

Ukázky pořadí a pořádkových statistik

X_1, \dots, X_m je n.h. vzájemně nezávislá distribucí funkce F a hustotou f .

vektor $(X_{(1)}, X_{(2)}, \dots, X_{(m)})^T$... vektor pořádkových statistik

$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(m)}$... $X_{(i)}$ je i -lá pořádková statistika (i -lé nejmenší pozorování)

Teorem

Hustota n.h. veličiny $X_{(k)}$ je rovna $f_{(k)}(x) = m \binom{m-1}{k-1} F(x)^{k-1} (1-F(x))^{m-k} \cdot f(x)$, pro $k=1, 2, \dots, m$.

Poznámka

Je-li X_1, \dots, X_m n.h. vzájemně z $B(0, 1)$, pak $f_{(k)}(x) = m \binom{m-1}{k-1} x^{k-1} (1-x)^{m-k}$, $0 \leq x \leq 1$ a $EX_{(k)} = \frac{k}{m+1}$ a $DX_{(k)} = \frac{k(m-k+1)}{(m+1)^2(m+2)}$.

R_i je pořadí n.o. X_i v n.h. vzájemně X_1, \dots, X_m , jestliže $R_i = \sum_{j=1}^m \mathbb{1}_{\{X_j \leq X_i\}}$.

$R = (R_1, \dots, R_m)^T$ je vektor pořadí

Teorem

a) $P(R = \pi) = \frac{1}{m!}$, kde π je libovolná permutace čísel $\{1, \dots, m\}$.

$$b) P(R_i = j) = \frac{1}{m} \quad \forall i, j = 1, \dots, m$$

$$P(R_i = j) = \sum_{R_1, \dots, R_m \neq j} P(R_1 = r_1, \dots, R_i = j, \dots, R_m = r_m) = \frac{(m-1)!}{m!} = \frac{1}{m}$$

$$c) P(R_i = k, R_j = l) = \frac{1}{m(m-1)}, \quad \forall i \neq j, k \neq l$$

$$d) ER_i = \frac{m+1}{2}$$

$$ER_i = 1 \cdot \frac{1}{m} + 2 \cdot \frac{1}{m} + \dots + m \cdot \frac{1}{m} = \frac{1}{m} (1 + 2 + \dots + m) = \frac{1}{m} \cdot \frac{m(m+1)}{2} = \frac{m+1}{2}$$

$$e) DR_i = \frac{m^2 - 1}{12}$$

$$ER_i^2 = 1^2 \cdot \frac{1}{m} + 2^2 \cdot \frac{1}{m} + \dots + m^2 \cdot \frac{1}{m} = \frac{1}{m} (1^2 + 2^2 + \dots + m^2) = \frac{1}{m} \cdot \frac{m(m+1)(2m+1)}{6} = \frac{2m^2 + 3m + 1}{6}$$

$$DR_i = ER_i^2 - (ER_i)^2 = \frac{2m^2 + 3m + 1}{6} - \left(\frac{m+1}{2}\right)^2 = \frac{m^2 - 1}{12}$$

$$f) C(R_i, R_j) = -\frac{m+1}{12} \quad (i \neq j)$$

g) R_i je invariantní vůči posunutí, tj. volíme pořadí (R_1, \dots, R_m) pro (X_1, \dots, X_m) je stejný i pro $(X_1 + c, \dots, X_m + c)$, $\forall c \in \mathbb{R}$.

Poznámka

F_j spojitá $\Rightarrow X_i = X_j \Rightarrow$ pravd. 0, tedy $R_i = R_j \Rightarrow$ pravd. 0 (nemohou nastat různé hodnoty).

o praxi ale metoda $X_i = X_j$ může nastat

• randomizace: má-li mít skupina pozorování stejný pořadí, pak se každému pozorování přiřadí hodnota pořadí ve skupině

-1, 5, 3, 3, 2, 1, -2	X	} pořadové hodnoty podle Junguji i nadále lze změny
2, 7, 5-6, 4, 3, 1	R	
5, 6	\Rightarrow pravd. $\frac{1}{2}$	
6, 5	\Rightarrow pravd. $\frac{1}{2}$	

• metoda průměrných pořadí (midranks): každému hodnotě pozorování se přiřadí průměrné pořadí celé skupiny

-1, 5, 3, 3, 2, 1, -2	X	} nutná modifikace hodnot
2, 7, 5,5, 5,5, 4, 3, 1	R	

Dvoustranné testy (o střední hodnotě)

klíčový: dvoustranný t-test

model: X_1, \dots, X_m máh. sčít. z $N(\mu_1, \sigma^2)$ } oba sčít. vzájemně nezávislé
 Y_1, \dots, Y_m máh. sčít. z $N(\mu_2, \sigma^2)$

$$H_0: \mu_1 = \mu_2$$

$$H_a: \mu_1 \neq \mu_2 \quad (\text{příp. } \mu_1 > \mu_2, \mu_1 < \mu_2)$$

roboční model: X_1, \dots, X_m máh. syst. s distribuční funkcí F } oba syst. mají jiné rozdělení
 Y_1, \dots, Y_m -||- G }

$H_0: F(x) = G(x), \forall x \in \mathbb{R}$

$H_1: G(x) = F(x - \Delta), \forall x \in \mathbb{R}$ pro nějaké $\Delta \neq 0$ (případně $\Delta > 0, \Delta < 0$)

Ročníky

- je-li F ^{dif. funkce} ~~lokálně~~ normálního rozdělení \Rightarrow model dvoustranného z -testu
- distribuční F a G se liší jen posunem.

Konstrukce pořadových testů

Čredpřehledně nejprve, než známe distribuční funkce F , resp. hustotu f . Budeme hledat "optimální" pořadový test pro dané rozdělení.

uvažujeme sdružený máh. syst. $(X_1, \dots, X_m, Y_1, \dots, Y_m)$ a označíme jej $(Z_1, \dots, Z_m, Z_{m+1}, \dots, Z_{m+m})$. Dalo bych $N = m + m$.
 R_1 R_m R_{m+1} R_{m+m}

označíme $R_i = \sum_{j=1}^N \mathbb{1}_{\{Z_j \leq Z_i\}}$ pořadí Z_i ve sdruženém systému Z_1, \dots, Z_N .

Definujeme testovou statistiku $S_N^f = \sum_{i=m+1}^N a_N(R_i, f)$. Testový testovací statistiku S_N^f je lokálně nejvíce výstižný pořadový test H_0 proti H_1 .

$a_N(i, g)$ je funkce pořadí $\{1, 2, \dots, n\}$ závislá na hodnotě g (skóre)

$a_N(i, g) = E \varphi(U_{(i)}, g)$, kde $U_{(1)} \leq U_{(2)} \leq \dots \leq U_{(N)}$ je uspořádaný máh. vzor z $Rs(0, 1)$ o rozsahu N .

$$\varphi(u, g) = -\frac{g'(\bar{F}^{-1}(u))}{g(\bar{F}^{-1}(u))}, \quad 0 < u < 1.$$

$$a_N(i, g) = E \varphi(U_{(i)}, g) = -\int_0^1 \frac{g'(\bar{F}^{-1}(u))}{g(\bar{F}^{-1}(u))} \cdot N \binom{N-1}{i-1} u^{i-1} (1-u)^{N-i} du \quad \text{často obtížné spočítat} \Rightarrow \text{použijeme heur. přibližné skóre}$$

$$a_N^*(i, g) = \varphi(E U_{(i)}, g) = \varphi\left(\frac{i}{N+1}, g\right) = -\frac{g'(\bar{F}^{-1}(\frac{i}{N+1}))}{g(\bar{F}^{-1}(\frac{i}{N+1}))}.$$

a definujeme ležoucí statistiku $S_N^{*g} = \sum_{i=m+1}^N a_N^*(R_i, g)$.

Teorem

S_N^g a S_N^{*g} jsou asymptoticky ekvivalentní, tj. $\frac{E(S_N^g - S_N^{*g})^2}{D S_N^g} \xrightarrow{N \rightarrow \infty} 0$.

Příklady

a) $f(x) = \frac{e^{-x}}{(1+e^{-x})^2}$, $x \in \mathbb{R}$... hustota logistického rozdělení

$$\varphi(\mu, f) = -\frac{f'(F^{-1}(\mu))}{f(F^{-1}(\mu))} = 2\mu - 1, \quad a_N^*(i, f) = \varphi\left(\frac{i}{N+1}, f\right) = \frac{2i}{N+1} - 1$$

$$S_N^{*f} = \sum_{i=m+1}^N a_N^*(R_i, f) = \sum_{i=m+1}^N \frac{2 \cdot R_i}{N+1} - 1 = \frac{2}{N+1} \sum_{i=m+1}^N R_i - m$$

kumulativní
„slučité“ Wilcoxonovo test

... Wilcoxonův test (je lokálně nejvíce výstižný pořádkový test pro n.h. slyby z logistického rozdělení lineární transformací).

b) $f(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}}$, $x \in \mathbb{R}$... hustota normálního rozdělení

$$\varphi(\mu, f) = \underline{\Phi}^{-1}(\mu), \quad a_N^*(i, f) = \underline{\Phi}^{-1}\left(\frac{i}{N+1}\right), \quad \text{kde } \underline{\Phi}^{-1} \text{ je kvantilová funkce } N(0, 1).$$

$$S_N^{*f} = \sum_{i=m+1}^N \underline{\Phi}^{-1}\left(\frac{R_i}{N+1}\right) \quad \dots \text{van der Waerdenův test}$$

c) $f(x) = \frac{1}{2} \cdot e^{-|x|}$, $x \in \mathbb{R}$... hustota Laplaceova (dvojitě exponenciálního) rozdělení

$$\varphi(\mu, f) = \text{sign}\left(\mu - \frac{1}{2}\right), \quad S_N^{*f} = \sum_{i=m+1}^N \text{sign}\left(\frac{R_i}{N+1} - \frac{1}{2}\right) \quad \dots \text{mediánový test}$$

V praxi ale budeme měřit. Proto se snažíme „lipnout“, jak by mohla vypadat.

Uvolíme tedy funkci $\varphi: [0,1] \rightarrow \mathbb{R}$ měřící, nekonečnou a integrovatelnou se čtvercem, tj. $\int_0^1 \varphi^2(u) du < \infty$.

a definujeme náhodný $a_N(i) = \varphi\left(\frac{i}{N+1}\right)$ a testovou statistiku $S_N = \sum_{i=m+1}^N a_N(R_i) = \sum_{i=m+1}^N \varphi\left(\frac{R_i}{N+1}\right)$.

Potřebujeme rozhodnout, která statistika za platnosti H_0 , abychom určili kritický obor.

Černé rozhodnutí:

náhodný pořadí $(R_1, \dots, R_N)^T$ má diskrétní rovnoměrné rozdělení na množině $\{1, \dots, N\} \Rightarrow$ náhodná σ transformace \Rightarrow rozdělení statistiky S_N

společně hledáme testové statistiky pro každou z $N!$ permutací čísel $\{1, \dots, N\} \rightarrow$ pravděpodobnostní funkce S_N (rovněž márovné).

$$\begin{matrix} Z_1, \dots, Z_m, Z_{m+1}, \dots, Z_N \\ R_1, \dots, R_m, R_{m+1}, \dots, R_N \end{matrix} \rightarrow S_N = \sum_{i=m+1}^N a_N(R_i)$$

Začíná jen na m pořadí \Rightarrow náhodná množina m pořadí z čísel $\{1, \dots, N\}$, tj. celkem $\binom{N}{m}$ možností (každá stejně pravděpodobná \Rightarrow prav. $\frac{1}{\binom{N}{m}}$)

společně hledáme testové statistiky pro každou z $\binom{N}{m}$ možností, jak z množiny $\{1, \dots, N\}$ vybrat m čísel. \Rightarrow prav. S_N (za platnosti H_0) \Rightarrow kvantily (kvantilová funkce) Q_α .

$\bullet H_1: D \neq 0$ $(S_N < Q_{\frac{\alpha}{2}} \text{ nebo } S_N > Q_{1-\frac{\alpha}{2}}) \Rightarrow$ zamítnutí H_0

$\bullet H_1: D > 0$ $(S_N > Q_{1-\alpha}) \Rightarrow$ zamítnutí H_0

$\bullet H_1: D < 0$ $(S_N < Q_\alpha) \Rightarrow$ zamítnutí H_0