

# Testování hypotéz – test korelace

- náhodné proměnné  $x$  a  $y$
- naměříme hodnoty  $x_1, x_2, \dots, x_N$  a  $y_1, y_2, \dots, y_N$
- vypočítáme odhad korelace:  $\hat{\rho}(x, y) = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\hat{\sigma}_x \hat{\sigma}_y}$  s chybou:  $\hat{\sigma}_\rho \approx \frac{1 - \hat{\rho}^2}{\sqrt{N - 1}}$
- **Je korelace statisticky významná?**

- použijeme **testovací statistiku**  $f(t|H_0)$

známá hustota pravděpodobnosti  $f(t)$  a distribuční funkce  $F(t)$

**transformace**  $\rho \rightarrow t$  (nová **testovací proměnná**  $t$ )

**nulová hypotéza**  $H_0$  (předpoklad nulové korelace proměnných  $x$  a  $y$ )

**hladina signifikance**  $P_\alpha$  (typicky 5 % nebo 1 %), pro  $P < P_\alpha$  odmítneme  $H_0$

$$P = P(t > \hat{t}(\hat{\rho})) = 1 - F(\hat{t}(\hat{\rho}))$$

# Test korelace – Fisherova transformace

- **Fisherova transformace**

transformace

$$z = \frac{1}{2} \ln \frac{1 + \rho}{1 - \rho}$$

Pokud platí nulová hypotéza, má proměnná  $z$  normální rozdělení  $N(\mu, \sigma)$ ,

kde očekávaná hodnota  $\mu = 0$  a standardní odchylka  $\sigma = 1/\sqrt{N - 3}$ .

testovací proměnná

$$t = \frac{z}{\sigma} = \frac{\sqrt{N - 3}}{2} \ln \frac{1 + \rho}{1 - \rho}$$

Pokud platí nulová hypotéza, má proměnná  $t$  normální rozdělení  $N(0,1)$ .

t-hodnota

$$\hat{t}(\hat{\rho}) = \frac{\sqrt{N - 3}}{2} \ln \frac{1 + \hat{\rho}}{1 - \hat{\rho}}$$

# Test korelace – Fisherova transformace

- **Fisherova transformace**

testovací statistika

$$f(t|H_0) = N(0,1) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right)$$

nulová hypotéza  $H_0$

Náhodné proměnné  $x$  a  $y$  jsou NEZÁVISLÉ.

hladina signifikance  $P_\alpha$

Pro  $P > P_\alpha$

**přijmeme** nulovou hypotézu.

Pro  $P < P_\alpha$

**odmítneme** nulovou hypotézu.

pravděpodobnost

$$P = P(|t| > \hat{t}(\hat{\rho})) = 2[1 - F(|\hat{t}(\hat{\rho})|)] = 2 \left\{ 1 - \frac{1}{2} \left[ 1 + \operatorname{erf}\left(\frac{|\hat{t}(\hat{\rho})|}{\sqrt{2}}\right) \right] \right\}$$

# Test korelace – Fisherova transformace

- Fisherova transformace

Příklad:  $N = 39$ , proměnné  $x, y, z$

$$\hat{\rho}(x, y) = 0.694$$

$$|\hat{t}_{x,y}| = 5.137$$

$$P_{x,y} = 3 \times 10^{-7}$$

$$\hat{\rho}(x, z) = -0.111$$


$$|\hat{t}_{x,z}| = 0.669$$

$$P_{x,z} = 0.50$$

$$\hat{\rho}(y, z) = 0.059$$

$$|\hat{t}_{y,z}| = 0.355$$

$$P_{y,z} = 0.72$$



$P < 5\%$  **odmítneme** nulovou hypotézu

Proměnné  $x, y$  jsou **ZÁVISLÉ**.

$P > 5\%$  **přijmeme** nulovou hypotézu

Proměnné  $x, z$  a  $y, z$  jsou **NEZÁVISLÉ**.

# Test korelace – studentovo rozdělení

- **studentovo rozdělení**

transformace

$$t = \rho \sqrt{\frac{N - 2}{1 - \rho^2}}$$

← testovací proměnná, t-hodnota

Pokud platí nulová hypotéza, má proměnná  $t$  studentovo rozdělení s  $N - 2$  stupni volnosti.

testovací statistika

studentovo rozdělení s  $\nu$  stupni volnosti

$$f(x|\nu) = \frac{\Gamma\left(\frac{\nu + 1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

nulová hypotéza  $H_0$


Náhodné proměnné  $x$  a  $y$  jsou NEZÁVISLÉ.

# Studentovo rozdělení

- **studentovo rozdělení** s  $\nu$  stupni volnosti

$$f(x|\nu) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

William Sealy Gosset („student“) → statistika na malém počtu vzorků



- **studentovo rozdělení** s  $\nu$  stupni volnosti

$$f(x|\nu) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$


- **gama funkce**

$$\Gamma(x) = \int_0^{\infty} t^{x-1} e^{-t} dt \quad x \geq 0$$

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

$$\Gamma(n) = (n-1)! \quad n \in \mathbb{N}$$

$$\Gamma(x+1) = x\Gamma(x) \quad x \in \mathbb{R}$$




Excel    `EXP(GAMMALN(x))`

ROOT    `ROOT::Math::tgamma(x)`

Python    `from scipy.special import gamma`

- **studentovo rozdělení s  $\nu$  stupni volnosti**



$$f(x|\nu) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

$$f(x|\nu = 1) = \frac{1}{\pi} \frac{1}{1+x^2}$$

$$f(x|\nu \rightarrow \infty) \rightarrow \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$$

$$E[x] \equiv \mu = 0$$

$$V[x] \equiv \sigma^2 = \frac{\nu}{\nu-2} \quad \nu > 2$$

Python `from scipy.stats import t`  
`→ t.pdf(x, nu)`  
`→ t.cdf(x, nu)`

ROOT `ROOT::Math::tdistribution_pdf(x, nu)`



# Test korelace – studentovo rozdělení

- **studentovo rozdělení**

hladina signifikance  $P_\alpha$

Pro  $P > P_\alpha$

**přijmeme** nulovou hypotézu

Pro  $P < P_\alpha$

**odmítneme** nulovou hypotézu

pravděpodobnost

$$P = 2[1 - T_\nu(|\hat{t}(\hat{\rho})|)]$$




distribuční funkce  
studentova rozdělení

konfidenční interval

$$(-T_\nu^{-1}(P_\alpha), T_\nu^{-1}(P_\alpha))$$



inverzní funkce k distribuční  
funkci studentova rozdělení



# Test korelace – studentovo rozdělení

- studentovo rozdělení

Příklad:  $N = 39$ , proměnné  $x, y, z, v = N - 2 = 37$

$$\hat{\rho}(x, y) = 0.694$$

$$|\hat{t}_{x,y}| = 5.867$$

$$P_{x,y} = 9 \times 10^{-7}$$

$$\hat{\rho}(x, z) = -0.111$$


$$|\hat{t}_{x,z}| = 0.679$$

$$P_{x,z} = 0.50$$

$$\hat{\rho}(y, z) = 0.059$$

$$|\hat{t}_{y,z}| = 0.360$$

$$P_{y,z} = 0.72$$



$P < 5\%$  **odmítneme** nulovou hypotézu

Proměnné  $x, y$  jsou **ZÁVISLÉ**.

$P > 5\%$  **přijmeme** nulovou hypotézu

Proměnné  $x, z$  a  $y, z$  jsou **NEZÁVISLÉ**.