

応用統計学 2017 第7回 最尤推定

2017年11月22日(水)

清智也 sei@mist.i.u-tokyo.ac.jp

<http://ur0.pw/yTzt>

今回は、多くの統計モデルに対して汎用的に用いられる最尤推定量を扱う。

- 尤度関数, 最尤推定, 尤度方程式, 指数型分布族, 十分統計量, 凸関数¹。

演習問題

問題 7-1. 以下の各統計モデルに対する最尤推定量を求めよ。すなわち、与えられたデータ x_1, \dots, x_n に対して尤度関数 $L(\theta) = \prod_{t=1}^n f(x_t; \theta)$ を最大化する θ を求めよ。また、その不偏性を調べよ。

- (i) ポアソン分布 $f(x; \theta) = (\theta^x/x!)e^{-\theta}$, $x \in \mathbb{Z}_{\geq 0} = \{0, 1, \dots\}$.
- (ii) 正規分布 $f(x; \mu, \sigma^2) = (2\pi\sigma^2)^{-1/2}e^{-(x-\mu)^2/(2\sigma^2)}$, $x \in \mathbb{R}$, $\theta = (\mu, \sigma^2)$.
- (iii) 指数分布 $f(x; \theta) = \theta e^{-\theta x}$, $x > 0$.

問題 7-2. 以下の各統計モデルは指数型分布族であることを示せ。

- (i) Bernoulli 分布 (サイズ 1 の二項分布) $f(x; p) = p^x(1-p)^{1-x}$, $x \in \{0, 1\}$.
- (ii) 負の二項分布 $f(x; p) = \binom{r+x-1}{x} p^r(1-p)^x$, $x \in \mathbb{Z}_{\geq 0}$. ただし r は既知とする。
- (iii) カテゴリー数 k , サイズ 1 の多項分布 $f(\mathbf{x}; \mathbf{p}) = \prod_{i=1}^k p_i^{x_i}$, $x_i \in \{0, 1\}$, $\sum_{i=1}^k x_i = 1$.

問題 7-3 (順序統計量). X_1, \dots, X_n は独立同一分布に従い、それぞれの確率密度関数は $f(x; \theta) = \theta e^{-\theta x}$ ($x \geq 0$) であるとする。また、 X_1, \dots, X_n を小さい順に並べ替えて得られる確率変数列を $X_{(1)}, \dots, X_{(n)}$ とおく²。このようにして得られる $X_{(k)}$ ($1 \leq k \leq n$) は一般に順序統計量 (order statistic) と呼ばれる。以下の問いに答えよ。

- (i) $X_{(1)}, \dots, X_{(n)}$ の同時密度関数を求めよ。
- (ii) $1 < k < n$ とする。 $X_{(1)}, \dots, X_{(k)}$ のみが観測された場合の θ の最尤推定量を求めよ。

¹likelihood function, maximum likelihood estimator (MLE), likelihood equation, exponential family, sufficient statistic, convex function.

²正確には、確率空間 (Ω, \mathcal{F}, P) で定義された確率変数列 X_1, \dots, X_n に対し、根元事象 $\omega \in \Omega$ ごとに $X_1(\omega), \dots, X_n(\omega)$ を小さい順に並べ替えたものを $X_{(1)}(\omega), \dots, X_{(n)}(\omega)$ とおく。これによって確率変数列 $X_{(1)}, \dots, X_{(n)}$ が定義される。

問題 7-4 (やや難しい). 初回の宿題で実施したアンケートの回答時刻のデータを, 生存時間解析と呼ばれる考え方でモデリングしてみよう。受講者は全部で J 人おり, J は既知とする ($J = 122$)。各受講者の回答時刻は独立同一分布に従うと仮定する。また, ある特定の受講者一人について, 時刻 t まで回答しなかったという条件のもとで, 時刻 t から $t + dt$ の間に回答する確率を $\lambda(t)dt$ とおく。 $\lambda(t)$ はハザード関数 (hazard function) と呼ばれる。回答時刻の累積分布関数を $F(t)$, 密度関数を $f(t) = F'(t)$ とおくと,

$$\lambda(t) = \frac{f(t)}{1 - F(t)}$$

の関係がある (なぜか?)。また $1 - F(t)$ は生存関数 (survival function) と呼ばれる。

さて, アンケートの受付開始時刻を 0, 受付打ち切り時刻を c で固定し, 実際の回答者数を n , 回答のあった時刻を $t_1 < \dots < t_n$ とおく。ハザード関数を

$$\lambda(t) = \frac{\phi}{\eta} \left(\frac{t}{\eta} \right)^{\phi-1}, \quad \eta > 0, \quad \phi > 0, \quad (*)$$

と仮定したときの尤度関数を求めよ。また, 授業で集めたアンケートの回答時刻に対し, (η, ϕ) の最尤推定値を計算機で求めよ。なお, 式 (*) のハザード関数に対応する確率分布を Weibull 分布と呼ぶ。

宿題 7

問題 7-5. 指数型分布族

$$f(x; \boldsymbol{\theta}) = a(x)e^{\boldsymbol{\theta}'s(x) - \psi(\boldsymbol{\theta})}, \quad x \in \mathbb{R}, \quad \boldsymbol{\theta} \in \mathbb{R}^d,$$

において, $\psi(\boldsymbol{\theta})$ は $\boldsymbol{\theta}$ の凸関数であることを示せ。また, 狭義凸となるための条件を調べよ。