

## Testy nezávislosti

klauzuly:  $(X_1, Y_1)^T, (X_2, Y_2)^T, \dots, (X_m, Y_m)^T$  je náhodný výběr z dvourozměrného normálního rozdělení.

označme  $\rho$  korelační koeficient mezi  $X_i$  a  $Y_i$

$H_0: \rho = 0$  ( $X_i$  a  $Y_i$  jsou nezávislé)

$H_1: \rho \neq 0$  (příp.  $\rho > 0, \rho < 0$ )

Pearsonův (výběrový) korelační koeficient 
$$r = \frac{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \cdot \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

$T = \sqrt{n-2} \cdot \frac{r}{\sqrt{1-r^2}} \stackrel{H_0}{\sim} t(n-2)$ .

zobecněný model:  $(X_1, Y_1)^T, \dots, (X_m, Y_m)^T$  je náhodný výběr z dvourozměrného spojitého rozdělení s distribuční funkcí  $F(x, y)$

označme  $F_1(x)$  marginální distribuční funkci a  $f_1(x)$  marginální hustotu máh. uhiány  $X_i$ ,

$F_2(y)$       -||-       $f_2(y)$       -||-       $Y_i$ .

$H_0: F(x, y) = F_1(x) \cdot F_2(y)$  ( $X_i$  a  $Y_i$  jsou nezávislé)

$H_1: F(x, y) \neq F_1(x) \cdot F_2(y)$

## Kombinace pořadových testů

Nejprve uvažujme, že známe funkce  $F_1(x)$  a  $F_2(y)$ , resp. hustoty  $f_1(x)$  a  $f_2(y)$ .

Označme  $R_i$  pořadí  $X_i$  mezi  $X_1, \dots, X_m$

a  $S_i$  pořadí  $Y_i$  mezi  $Y_1, \dots, Y_m$ .

Zobecně nejprvejší pořadový test  $H_0$  proti  $H_1$  je určen testovou statistikou  $S_n^{(1,2)} = \sum_{i=1}^m a_m(R_i, f_1) \cdot a_m(S_i, f_2)$ .

Skóre  $a_m(i, f)$  můžeme opět definovat přeměnou  $E\psi(U_{(i)}, f)$ , nebo pomocí aproxičních skóre  $\psi(EU_{(i)}, f) = \psi\left(\frac{i}{m+1}, f\right)$ .

$$\psi(u, f) = -\frac{f'(F^{-1}(u))}{f(F^{-1}(u))}, \quad 0 < u < 1.$$

V praxi ale marginální hustoty  $f_1$  a  $f_2$  neznáme. Zvolíme proto funkce  $\varphi, \psi: [0, 1] \rightarrow \mathbb{R}$  neklesající, nekonzantní a integrovalné se čtvercem a definujeme

$$a_m^{(1)}(i) = \varphi\left(\frac{i}{m+1}\right) \quad S_m = \sum_{i=1}^m a_m^{(1)}(R_i) \cdot a_m^{(2)}(S_i) = \sum_{i=1}^m \varphi\left(\frac{R_i}{m+1}\right) \cdot \psi\left(\frac{S_i}{m+1}\right)$$

$$a_m^{(2)}(i) = \psi\left(\frac{i}{m+1}\right)$$

Jak určíme rozdělení testové statistiky  $S_m$  za platnosti  $H_0$ ?

permutační princip:

- položíme  $R_1=1, R_2=2, \dots, R_m=m$

- pro každou permutaci pořadí  $S_1, S_2, \dots, S_m$ , tj. čísel  $\{1, 2, \dots, m\}$  spočítáme hodnotu  $S_m$  (testové statistiky)  $\rightarrow$  pravd. funkce  $S_m$  za platnosti  $H_0$

Výpočetná náročnost pro  $m$  střední  $\rightarrow$  asymptotická aproximace.

Poznámka

Ma platnosti  $H_0$  platí:

$$ES_m = \frac{1}{m} \left( \sum_{i=1}^m a_m^{(1)}(i) \right) \cdot \left( \sum_{j=1}^m a_m^{(2)}(j) \right), \quad DS_m = \frac{1}{m-1} \left( \sum_{i=1}^m (a_m^{(1)}(i) - \bar{a}^{(1)})^2 \right) \cdot \left( \sum_{j=1}^m (a_m^{(2)}(j) - \bar{a}^{(2)})^2 \right).$$

Lemma

Ma platnosti  $H_0$  má testová statistika  $S_m$  asymptoticky normální rozdělení  $N(ES_m, DS_m)$  při  $m \rightarrow \infty$ .

Poznámka

Rozptyl  $DS_m$  můžeme aproximovat pomocí  $m \left( \int_0^1 (\psi(u) - \bar{\psi})^2 du \right) \left( \int_0^1 (\psi(u) - \bar{\psi})^2 du \right)$ .

## Příklady

a)  $f_1(x) = f_2(x) = \frac{e^{-x}}{(1+e^{-x})^2}, x \in \mathbb{R}$  hustota logistického rozdělení

$$\varphi(u, g) = 2u - 1$$

$$a_m^{(1)}(i) = a_m^{(2)}(i) = \frac{2i}{m+1} - 1$$

$$S_m^{\text{hrb}} = \sum_{i=1}^m \left( \frac{2R_i}{m+1} - 1 \right) \cdot \left( \frac{2S_i}{m+1} - 1 \right) = \sum_{i=1}^m \left( \frac{4R_i \cdot S_i}{(m+1)^2} - \frac{2R_i}{m+1} - \frac{2S_i}{m+1} + 1 \right) = \frac{4}{(m+1)^2} \sum_{i=1}^m R_i \cdot S_i - \frac{2}{m+1} \cdot \frac{m(m+1)}{2} - \frac{2}{m+1} \cdot \frac{m(m+1)}{2} + m =$$

$$= \frac{4}{(m+1)^2} \sum_{i=1}^m R_i \cdot S_i - m \quad \dots \text{Dovršil se Spearmanovými korelačním koeficientem}$$

$$r_D = \frac{\frac{1}{m-1} \sum_{i=1}^m (R_i - \bar{R}) \cdot (S_i - \bar{S})}{\sqrt{\frac{1}{m-1} \sum_{i=1}^m (R_i - \bar{R})^2 \cdot \frac{1}{m-1} \sum_{i=1}^m (S_i - \bar{S})^2}} \quad \dots = \text{Pearsonův korelační koeficient z porádků } (R_1, S_1)^T, (R_2, S_2)^T, \dots, (R_m, S_m)^T$$

Ma rozdíl od Pearsonova korelačního koeficientu měří pouze lineární závislost, ale i závislost popsanou pomocí monotonních transformací.

## Poznámka

$$\sum_{i=1}^m R_i = \sum_{i=1}^m S_i = 1 + \dots + m = \frac{m(m+1)}{2} \Rightarrow \bar{R} = \bar{S} = \frac{m+1}{2}$$

$$\sum_{i=1}^m R_i^2 = \sum_{i=1}^m S_i^2 = 1^2 + \dots + m^2 = \frac{m(m+1)(2m+1)}{6} \Rightarrow \sum_{i=1}^m (R_i - \bar{R})^2 = \sum_{i=1}^m R_i^2 - m \cdot (\bar{R})^2 = \frac{m(m+1)(2m+1)}{6} - m \cdot \left( \frac{m+1}{2} \right)^2 = \sum_{i=1}^m (S_i - \bar{S})^2$$

$$r_D = \frac{12}{m(m^2-1)} \sum_{i=1}^m R_i \cdot S_i - 3 \frac{m+1}{m-1} \quad -1 \leq r_D \leq 1$$

$$r_D = 1 - \frac{6}{m^3-m} \sum_{i=1}^m (R_i - S_i)^2$$

La platnosti  $H_0$  plati:  $E r_D = 0$ ,  $D r_D = \frac{1}{m-1}$  a  $r_D \approx N\left(0, \frac{1}{m-1}\right)$ .

b)  $f_1(x) = f_2(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}}$ ,  $x \in \mathbb{R}$  hustota normálneho rozdelenia

$$\Psi(\mu, \sigma) = \Phi^{-1}(\mu)$$

$$a_m^{(1)}(i) = a_m^{(2)}(i) = \Phi^{-1}\left(\frac{i}{m+1}\right)$$

$$S_m = \sum_{i=1}^m \Phi^{-1}\left(\frac{R_i}{m+1}\right) \cdot \Phi^{-1}\left(\frac{S_i}{m+1}\right) \quad \dots \text{van der Waerden's test}$$

La platnosti  $H_0$  plati pri  $m \rightarrow \infty$   $S_m \approx N\left(0, \frac{1}{m-1} \left\{ \sum_{i=1}^m \left[ \Phi^{-1}\left(\frac{i}{m+1}\right) \right]^2 \right\}^2\right)$ .

c) Kendallovo  $\tau$

$$\tau = \frac{\sum_{i \neq j} \text{sign}(R_i - R_j) \cdot \text{sign}(S_i - S_j)}{m(m-1)}$$

$$-1 \leq \tau \leq 1$$

- je to porádová štatistika, ale nemá lineárnu.

$$\tau = \frac{a - b}{\binom{n}{2}}$$

(kde  $a$  je počet koncordantních párů  $(x_i, y_i)$ , tj.  $x_i > x_j \wedge y_i > y_j$  nebo  $x_i < x_j \wedge y_i < y_j$ .  
 $b$  je počet diskordantních párů  $(x_i, y_i)$ , tj.  $x_i > x_j \wedge y_i < y_j$  nebo  $x_i < x_j \wedge y_i > y_j$ .)

### Poznámka

Projektivní Kendallova  $\tau$  do prostoru lineárních pořadových statistik je až na násobek Spearmanův korelační koeficient.

Pro platnosti  $H_0$  platí:  $E\tau = 0$ ,  $D\tau = \frac{2(2n+5)}{9n(n-1)}$  a  $\tau \approx N(0, D\tau)$  pro  $n \rightarrow \infty$ .