

Cvičení 11 – Korelační analýza

Výběrový Spearmanův koeficient pořadové korelace: $r_s = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$,

kde n je rozsah dvourozměrného náhodného výběru $(X_1, Y_1), \dots, (X_n, Y_n)$, R_i pořadí náhodné veličiny X_i a Q_i pořadí náhodné veličiny Y_i , $i = 1, \dots, n$.

Testování nezávislosti ordinálních veličin

Na hladině významnosti α testujeme H_0 : X, Y jsou pořadově nezávislé náhodné veličiny proti H_1 : X, Y jsou pořadově závislé náhodné veličiny

Jako testová statistika slouží Spearmanův koeficient pořadové korelace r_s .

H_0 zamítáme na hladině významnosti α , když $|r_s| \geq r_{s,1-\alpha/2}(n)$, kde $r_{s,1-\alpha/2}(n)$ je kritická hodnota, kterou pro $\alpha = 0,05$ nebo $0,01$ a $n \leq 30$ najdeme v tabulkách.

Asymptotická varianta testu

Pro $n > 20$ lze použít testovou statistiku $T_0 = \frac{r_s \sqrt{n-2}}{\sqrt{1-r_s^2}} \approx t(n-2)$ za platnosti H_0 .

Kritický obor $W = (-\infty, -t_{1-\alpha/2}(n-2)) \cup (t_{1-\alpha/2}(n-2), \infty)$

Výběrový Pearsonův koeficient korelace: $R_{12} = \frac{S_{12}}{S_1 S_2}$ pro $S_1 S_2 > 0, = 0$ jinak

Testování nezávislosti intervalových a poměrových veličin

Důležitý předpoklad: daný náhodný výběr $(X_1, Y_1), \dots, (X_n, Y_n)$ pochází z dvourozměrného normálního rozložení s koeficientem korelace ρ . Pak jsou pojmy „stochastická nezávislost“ a „nekorelovanost“ ekvivalentní.

Na hladině významnosti α testujeme H_0 : X, Y jsou stochasticky nezávislé náhodné veličiny (tj. $\rho = 0$) proti H_1 : X, Y jsou stochasticky závislé náhodné veličiny (tj. $\rho \neq 0$).

Testová statistika $T_0 = \frac{R_{12} \sqrt{n-2}}{\sqrt{1-R_{12}^2}} \sim t(n-2)$ za platnosti H_0 .

Kritický obor: $W = (-\infty, -t_{1-\alpha/2}(n-2)) \cup (t_{1-\alpha/2}(n-2), \infty)$

Porovnání koeficientu korelace s danou konstantou

Testujeme $H_0: \rho = c$ proti $H_1: \rho \neq c$.

Pro $n \geq 10$: testová statistika $U = \left(Z - \frac{1}{2} \ln \frac{1+c}{1-c} - \frac{c}{2(n-1)} \right) \sqrt{n-3} \approx N(0,1)$ za platnosti H_0 ,

přičemž $Z = \frac{1}{2} \ln \frac{1+R_{12}}{1-R_{12}}$ je tzv. Fisherova Z-transformace.

Kritický obor: $W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$.

Porovnání dvou korelačních koeficientů

Máme dva nezávislé náhodné výběry o rozsazích n a n^* z dvourozměrných normálních rozložení s korelačními koeficienty ρ a ρ^* . Testujeme $H_0: \rho = \rho^*$ proti $H_1: \rho \neq \rho^*$.

Označme R_{12} výběrový korelační koeficient 1. výběru a R_{12}^* výběrový korelační koeficient 2.

výběru. Položme $Z = \frac{1}{2} \ln \frac{1+R_{12}}{1-R_{12}}$ a $Z^* = \frac{1}{2} \ln \frac{1+R_{12}^*}{1-R_{12}^*}$.

Platí-li H_0 , pak testová statistika $U = \frac{Z - Z^*}{\sqrt{\frac{1}{n-3} + \frac{1}{n^*-3}}}$ má asymptoticky rozložení $N(0,1)$.

Kritický obor: $W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$.

Interval spolehlivosti pro koeficient korelace

$(d, h) = \text{tgh} \left(Z \mp \frac{u_{1-\alpha/2}}{\sqrt{n-3}} \right)$, přičemž $\text{tgh } x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$.

Příklad 1.: (viz př. 11.5.2 ze skript) 12 různých softwarových firem nabízí speciální programové vybavení pro vedení účetnictví. Jednotlivé programy byly posouzeny odbornou komisí složenou z počítačových odborníků a komisí složenou z profesionálních účetních. Úkolem bylo doporučit vhodný program na základě stanovení pořadí jednotlivých programů. Výsledky posouzení:

Produkt firmy číslo	1	2	3	4	5	6	7	8	9	10	11	12
Pořadí dle odborníků	6	7	1	8	4	2,5	9	12	10	2,5	5	11
Pořadí dle účetních	4	5	2	10	6	1	7	11	8	3	12	9

Vypočtěte Spearmanův koeficient pořadové korelace a na hladině významnosti 0,05 testujte hypotézu, že hodnocení obou komisí jsou nezávislá.

Příklad 2.: Pět mužů, kteří bydlí v jednom panelovém domě, se rozhodlo zjistit a zapsat svou hmotnost [kg] a výšku [cm]. Zapsané hodnoty jsou: (76, 170), (86, 177), (73, 169), (84, 174), (79, 175). Najděte realizaci výběrového koeficientu korelace a na hladině významnosti 0,05 testujte hypotézu, že hmotnost a výška jsou nezávislé veličiny proti oboustranné alternativě. Pro úsporu času máte uvedeny tyto číselné realizace: $s_1^2 = 29,3$, $s_2^2 = 11,5$, $s_{12} = 16,5$.

Příklad 3.: V pedagogicko – psychologické poradně bylo vyšetřeno 12 hochů a 15 dívek. Mimo jiné byla zjišťována jejich verbální složka IQ a performační složka IQ. Předpokládáme, že v obou skupinách dětí se zjištěná data řídí dvourozměrným normálním rozložením, v prvním případě s koeficientem korelace ρ , ve druhém případě s koeficientem korelace ρ^* . Ve skupině hochů nabyl výběrový koeficient korelace mezi verbálním a performačním IQ hodnoty 0,6033, u dívek pak 0,5833.

a) Sestrojte 95% asymptotický interval spolehlivosti pro ρ .

b) Na hladině významnosti 0,05 testujte $H_0: \rho = \rho^*$ proti oboustranné alternativě $H_0: \rho \neq \rho^*$.