

M5VM05 Statistické modelování

12. Analýza závislosti dvou veličin

Jan Koláček (kolacek@math.muni.cz)

Ústav matematiky a statistiky, Přírodovědecká fakulta, Masarykova univerzita, Brno



Motivace

Při zpracování dat se velmi často setkáme s úkolem zjistit, zda dvě náhodné veličiny jsou stochasticky nezávislé. Např. nás může zajímat, zda ve sledované populaci je barva očí a barva vlasů nezávislá nebo zda počet dnů absence a věk pracovníka jsou nezávislé. Testování hypotézy o nezávislosti se provádí různými způsoby podle toho, jakého typu jsou dané náhodné veličiny – zda jsou nominální, ordinální, intervalové či poměrové.

Zpravidla chceme také zjistit intenzitu případné závislosti sledovaných dvou veličin. K tomuto účelu byly zkonstruovány různé koeficienty, které nabývají hodnot od 0 do 1 (resp. od -1 do 1). Čím je takový koeficient bližší 1 (resp. -1), tím je závislost mezi danými dvěma veličinami silnější a čím je bližší 0, tím je slabší.

Testování nezávislosti nominálních veličin

Nechť X, Y jsou dvě nominální náhodné veličiny. Nechť X nabývá variant $x_{[1]}, \dots, x_{[r]}$ a Y nabývá variant $y_{[1]}, \dots, y_{[s]}$. Pořídíme dvourozměrný náhodný výběr rozsahu n z rozložení, kterým se řídí dvourozměrný diskrétní náhodný vektor (X, Y) . Zjištěné absolutní četnosti n_{jk} dvojice variant $(x_{[j]}, y_{[k]})$ uspořádáme do kontingenční tabulky:

| | y | $y_{[1]} \dots y_{[s]}$ | $n_j.$ |
|-----------|----------|-------------------------|----------|
| x | n_{jk} | | |
| $x_{[1]}$ | | $n_{11} \dots n_{1s}$ | $n_{1.}$ |
| \vdots | | | ... |
| $x_{[r]}$ | | $n_{r1} \dots n_{rs}$ | $n_{r.}$ |
| $n_{.k}$ | | $n_{.1} \dots n_{.s}$ | n |

Testování nezávislosti nominálních veličin

Testujeme hypotézu $H_0 : X, Y$ jsou stochasticky nezávislé náhodné veličiny proti $H_1 : X, Y$ nejsou stochasticky nezávislé náhodné veličiny. Testová statistika má tvar:

$$K = \sum_{j=1}^r \sum_{k=1}^s \frac{\left(n_{jk} - \frac{n_{j \cdot} \cdot n_{\cdot k}}{n} \right)^2}{\frac{n_{j \cdot} \cdot n_{\cdot k}}{n}}.$$

Platí-li H_0 , pak K se asymptoticky řídí rozložením $\chi^2((r-1)(s-1))$. Hypotézu o nezávislosti veličin X, Y tedy zamítáme na asymptotické hladině významnosti α , když $K \geq \chi^2_{1-\alpha}((r-1)(s-1))$.

Definice 1

Výraz $\frac{n_{j \cdot} \cdot n_{\cdot k}}{n}$ se nazývá **teoretická četnost**.

Poznámka 2 (Podmínka dobré approximace)

Teoretické četnosti aspoň v 80% případů nabývají hodnoty větší nebo rovné 5 a ve zbylých 20% neklesnou pod 2. Není-li splněna podmínka dobré approximace, doporučuje se slučování některých variant.

Měření síly závislosti

Definice 3

Cramérův koeficient je tvaru

$$V = \sqrt{\frac{K}{n(m-1)}},$$

kde $m = \min\{r, s\}$. Tento koeficient nabývá hodnot mezi 0 a 1. Čím blíže je 1, tím je těsnější závislost mezi X a Y. Čím blíže je 0, tím je tato závislost volnější.

Příklad

Příklad 1

V sociologickém průzkumu byl z uchazečů o studium na vysokých školách pořízen náhodný výběr rozsahu 360. Mimo jiné se zjišťovala sociální skupina, ze které uchazeč pochází a typ školy, na kterou se hlásí. Výsledky jsou zaznamenány v kontingenční tabulce:

| Typ školy | Sociální skupina | | | | n_j |
|-------------|------------------|-----|-----|-----|-------|
| | I | II | III | IV | |
| univerzitní | 50 | 30 | 10 | 50 | 140 |
| technický | 30 | 50 | 20 | 10 | 110 |
| ekonomický | 10 | 20 | 30 | 50 | 110 |
| n_k | 90 | 100 | 60 | 110 | 360 |

Na asymptotické hladině významnosti 0,05 testujte hypotézu o nezávislosti typu školy a sociální skupiny. Vypočtěte Cramérův koeficient.

Příklad

Řešení

$$\begin{aligned}\frac{n_1 \cdot n_1}{n} &= \frac{140 \cdot 90}{360} = 35, \quad \frac{n_1 \cdot n_2}{n} = \frac{140 \cdot 100}{360} = 38,9, \quad \frac{n_1 \cdot n_3}{n} = \frac{140 \cdot 60}{360} = 23,3, \\ \frac{n_1 \cdot n_4}{n} &= \frac{140 \cdot 110}{360} = 42,8, \quad \frac{n_2 \cdot n_1}{n} = \frac{110 \cdot 90}{360} = 27,5, \quad \frac{n_2 \cdot n_2}{n} = \frac{110 \cdot 100}{360} = 30,6, \\ \frac{n_2 \cdot n_3}{n} &= \frac{110 \cdot 60}{360} = 18,3, \quad \frac{n_2 \cdot n_4}{n} = \frac{110 \cdot 110}{360} = 33,6, \quad \frac{n_3 \cdot n_1}{n} = \frac{110 \cdot 90}{360} = 27,5, \\ \frac{n_3 \cdot n_2}{n} &= \frac{110 \cdot 100}{360} = 30,6, \quad \frac{n_3 \cdot n_3}{n} = \frac{110 \cdot 60}{360} = 18,3, \quad \frac{n_3 \cdot n_4}{n} = \frac{110 \cdot 110}{360} = 33,6 \\ K &= \frac{(50-35)^2}{35} + \frac{(30-38,9)^2}{38,9} + \dots + \frac{(50-33,6)^2}{33,6} = 76,84,\end{aligned}$$

$r = 3, s = 4, \chi^2_{0,95}(6) = 12,6$. Protože $K \geq 12,6$, hypotézu o nezávislosti typu školy a sociální skupiny zamítáme na asymptotické hladině významnosti 0,05. Cramérův koeficient:

$$V = \sqrt{\frac{76,4}{360 \cdot 2}} = 0,3267.$$

Čtyřpolní tabulky

Speciálním případem kontingenčních tabulek, kdy $r = s = 2$ jsou čtyřpolní tabulky. Zavádí se pro ně jiné značení.

Definice 4

Necht' $r = s = 2$. Pak hovoříme o **čtyřpolní kontingenční tabulce** a používáme označení: $n_{11} = a, n_{12} = b, n_{21} = c, n_{22} = d$.

| x | y | | $n_j.$ |
|-----------|-----------|-----------|---------|
| | $y_{[1]}$ | $y_{[2]}$ | |
| $x_{[1]}$ | a | b | $a + b$ |
| $x_{[2]}$ | c | d | $c + d$ |
| $n_{.k}$ | $a + c$ | $b + d$ | n |

Čtyřpolní tabulky

Ve čtyřpolních tabulkách používáme charakteristiku $OR = \frac{ad}{bc}$, která se nazývá **podíl šancí (odds ratio)**. Můžeme si představit, že pokus se provádí za dvojích různých okolností a může skončit buď úspěchem nebo neúspěchem.

| Výsledek pokusu | okolnosti | | n_j |
|-----------------|-----------|---------|---------|
| | I | II | |
| úspěch | a | b | $a + b$ |
| neúspěch | c | d | $c + d$ |
| $n_{.k}$ | $a + c$ | $b + d$ | n |

Poměr počtu úspěchů k počtu neúspěchů (tzv. šance) za prvních okolností je $\frac{a}{c}$, za druhých okolností je $\frac{b}{d}$.

Definice 5

Podíl šancí (odds ratio) ve čtyřpolní tabulce je definován jako $OR = \frac{ad}{bc}$.

Čtyřpolní tabulky

Věta 6

Pomocí $100(1 - \alpha)\%$ asymptotického intervalu spolehlivosti pro podíl šancí lze na asymptotické hladině významnosti α testovat hypotézu o nezávislosti nominálních veličin X a Y . Asymptotický $100(1 - \alpha)\%$ interval spolehlivosti pro přirozený logaritmus skutečného podílu šancí má meze:

$$\ln OR \pm \sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}} u_{1-\alpha/2}.$$

Jestliže po odlogaritmování nezahrne interval spolehlivosti 1, pak hypotézu o nezávislosti zamítneme na asymptotické hladině významnosti α .

Příklad

Příklad 2

U 135 uchazečů o studium na jistou fakultu byl hodnocen dojem, jakým zapůsobili na komisi u ústní přijímací zkoušky. Na asymptotické hladině významnosti 0,05 testujte hypotézu, že přijetí na fakultu nezávisí na dojmu u přijímací zkoušky.

| přijetí | dojem | | n.j. |
|---------|-------|--------|------|
| | dobrý | špatný | |
| ano | 17 | 11 | 28 |
| ne | 39 | 58 | 97 |
| n.k | 56 | 69 | 125 |

Příklad

Řešení

$$OR = \frac{ad}{bc} = \frac{17 \cdot 58}{11 \cdot 39} = 2,298, \ln OR = 0,832,$$

$$\sqrt{\frac{1}{a} + \frac{1}{b} + \frac{1}{c} + \frac{1}{d}} = \sqrt{\frac{1}{17} + \frac{1}{11} + \frac{1}{39} + \frac{1}{58}} = 0,439, u_{0,975} = 1,96$$

$$\ln dm = 0,832 - 0,439 \cdot 1,96 = -0,028, \ln hm = 0,832 + 0,439 \cdot 1,96 = 1,692 \Rightarrow dm = e^{-0,028} = 0,972, hm = e^{1,692} = 5,433$$

Protože interval (0,972; 5,433) obsahuje číslo 1, na asymptotické hladině významnosti 0,05 nezamítáme hypotézu o nezávislosti dojmu u přijímací zkoušky a přijetí na fakultu.

Testování nezávislosti ordinálních veličin

Nechť X, Y jsou dvě ordinální náhodné veličiny. Pořídíme dvourozměrný náhodný výběr $(X_1, Y_1), \dots, (X_n, Y_n)$ z rozložení, jímž se řídí náhodný vektor (X, Y) .

Označíme R_i pořadí náhodné veličiny X_i a Q_i pořadí náhodné veličiny $Y_i, i = 1, \dots, n$. Testujeme hypotézu $H_0 : X, Y$ jsou pořadově nezávislé náhodné veličiny proti oboustranné alternativě $H_1 : X, Y$ jsou pořadově závislé náhodné veličiny (resp. proti levostranné alternativě H_1 : mezi X a Y existuje nepřímá pořadová závislost resp. proti pravostranné alternativě H_1 : mezi X a Y existuje přímá pořadová závislost).

Testová statistika se nazývá Spearmanův koeficient pořadové korelace a má tvar:

$$r_s = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (R_i - Q_i)^2.$$

Testování nezávislosti ordinálních veličin

H_0 zamítáme na hladině významnosti α

- ① ve prospěch oboustranné alternativy, když $|r_S| \geq r_{S,1-\alpha}(n)$
- ② ve prospěch levostranné alternativy, když $r_S \leq -r_{S,1-2\alpha}(n)$
- ③ ve prospěch pravostranné alternativy, když $r_S \geq r_{S,1-2\alpha}(n)$

$r_{S,1-\alpha}(n)$ je kritická hodnota, kterou pro $\alpha = 0,05$ nebo $0,01$ a $n \leq 30$ najdeme v tabulkách.

Pro $n > 30$ H_0 zamítáme na asymptotické hladině významnosti α ve prospěch oboustranné alternativy, když

$$|r_s| \geq \frac{u_{1-\alpha/2}}{\sqrt{n-1}}$$

Poznámka 7

Spearmanův koeficient r_S současně měří sílu pořadové závislosti náhodných veličin X, Y . Nabývá hodnot z intervalu $\langle -1, 1 \rangle$. Čím je jeho hodnota bližší -1 (resp. 1), tím je silnější nepřímá (resp. přímá) pořadová závislost veličin X, Y . Čím je jeho hodnota bližší 0 , tím je slabší pořadová závislost veličin X, Y .

Příklad

Příklad 3

Dva lékaři hodnotili stav sedmi pacientů po též chirurgickém zákroku. Postupovali tak, že nejvyšší pořadí dostal nejtěžší případ.

| Číslo pacienta | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
|---------------------|---|---|---|---|---|---|---|
| Hodnocení 1. lékaře | 4 | 1 | 6 | 5 | 3 | 2 | 7 |
| Hodnocení 2. lékaře | 4 | 2 | 5 | 6 | 1 | 3 | 7 |

Vypočtěte Spearmanův koeficient r_S a na hladině významnosti 0,05 testujte hypotézu, že hodnocení obou lékařů jsou pořadově nezávislá.

Příklad

Řešení

$$\begin{aligned} r_s &= 1 - \frac{6}{7(7^2 - 1)} \left[(4-4)^2 + (1-2)^2 + (6-5)^2 \right. \\ &\quad \left. + (3-1)^2 + (2-3)^2 + (7-7)^2 \right] \\ &= 0,857 \end{aligned}$$

Kritická hodnota: $r_{S,0,95}(7) = 0,745$. Protože $0,857 \geq 0,745$, nulovou hypotézu zamítáme na hladině významnosti 0,05.

Testování nezávislosti intervalových či poměrových veličin

Pearsonův koeficient korelace

V teorii pravděpodobnosti byl zaveden Pearsonův koeficient korelace náhodných veličin X, Y (které jsou aspoň intervalového charakteru) vztahem

$$R(X, Y) = \begin{cases} \frac{C(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}} & \text{pro } \sqrt{D(X)}, \sqrt{D(Y)} > 0, \\ 0 & \text{jinak.} \end{cases}$$

Připomeneme jeho vlastnosti:

- ① $R(X, X) = 1$
- ② $R(X, Y) = R(Y, X)$
- ③ $R(a + bX, c + dY) = \text{sgn}(bd)R(X, Y)$
- ④ $-1 \leq R(X, Y) \leq 1$ a rovnosti je dosaženo tehdy a jen tehdy, když existují reálné konstanty a, b , kde $b \neq 0$ tak, že $P(Y = a + bX) = 1$, přičemž $R(X, Y) = 1$ pro $b > 0$ a $R(X, Y) = -1$ pro $b < 0$.

Z těchto vlastností plyne, že $R(X, Y)$ je vhodnou mírou těsnosti lineárního vztahu náhodných veličin X, Y .

Výběrový koeficient korelace

Definice 8

Z dvouzměrného náhodného výběru $(X_1, Y_1), \dots, (X_n, Y_n)$ můžeme stanovit:

❶ výběrové průměry $M_1 = \frac{1}{n} \sum_{i=1}^n X_i$, $M_2 = \frac{1}{n} \sum_{i=1}^n Y_i$,

❷ výběrové rozptyly

$$S_1^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_1)^2, S_2^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - M_2)^2,$$

❸ výběrovou kovarianci

$$S_{12} = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_1)(Y_i - M_2)$$

S jejich pomocí zavedeme **výběrový koeficient korelace**

$$R_{12} = \frac{S_{12}}{S_1 S_2} \quad \text{pro } S_1 S_2 > 0.$$

Koeficient korelace dvourozměrného normálního rozdělení

Věta 9

Nechť náhodný vektor (X, Y) má dvourozměrné normální rozložení s hustotou

$$\varphi(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)} \left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - 2\rho \frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \left(\frac{y-\mu_2}{\sigma_2}\right)^2 \right]},$$

přičemž $\mu_1 = E(X), \mu_2 = E(Y), \sigma_1^2 = D(X), \sigma_2^2 = D(Y), \rho = R(X, Y)$.

Pak marginální hustoty jsou:

$$\varphi_1(x) = \frac{1}{\sigma_1\sqrt{2\pi}} e^{\frac{(x-\mu_1)^2}{2\sigma_1^2}}, \quad \varphi_2(y) = \frac{1}{\sigma_2\sqrt{2\pi}} e^{\frac{(y-\mu_2)^2}{2\sigma_2^2}}.$$

Věta 10

Je-li $\rho = 0$, pak pro $\forall (x, y) \in \mathbb{R}^2 : \varphi(x, y) = \varphi_1(x)\varphi_2(y)$, tedy náhodné veličiny X, Y jsou stochasticky nezávislé. Jinými slovy: stochastická nezávislost složek X, Y normálně rozloženého náhodného vektoru je ekvivalentní jejich nekorelovanosti.

Koeficient korelace dvourozměrného normálního rozdělení

Věta 11

Testujeme $H_0 : \rho = 0$ proti oboustranné alternativě $H_1 : \rho \neq 0$ (resp. proti levostranné alternativě $H_1 : \rho < 0$ resp. proti pravostranné alternativě $H_1 : \rho > 0$).

Testová statistika má tvar:

$$T = \frac{R_{12}\sqrt{n-2}}{\sqrt{1-R_{12}^2}}.$$

Platí-li nulová hypotéza, pak $T \sim t(n-2)$.

Kritický obor pro test H_0 proti oboustranné alternativě:

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

proti levostranné alternativě: $W = (-\infty, -t_{1-\alpha}(n-2))$

a proti pravostranné alternativě: $W = (t_{1-\alpha}(n-2), \infty)$. H_0 zamítáme na hladině významnosti α , když $T \in W$.

Příklad

Příklad 4

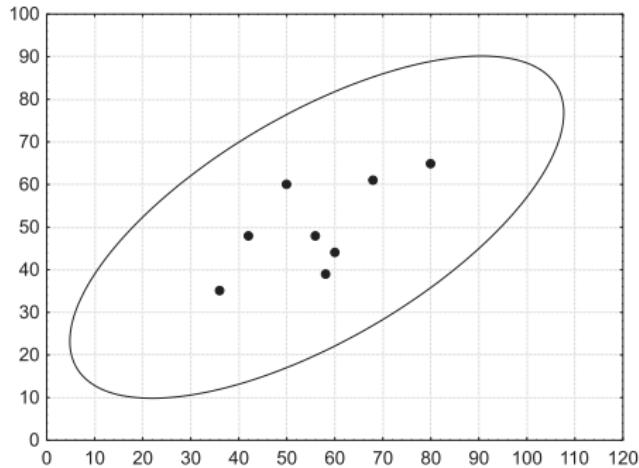
Máme k dispozici výsledky testů ze dvou předmětů zjištěné u osmi náhodně vybraných studentů určitého oboru.

| Číslo studenta | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
|------------------------|----|----|----|----|----|----|----|----|
| Počet bodů v 1. testu | 80 | 50 | 36 | 58 | 42 | 60 | 56 | 68 |
| Počet bodů ve 2. testu | 65 | 60 | 35 | 39 | 48 | 44 | 48 | 61 |

Na hladině významnosti 0,05 testujte hypotézu, že výsledky obou testů nejsou kladně korelované.

Příklad

Řešení. Nejprve se musíme přesvědčit, že uvedené výsledky lze považovat za realizace náhodného výběru z dvourozměrného normálního rozložení. Lze tak učinit orientačně pomocí dvourozměrného tečkového diagramu. Tečky by měly vytvořit elipsovity obrazec.



Obrázek : Dvourozměrný tečkový diagram

Příklad

Obrázek svědčí o tom, že předpoklad dvourozměrné normality je oprávněný a že mezi počty bodů z 1. a 2. testu bude existovat určitý stupeň přímé lineární závislosti.

Testujeme $H_0 : \rho = 0$ proti pravostranné alternativě $H_1 : \rho > 0$.

Výpočtem zjistíme: $R_{12} = 0,6668$, $T = 2,1917$. V tabulkách najdeme $t_{0,95}(6) = 1,9432$. Kritický obor: $W = \langle 1,9432; \infty \rangle$. Protože $T \in W$, hypotézu o neexistenci kladné korelace výsledků z 1. a 2. testu zamítáme na hladině významnosti 0,05.

Porovnání koeficientu korelace s danou konstantou

Věta 12

Nechť c je reálná konstanta. Testujeme $H_0 : \rho = c$ proti $H_1 : \rho \neq c$. Test je založen na statistice

$$U = \left(Z - \frac{1}{2} \ln \frac{1+c}{1-c} - \frac{c}{2(n-1)} \right) \sqrt{n-3},$$

která má za platnosti H_0 pro $n \geq 10$ asymptoticky rozložení $N(0,1)$, přičemž

$$Z = \frac{1}{2} \ln \frac{1+R_{12}}{1-R_{12}}$$

je tzv. Fisherova Z-transformace. Kritický obor pro test H_0 proti oboustranné alternativě tedy je $W = (-\infty, -u_{1-\alpha/2}] \cup [u_{1-\alpha/2}, \infty)$. H_0 zamítáme na asymptotické hladině významnosti α , když $U \in W$.

Příklad

Příklad 5

U 600 vzorků rudy byl stanoven obsah železa dvěma analytickými metodami s výběrovým koeficientem korelace 0,85. V literatuře se uvádí, že koeficient korelace těchto dvou metod má být 0,9. Na asymptotické hladině významnosti 0,05 testujte hypotézu $H_0 : \rho = 0,9$ proti $H_1 : \rho \neq 0,9$.

Řešení

$$Z = \frac{1}{2} \ln \frac{1+0,85}{1-0,85} = 1,2562,$$

$$U = \left(1,2562 - \frac{1}{2} \ln \frac{1+0,9}{1-0,9} - \frac{0,9}{2(600-1)} \right) \sqrt{600-3} = -5,2976,$$

$$u_{0,975} = 1,96, \quad W = (-\infty, -1,96) \cup (1,96, \infty).$$

Protože $U \in W$, H_0 zamítáme na asymptotické hladině významnosti 0,05.

Porovnání dvou koeficientů korelace

Věta 13

Nechť jsou dány 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 koeficient korelace 1. výběru a R_{12}^* výběrový koeficient korelace 2. výběru. Položme

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

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 pro test H_0 tedy je

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

Příklad

Příklad 6

Lékařský výzkum se zabýval sledováním koncentrací látek A a B v moči pacientů trpících určitou ledvinovou chorobou. U 100 zdravých jedinců činil výběrový koeficient korelace mezi koncentracemi obou látek 0,65 a u 142 osob trpících zmíněnou chorobou byl 0,37. Na asymptotické hladině významnosti 0,05 testujte hypotézu, že se koeficienty korelace v obou skupinách neliší.

Řešení

$$Z = \frac{1}{2} \ln \frac{1+0,65}{1-0,65} = 0,7753,$$

$$Z^* = \frac{1}{2} \ln \frac{1+0,37}{1-0,37} = 0,3884,$$

$$U = \frac{0,7753 - 0,3884}{\sqrt{\frac{1}{100-3} + \frac{1}{142-3}}} = 2,9242,$$

$$u_{0,975} = 1,96, W = (-\infty, -1,96) \cup (1,96, \infty).$$

Protože $U \in W, H_0$ zamítáme na asymptotické hladině významnosti 0,05.

Interval spolehlivosti pro koeficient korelace

Věta 14

Jestliže dvouozměrný náhodný výběr rozsahu n pochází z dvouozměrného normálního rozložení, jehož koeficient korelace se příliš neliší od nuly ($|\rho| < 0,5$) a rozsah výběru je dostatečně velký ($n \geq 100$), lze odvodit, že $100(1 - \alpha)\%$ interval spolehlivosti pro ρ má meze

$$R_{12} \pm u_{1-\alpha/2} \frac{1 - R_{12}^2}{\sqrt{n-3}}.$$

Nejsou-li uvedené podmínky splněny, pak nelze tento vzorec použít, protože rozložení výběrového korelačního koeficientu je příliš zešikmené. V takovém případě využijeme následujícího tvrzení.

Interval spolehlivosti pro koeficient korelace

Věta 15

Náhodná veličina

$$Z = \frac{1}{2} \ln \frac{1 + R_{12}}{1 - R_{12}}$$

má i při malém rozsahu výběru přibližně normální rozložení se střední hodnotou

$$E(Z) = \frac{1}{2} \ln \frac{1 + \rho}{1 - \rho} + \frac{\rho}{2(n - 1)}$$

(2. sčítanec lze při větším n zanedbat) a rozptylem $D(Z) = \frac{1}{n-3}$.

Standardizací veličiny Z dostaneme veličinu

$$U = \frac{Z - E(Z)}{\sqrt{D(Z)}},$$

která má asymptoticky rozložení $N(0, 1)$.

Tudíž $100(1 - \alpha)\%$ asymptotický interval spolehlivosti pro $\frac{1}{2} \ln \frac{1 + \rho}{1 - \rho}$ bude mít meze $Z \pm \frac{u_{1-\alpha/2}}{\sqrt{n-3}}$. Interval spolehlivosti pro ρ pak dostaneme zpětnou transformací.

Interval spolehlivosti pro koeficient korelace

Poznámka 16

Jelikož $Z = \operatorname{arctgh} R_{12}$, dostáváme $R_{12} = \operatorname{tgh} Z$ a meze intervalu spolehlivosti pro ρ můžeme psát ve tvaru

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

Příklad

Příklad 7

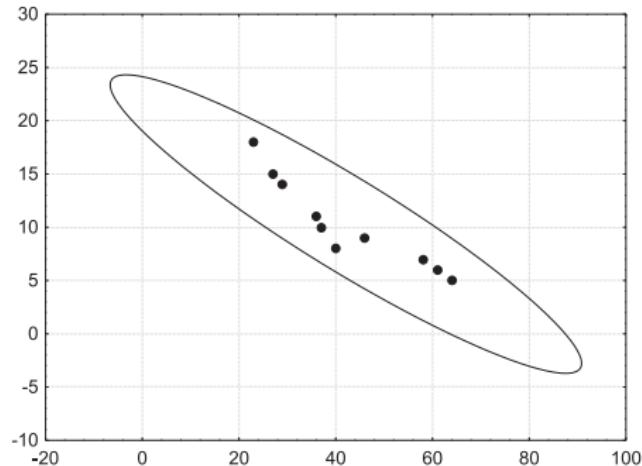
Pracovník personálního oddělení určité firmy zkoumá, zda existuje vztah mezi počtem dní absence za rok (veličina Y) a věkem pracovníka (veličina X). Proto náhodně vybral údaje o 10 pracovnících.

| Č.prac. | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
|---------|----|----|----|----|----|----|----|----|----|----|
| X | 27 | 61 | 37 | 23 | 46 | 58 | 29 | 36 | 64 | 40 |
| Y | 15 | 6 | 10 | 18 | 9 | 7 | 14 | 11 | 5 | 8 |

Za předpokladu, že uvedené údaje tvoří číselné realizace náhodného výběru rozsahu 10 z dvourozměrného normálního rozložení, vypočtěte výběrový koeficient korelace a na hladině významnosti 0,05 testujte hypotézu, že X a Y jsou nezávislé náhodné veličiny. Sestrojte 95% asymptotický interval spolehlivosti pro skutečný koeficient korelace ρ .

Příklad

Řešení. Předpoklad o dvourozměrné normalitě dat ověříme orientačně pomocí dvourozměrného tečkového diagramu, viz. Obr. 2.



Obrázek : Dvourozměrný tečkový diagram

Vzhled diagramu svědčí o tom, že předpoklad je oprávněný.

Příklad

Testujeme $H_0 : \rho = 0$ proti $H_1 : \rho \neq 0$. Vypočítáme $R_{12} = -0,9325$, tedy mezi věkem pracovníka a počtem dnů pracovní neschopnosti existuje silná nepřímá lineární závislost. Testová statistika: $T = -7,3053$, kvantil $t_{0,975}(8) = 2,306$, kritický obor $W = (-\infty, -2,306) \cup (2,306, \infty)$. Jelikož $T \in W$, zamítáme na hladině významnosti 0,05 hypotézu o nezávislosti veličin X a Y . Vypočítáme

$$Z = \frac{1}{2} \ln \frac{1 + R_{12}}{1 - R_{12}} = \frac{1}{2} \ln \frac{1 - 0,9325}{1 + 0,9325} = -1,6772.$$

Meze 95% asymptotického intervalu spolehlivosti pro ρ jsou $\text{tgh}(-1,6772 \pm \frac{1,96}{\sqrt{7}})$, tedy $-0,9842 < \rho < -0,7336$ s pravděpodobností přibližně 0,95.

Úlohy k procvičení

Příklad 1 (Testování nezávislosti nominálních veličin)

Na hladině významnosti 0,05 testujte hypotézu o nezávislosti pedagogické hodnosti a pohlaví a vypočtěte Cramérův koeficient, jsou-li k dispozici následující údaje:

| pohlaví | pedagogická hodnost | | |
|---------|---------------------|--------|----------|
| | odb. asistent | docent | profesor |
| muž | 32 | 15 | 8 |
| žena | 34 | 8 | 3 |

[hypotézu o nezávislosti pohlaví a pedagogické hodnosti nezamítáme, Cramérův koeficient: 0,187]

Úlohy k procvičení

Příklad 2 (Testování nezávislosti ordinálních veličin)

12 různých softwarových firem nabízí programy pro vedení účetnictví. Programy byly posouzeny odbornou komisí a komisí složenou z profesionálních účetních. Výsledky v 1. a 2. komisi: (6,4), (7,5), (1,2), (8,10), (4,6), (2.5,1), (9,7), (12,11), (10,8), (2.5,3), (5,12), (11,9). Vypočtěte Spearmanův koeficient pořadové korelace a na hladině významnosti 0,05 testujte hypotézu o nezávislosti pořadí v obou komisiích.

$$[r_s = 0,715, \text{nulovou hypotézu zamítáme}]$$

Úlohy k procvičení

Příklad 3 (Testování nezávislosti intervalových a poměrových veličin)

V dílně pracuje 15 dělníků, u nichž byl zjištěn počet směn odpracovaných za měsíc (veličina X) a počet zhotovených výrobků (veličina Y). Orientačně ověřte dvourozměrnou normalitu dat, vypočtěte výběrový koeficient korelace mezi X a Y , sestrojte pro něj 99% asymptotický interval spolehlivosti a na hladině 0,01 testujte hypotézu o nezávislosti X a Y .

| | | | | | | | | | | | | | | | |
|-----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| x | 20 | 21 | 18 | 17 | 20 | 18 | 19 | 21 | 20 | 14 | 16 | 19 | 21 | 15 | 15 |
| y | 92 | 93 | 83 | 80 | 91 | 85 | 82 | 98 | 90 | 60 | 73 | 86 | 96 | 64 | 81 |

$[r_{12} = \frac{s_{12}}{s_1 s_2} = 0,927$, hypotézu o nezávislosti veličin X a Y zamítáme, IS pro $\rho : (0,7131; 0,983)$]

Úlohy k procvičení

Příklad 4

Nechť $(X_1, Y_1), \dots, (X_{16}, Y_{16})$ je náhodný výběr z dvourozměrného normálního rozložení. Výběrový koeficient korelace R_{XY} nabyl hodnoty $-0,87$. Jestliže provedeme transformaci $U_i = 1 + 3X_i$, $V_i = -3 - Y_i$, $i = 1, \dots, 16$, jakou hodnotu nabude výběrový koeficient korelace R_{UV} ?

$$[R_{UV} = 0,87]$$

Úlohy k procvičení

Příklad 5

400 náhodně vybraných pracovníků potravinářského podniku bylo dotázáno na příčiny nespokojenosti na pracovišti. Výsledky jsou uvedeny v tabulce:

| kategorie pracovníků | hlavní příčina nespokojenosti | | | | |
|-------------------------|-------------------------------|---------------|------------------|---------|------|
| | pracovní prostředí | špatné vztahy | organizace práce | výdělek | jiné |
| dělníci | 80 | 50 | 75 | 40 | 55 |
| THP | 10 | 10 | 25 | 30 | 25 |

Na hladině významnosti 0,05 testujte hypotézu, že hlavní příčina nespokojenosti nezávisí na kategorii, do níž je pracovník zařazen. Vypočtěte Cramérův koeficient.

[hypotézu o nezávislosti zamítáme, Cramérův koeficient je $V = 0,25$]