale parameter σ is denoted as $Ca(\mu, \sigma)$, and defined by the following probability density function:

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

(1) Derive the characteristic function of $Ca(0, 1)$. (Hint: residue theorem)

(2) Show that if $X_1, \dots, X_n \stackrel{i.i.d.}{\sim} Ca(\mu, 1)$, $\bar{X}_n \sim Ca(\mu, 1)$.

Definition 1.8 (分布収束)

$\{X_n\}_{n=1,2,\dots}$: a sequence of random variables

X : a random variables

F_n : the distribution function of X_n ($n = 1, 2, \dots$)

F : the distribution function of X

We say “ X_n converges to X in distribution”, and denote “ $X_n \xrightarrow{d} X$ ($n \rightarrow \infty$)” if

$$\lim_{n \rightarrow \infty} F_n(x) = x$$

for any continuous point x of F .

Lemma 1.5

If $X_n \xrightarrow{d} X$ ($n \rightarrow \infty$), $\lim_{n \rightarrow \infty} E\{g(X_n)\} = E\{g(X)\}$ for any continuous and bounded function g .

Theorem 1.12 (Lévy's continuity theorem)

$\varphi_n(t)$: the characteristic function of a random variable X_n ($n = 1, 2, \dots$)

If $\varphi_n(t)$ converges to $\varphi(t)$ at each t and $\varphi(t)$ is continuous at $t = 0$, $\varphi(t)$ is the characteristic function of certain distribution P_X , and $X_n \xrightarrow{d} P_X$ ($n \rightarrow \infty$).

Lemma 1.6

Under the assumptions of Theorem 1.12, for any positive number ε , there exists A such that

$$P(|X_n| \leq A) > 1 - \varepsilon, \quad n = 1, 2, \dots \quad (1.5)$$

Lemma 1.7

For any real number x , it holds that

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

Theorem 1.13 (Central limit theorem (Lindeberg))

$X_{n,1}, X_{n,2}, \dots, X_{n,n}$: independent random variables for each n

Assume $E[X_{n,k}] = 0$, $\sum_{k=1}^n \text{Var}[X_{n,k}] = 1$ and

$$\forall \tau > 0, \quad \lim_{n \rightarrow \infty} \sum_{k=1}^n E[X_{n,k}^2 1_{|X_{k,n}|>\tau}] = 0, \quad (1.6)$$

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

Theorem 1.14 (Central limit theorem)

$\{X_n\}_{n=1,2,\dots}$: a sequence of independent and identically distributed random variables

Suppose

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

Then

$$Z_n = \frac{1}{\sqrt{n}\sigma} \sum_{j=1}^n (X_j - \mu) = \frac{\sqrt{n}(\bar{X} - \mu)}{\sigma} \xrightarrow{d} N(0, 1).$$

Problem 1.6

Prove Theorem 1.14.

2 最尤推定量の分布

Definition 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。

Definition 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。

Example 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。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、 $\boldsymbol{\theta} = (\mu, \sigma^2)$ 、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。

Definition 2.3 (カルバックー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

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

をカルバックー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、 $KL(f; g) = \infty$ と定義する。

Lemma 2.1

任意の g に対して、 $KL(f; g) \geq 0$ 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

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

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

$$L(\theta; \mathbf{x}) \quad (= f(\mathbf{x}; \theta)) \quad (2.7)$$

と表し, 尤度関数とよぶ.

Definition 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.

Problem 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.

Lemma 2.2

$\{X_n\}$ を (Ω, \mathcal{B}, P) 上の確率変数列とするとき, $X_n \xrightarrow{a.s} X$ 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,

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

である.

Thoerem 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

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

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 $\hat{\theta}_n \xrightarrow{a.s.} \theta_0$ ($n \rightarrow \infty$).

Thoerem 2.2 (漸近正規性 ; クラメールの十分条件)

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

$$\mathbb{E}_{\theta_0} \{H(X)\} \leq M$$

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

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N(0, J(\theta_0)^{-1}) \quad (2.8)$$

が成り立つ.

Example 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

$$\begin{aligned} & \sup_{\theta \in U_{\theta_*, \delta_0}} \left| \log \frac{1+x^2}{1+(x-\theta)^2} \right| \\ & \leq \log(1+x^2) + \log(1+(x-\theta_*+\delta)^2) \\ & \quad + \log(1+(x-\theta_*-\delta)^2), \\ & \mathbb{E}_{\theta_0} [\log\{1+(X_1 - \alpha)^2\}] < \infty \end{aligned}$$

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.

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

$k \geq 1$ のとき

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

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.

Example 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

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

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

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

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

$$\begin{aligned} \mathbf{x} \in \mathcal{W} &\Rightarrow H_0 \text{ を棄却する} \\ \mathbf{x} \notin \mathcal{W} &\Rightarrow H_0 \text{ を棄却しない} \end{aligned}$$

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

$$\begin{aligned} \beta(\theta; \mathcal{W}) &\quad (\theta \in \Theta_0), \\ 1 - \beta(\theta; \mathcal{W}) &\quad (\theta \notin \Theta_0) \end{aligned}$$

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,

$$H_0 : \theta = \theta_0, \quad H_1 : \theta = \theta_1 \quad (3.9)$$

となる.

Theorem 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, (3.9) 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.

Example 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 $\boldsymbol{\theta} = \boldsymbol{\theta}_0$ 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

$$\text{帰無仮説 } H_0 : \boldsymbol{\theta} = \boldsymbol{\theta}_0, \quad \text{対立仮説 } H_1 : \boldsymbol{\theta} \neq \boldsymbol{\theta}_0$$

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 $\hat{\boldsymbol{\theta}}_n$ が存在して, 尤度方程式

$$\mathbf{s}_n(\boldsymbol{\theta}) = \sum_{i=1}^n \frac{\log \partial f(X_i; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{0} \quad (3.10)$$

の解であるとする. このとき, 尤度比基準は

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

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

$$T_W = n(\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}_0)' J(\hat{\boldsymbol{\theta}}_n)(\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}_0)$$

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

$$T_S = \frac{1}{n} \mathbf{s}_n(\boldsymbol{\theta}_0)' J(\boldsymbol{\theta}_0)^{-1} \mathbf{s}_n(\boldsymbol{\theta}_0)$$

と定義される。適當な正則条件の下で

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

3.3 関数構造の検定

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

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

の検定問題を考える。ここで、 $\boldsymbol{\theta}(\boldsymbol{\xi})$ 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、 $\boldsymbol{\xi}$ 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 $\boldsymbol{\theta}_0 = \boldsymbol{\theta}(\boldsymbol{\xi}_0)$ であると仮定する。また、 Θ 全体での最尤推定量を $\hat{\boldsymbol{\theta}}_n$ 、帰無仮説の下での $\boldsymbol{\xi}$ の最尤推定量を $\hat{\boldsymbol{\xi}}_n$ とする。このとき、尤度比基準は

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

となる。

ワルド検定統計量、スコア検定統計量はそれぞれ、

$$\begin{aligned} T_W &= n\{\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n)\}' J(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))\{\hat{\boldsymbol{\theta}}_n - \boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n)\}, \\ T_S &= \frac{1}{n} \mathbf{s}_n(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))' J(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n))^{-1} \mathbf{s}_n(\boldsymbol{\theta}(\hat{\boldsymbol{\xi}}_n)) \end{aligned}$$

と定義される。このとき、適當な正則条件の下で

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