

Ch.6 統計的推定

§6.1 統計的推測

6.1.1 統計的推測の考え方

・ 母集団：分布 $f(x|\theta)$ に従う。

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} f(x|\theta)$: サイズ n の標本.
↓ ↓
 x_1, \dots, x_n : 実現値.

・ θ : パラメータ

・ 統計的点推定: θ を $X_1 \sim X_n$ の値に基づいて予測すること.

・ 区間推定: θ の入り可能性の高い区間を求めること.

・ 統計的仮説検定: 仮説の正しさを判断すること.

6.1.2 データの縮小

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} f(x|\theta)$.

$X = (X_1, \dots, X_n)$, $x = (x_1, \dots, x_n)$ とおく.

Def. (十分統計量)

X を $T(X)$ に縮小しても、 θ に関する情報は失われない.

$T(X)$: θ に関して十分統計量

def. $\Leftrightarrow T(x) = t$ をみたす x, t に対し、 $T(X) = t$ を与えたときの

$X = x$ の条件付き確率 $P(X = x | T(X) = t)$ が θ に依らない. \square

Th. (Neymanの因子分解定理)

$T(X)$: θ の十分統計量

$\Leftrightarrow f_X(x|\theta) = h(x)g(T(x)|\theta)$ とかける. □

Def. (指数型分布族)

pdfの族が

$$f(x|\theta) = h(x)c(\theta) \exp(\eta(\theta)^T \boldsymbol{\pi}(x))$$

の形になるとき, **指数型分布族** という □

ex) 正規分布, ガンマ分布, 2項分布, Poisson分布, 負の2項分布
は指数型分布族に入る.

§6.2 点推定量の導出方法

- パラメトリック・モデル $f(x|\theta)$ $\theta \in \mathbb{R}^k$.

θ を $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} f(x|\theta)$ から点推定.

θ の推定量を $\hat{\theta}(X)$ とかく.

6.2.1 モーメント法

- $X \sim f(x|\theta)$,

$\mathbb{E}[X] = \mu_1'(\theta)$, $\mathbb{E}[X^2] = \mu_2'(\theta)$, ..., $\mathbb{E}[X^k] = \mu_k'(\theta)$ とする.

- $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} f(x|\theta)$ によって,

大数の法則より $\frac{1}{n} \sum_{i=1}^n X_i^r \xrightarrow{P} \mathbb{E}[X^r]$ ($r=1, \dots, k$)

$$\rightarrow \begin{cases} \frac{1}{n} \sum_{i=1}^n X_i = \mu_1'(\theta) \\ \frac{1}{n} \sum_{i=1}^n X_i^2 = \mu_2'(\theta) \\ \vdots \\ \frac{1}{n} \sum_{i=1}^n X_i^k = \mu_k'(\theta) \end{cases}$$

を θ について解くことで $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_k)$ を得る.

これをモーメント推定量という.

ex $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \mathcal{N}(\mu, \sigma^2)$.

$$\mathbb{E}[X_1] = \mu, \quad \mathbb{E}[X_1^2] = \text{V}[X_1] + \mathbb{E}[X_1]^2 = \sigma^2 + \mu^2.$$

$$\begin{cases} \frac{1}{n} \sum_{i=1}^n X_i = \hat{\mu} \\ \frac{1}{n} \sum_{i=1}^n X_i^2 = \hat{\sigma}^2 + \hat{\mu}^2 \end{cases}$$

モーメント推定量は.

$$\hat{\mu} = \bar{X},$$

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 \\ &= \frac{1}{n} \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2 \right) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = S^2. \quad \square \end{aligned}$$

6.2.2 最大法

Def. (尤度函数)

$$\mathcal{L}(\theta | X) := \prod_{i=1}^n f(X_i | \theta) \text{ を 尤度函数 とし、}$$

$$\mathcal{Q}(\theta | X) := \log \mathcal{L}(\theta | X) = \sum_{i=1}^n \log f(X_i | \theta) \text{ を}$$

対数尤度函数 とし、

Def. (最大推定量)

$\hat{\theta}$: 最大推定量

$$\text{def. } \hat{\theta} = \underset{\theta}{\text{argmax}} \mathcal{L}(\theta | X) = \underset{\theta}{\text{argmax}} \mathcal{Q}(\theta | X). \quad \square$$

- MLEの候補: **尤度方程式** $\frac{\partial}{\partial \theta} L(\theta|X) = 0$ の解.

Prop. (MLEの不変性)

$\tau = g(\theta)$ の推定を考えると,

$\hat{\theta} : \theta$ の MLE $\Rightarrow \hat{\tau} = g(\hat{\theta}) : \tau$ の MLE. □

6.2.3 Bayes法.

- $f(x|\theta)$ で, θ : r.v. とみたり. pdf を仮定.

θ の **事前分布**: $\pi(\theta|\xi)$ (ξ : ハイパーパラメータ)

- モデル. $\begin{cases} X|\theta \sim f(x|\theta) \\ \theta \sim \pi(\theta|\xi) \end{cases}$

- $X=x$: given のとき. θ の **事後分布** は

$$\pi(\theta|x,\xi) = \frac{f(x|\theta)\pi(\theta|\xi)}{\int f(x|\theta)\pi(\theta|\xi)d\theta} \leftarrow X \text{ の周辺分布}$$

- $E[\theta|X]$: **Bayes推定量** $\pi(\theta|x,\xi)$ の E

$\hat{\theta} := \operatorname{argmax}_{\theta} \pi(\theta|x,\xi)$: **Bayes的最尤推定量**.

- $\pi(\theta|\xi)$ と $\pi(\theta|x,\xi)$ が 同じ分布族に入るような事前分布を

共役事前分布 といふ.

§6.3 推定量の評価.

6.3.1. 不偏性

Def. (不偏推定量)

推定量 $\hat{\theta}$ が θ の **不偏推定量**

def. $\Leftrightarrow \forall \theta, \mathbb{E}_{\theta}[\hat{\theta}(X)] = \theta.$ □

\uparrow θ に依存している

Def. (バイアス)

$\hat{\theta}$: θ の推定量. $\hat{\theta}$ の **バイアス** は,

$$\text{Bias}(\hat{\theta}) := \mathbb{E}_{\theta}[\hat{\theta}(X)] - \theta$$

で定めらる.

□

Def. (平均二乗誤差)

$\text{MSE}(\theta, \hat{\theta}) := \mathbb{E}[(\hat{\theta}(X) - \theta)^2]$ を **平均二乗誤差** といふ. □

Prop. (バイアス-バリエンス分解)

$$\text{MSE}(\theta, \hat{\theta}) = V[\hat{\theta}] + (\text{Bias}(\theta))^2.$$

□

Def. (BLUE)

$\hat{\theta} = \sum_{i=1}^n c_i X_i$ の形 (線形) の推定量が, 不偏かつ分散が最小とあるとき, $\hat{\theta}$ を BLUE (最良線形不偏推定量)

という. □

6.3.2 Fisher情報量と Cramér-Rao 不等式.

・ 不偏推定量の分散は どこまで小さくできるか?

→ Cramér-Rao の下限まで.

Def. (Fisher情報量)

$X_1, \dots, X_n \stackrel{i.i.d.}{\sim} f(x|\theta)$.

$$S_n(\theta, \mathbf{X}) := \frac{d}{d\theta} \ell(\mathbf{x}|\theta) = \frac{d}{d\theta} \sum_{i=1}^n \log f(x_i|\theta)$$

を スコア関数 といい, その2乗の期待値

$$I_n(\theta) := \mathbb{E}[S_n(\theta, \mathbf{X})^2] = \mathbb{E}\left[\left(\frac{d}{d\theta} \ell(\mathbf{x}|\theta)\right)^2\right]$$

を Fisher情報量 という. □

Prop. 次の三つの条件を仮定する:

(C1) $f(x|\theta)$ のサポート $\{x | f(x|\theta) > 0\}$ は θ に依らない.

(C2) $f(x|\theta)$ は θ に関して 2 階微分可能. さらに, $k=1, 2$ とし

$$\frac{d^k}{d\theta^k} \int f(x|\theta) dx = \int \frac{d^k}{d\theta^k} f(x|\theta) dx$$

(C3) $0 < I_1(\theta) < \infty$.

このとき, 次の成立:

(1) $E[S_1(\theta, X_1)] = 0$.

n 個のデータの Fisher 情報量は
1 個のデータのものの *n* 倍

(2) $I_n(\theta) = n I_1(\theta)$

(3) $I_1(\theta) = -E\left[\frac{d^2}{d\theta^2} \log f(X_1|\theta)\right]$. □

Th. (Cramér-Rao の不等式)

上の (C1) ~ (C3) を仮定する. $\hat{\theta} = \hat{\theta}(X)$: θ の不偏推定量.

$V[\hat{\theta}]$ が存在し

$$\frac{d}{d\theta} \int \hat{\theta}(x) f_n(x|\theta) dx = \int \hat{\theta}(x) \frac{d}{d\theta} f_n(x|\theta) dx$$

とする. このとき,

$\forall \theta, V_\theta[\hat{\theta}] \geq I_n(\theta)^{-1}$. □

Cramér-Rao の FPE

6.3.3 最大推定量の一致性と漸近正規性, 漸近有効性

Def. (一致性)

$X_1, X_2, \dots \stackrel{\text{i.i.d.}}{\sim} f(x|\theta)$. $\hat{\theta}_n = \hat{\theta}_n(X_1, \dots, X_n)$ とする.

$\hat{\theta}_n$: 一致性を示す

def. $\hat{\theta}_n \xrightarrow{P} \theta$. □

Prop. $\{a_n\}_{n=1}^{\infty} : a_n \nearrow \infty$.

$\exists U$: r.v. s.t. $a_n(\hat{\theta}_n - \theta) \xrightarrow{d} U$.

$\Rightarrow \hat{\theta}_n$: 一致性を示す. □

Def. (漸近分散, 漸近有効)

$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} \mathcal{N}(0, \sigma^2)$ となるとき, σ^2 を 漸近分散

という.

$\hat{\theta}_n$ の 漸近分散 が $\frac{1}{I_1(\theta)}$ のとき, i.e., Cramér-Rao の下界

$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} \mathcal{N}(0, \frac{1}{I_1(\theta)})$

のとき, $\hat{\theta}_n$ は 漸近有効 であるという. □