

Opakování a rozšíření pojmů z matematické statistiky

Parametrický model: Náhodný vektor X_1, \dots, X_n je rozdělen \Rightarrow distribuční funkcí $F(x, \theta)$. Tu známe až na hodnotu neznámého parametru $\theta \in \mathbb{R}^p$.

Úlohy matematické statistiky:

- bodový odhad parametru θ
- intervalový odhad -||-
- testy hypotéz o parametru θ

Porovnání

Někdy máis místo parametru θ nějaká jeho funkce, tzv. parametrická funkce $g: \mathbb{R}^p \rightarrow \mathbb{R}$.

Pr. Meduzim porci melok za 1 den = X_i , medti $X_i \sim Po(\lambda)$

λ = průměrná porci melok za 1 den

$g(\lambda) = \frac{-\lambda}{2} = P(X_i = 0)$ -- pratepatobnost, že nedaný den nekone řádná meloka

Bodové odhady

Řekneme, že $T: \mathbb{R}^n \rightarrow \mathbb{R}^p$ je bodový odhad parametru θ , jestliže $T = T(X_1, \dots, X_n)$ je měřitelná funkce náh. vektoru X_1, \dots, X_n . Tedy T je náhodný vektor.

Oblasti bodových odhadů:

- T je nekraný odhad parametru θ , jestliže $ET = \theta, \forall \theta$.
- T je asymptoticky nekraný -||-, jestliže $\lim_{n \rightarrow \infty} ET = \theta, \forall \theta$.
- T je konzistentní -||- (jestliže $T \xrightarrow{P} \theta, \forall \theta$, tj. $\forall \epsilon > 0 P(\|T - \theta\| > \epsilon) \xrightarrow{n \rightarrow \infty} 0, \forall \theta$).

Dále uvažujme jednorozměrný parametr $\theta \in \mathbb{R}$.

Příklad

$X_1 \sim \text{Bin}(N, p)$ je náh. výsledek n pokusů 1 z binomického rozdělení s parametry N (známí) a $p \in (0, 1)$ neznámí.

Chceme odhad parametrické funkce $\frac{1}{p}$.

$$P(X_1 = x) = \binom{N}{x} p^x (1-p)^{N-x}, \quad x = 0, 1, \dots, N.$$

Necht $T = T(X_1)$ je nekorektní odhad param. funkce $\frac{1}{p}$.

$$ET = \sum_{x=0}^N T(x) \binom{N}{x} p^x (1-p)^{N-x} = \frac{1}{p}, \quad \forall p \in (0, 1)$$

polynom stupně nejvýše N (známí p)

\Rightarrow faktorů funkce T neexistují, tedy neexistují nekorektní odhad param. funkce $\frac{1}{p}$.

Který odhad je (nej)lepší?

Necht T_1 a T_2 jsou nekorektní odhady parametru θ . Řekneme, že T_1 je *rychlejší* (lepší) než T_2 , jestliže $DT_1 \leq DT_2, \forall \theta$.

Řekneme, že T_1 je *nejlepší* nekorektní odhad parametru θ , jestliže $DT_1 \leq DT^*$, $\forall \theta$ a pro střední T^* nekorektní odhad parametru θ .

A co pro odhady, které nejsou nekorektní?

Pak se jako měřítko průměrné čtvercové chyby $MSE(T_1) = E(T_1 - \theta)^2 = DT_1 + (ET_1 - \theta)^2$.

T_1, T_2 jsou odhady parametru θ . T_1 je *rychlejší* než T_2 , jestliže $MSE(T_1) \leq MSE(T_2), \forall \theta$.

Ukážeme-li nejlepší odhad parametru θ neexistuje!

Příklad

Nechť X_1, \dots, X_n je n.ř. náh. vektor $N(\mu, \sigma^2)$, kde $\mu \in \mathbb{R}$ a $\sigma^2 > 0$ jsou neznámé parametry. Májme-li náš odhad parametru σ^2 (μ je rušivý parametr).

$$T_1 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \dots \text{rychlý rozptyl}$$

JE NESTRANNÝ

$$T_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \dots \text{maximálně věrohodný odhad}$$

NEJÍ NESTRANNÝ

} Který z nich je "lepší"?

$$\text{MSE}(T_1) = \text{DT}_1 = D\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2\right) = \frac{1}{(n-1)^2} \cdot DY = \frac{\sigma^4 \cdot 2(n-1)}{(n-1)^2} = \frac{2\sigma^4}{n-1}$$

$$\text{viz. 1.2} \quad \frac{Y}{\sigma^2} \sim \chi_{n-1}^2 \Rightarrow EY = \sigma^2 \cdot E\chi_{n-1}^2 = \sigma^2(n-1)$$

$$DY = \sigma^4 D\chi_{n-1}^2 = \sigma^4 \cdot 2(n-1)$$

$$\text{MSE}(T_2) = \text{DT}_2 + (ET_2 - \sigma^2)^2 = \frac{1}{n^2} DY + \left(\frac{n-1}{n} \sigma^2 - \sigma^2\right)^2 = \frac{\sigma^4 \cdot 2(n-1)}{n^2} + \frac{\sigma^4}{n^2} = \frac{\sigma^4(2n-1)}{n^2}$$

$$ET_2 = E\left(\frac{n-1}{n} T_1\right) = \frac{n-1}{n} \cdot \sigma^2$$

$$\text{viz. 1.2} \quad \text{MSE}(T_1) > \text{MSE}(T_2)$$

$$\frac{2\sigma^4}{n-1} > \frac{\sigma^4(2n-1)}{n^2}$$

$$2n^2 > 2n^2 - n - 2n + 1$$

$$n > \frac{1}{3}$$

} Tedy střední čtvercová chyba odhadu T_2 je menší než odhadu T_1 .

Metody pro odhady parametrů

I) Metoda momentů

uvážme opět $\Theta \in \mathbb{R}^p$ p -rozměrný neznámý parametr

necht k tejšího řádu momenty $\mu_k = \mu_k(\Theta) = EX_i^k$ pro $k=1, 2, \dots, p$

jejich přírodnými odhady jsou vzájemné momenty $M_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ pro $k=1, 2, \dots, p$

$\tilde{\Theta}$ je odhad parametru Θ metodou momentů, jedliže řeší rovnice p rovnic p rovnic p neznámých: $\mu_k(\tilde{\Theta}) = M_k$, $k=1, \dots, p$.

Příklad

Necht X_1, \dots, X_n je náhodný výběr ze ZIP rozdělení s param. funkcí:

$$P(X=0) = \pi + (1-\pi)e^{-\lambda}$$

$$P(X=x) = (1-\pi)e^{-\lambda} \frac{\lambda^x}{x!}, \quad x=1, 2, \dots$$

kde $\pi \in [0, 1]$ a $\lambda > 0$ jsou neznámé parametry. Odhadněte je metodou momentů

$$EX_i = (1-\pi) \cdot \lambda \stackrel{!}{=} M_1$$

$$EX_i^2 = (1-\pi)(\lambda + \lambda^2) \stackrel{!}{=} M_2$$

$$M_1(1+\lambda) = M_2$$

$$\tilde{\lambda} = \frac{M_2}{M_1} - 1, \quad \tilde{\pi} = 1 - \frac{(M_1)^2}{M_2 - M_1}$$