

# Korelační analýza

- zabývá se především intenzitou vzájemného vztahu proměnných;
- je základní metodou měření síly lineární závislosti číselných proměnných;
- „correlatio“ = vzájemná souvislost (z lat.).

! Z výpočetních a interpretačních hledisek se regresní a korelační analýza prolínají, nelze mezi nimi stanovit ostrou hranici.

## Sdružené regresní přímky

$$Y = a_{yx} + b_{yx}x \quad \text{popisuje závislost } y \text{ na } x$$

$$X = a_{xy} + b_{xy}y \quad \text{popisuje závislost } x \text{ na } y$$

$$a_{yx} = \bar{y} - b_{yx}\bar{x} \quad b_{yx} = \frac{s_{xy}}{s_x^2}$$

$$a_{xy} = \bar{x} - b_{xy}\bar{y} \quad b_{xy} = \frac{s_{xy}}{s_y^2}$$

1.  $b_{yx} = b_{xy} = 0 \Rightarrow x$  a  $y$  jsou korelačně nezávislé; sdružené regresní přímky svírají pravý úhel.
2.  $b_{yx} = \frac{1}{b_{xy}} \Rightarrow x$  a  $y$  jsou úplně závislé; sdružené regresní přímky svírají nulový úhel (splývají).

## Míry těsnosti lineární závislosti

$$\text{Koeficient determinace: } r_{yx}^2 = r_{xy}^2 = b_{yx} \cdot b_{xy} = \frac{s_{xy}}{s_x^2} \cdot \frac{s_{xy}}{s_y^2} = \frac{s_{xy}^2}{s_x^2 \cdot s_y^2}; \quad r_{xy}^2 \in \langle 0; 1 \rangle$$

$$\text{Koeficient korelace: } r_{yx} = r_{xy} = \sqrt{r_{yx}^2} = \frac{s_{xy}}{s_x \cdot s_y} = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\sqrt{(\overline{x^2} - \bar{x}^2) \cdot (\overline{y^2} - \bar{y}^2)}}; \quad r_{xy} \in \langle -1; 1 \rangle$$

- měří sílu lineární závislosti, nikoli závislosti obecně (lineární závislost = korelovanost).
- koeficient je symetrický.

### Interpretace:

1. znaménko +/- udává směr závislosti:

$$r_{xy} > 0 \Rightarrow \text{přímá závislost}$$

$$r_{xy} < 0 \Rightarrow \text{nepřímá závislost}$$

2.  $|r_{xy}|$  udává sílu závislosti:

$$r_{xy} = 0 \quad \Rightarrow \quad \text{lineární nezávislost}$$

$$|r_{xy}| = 1 \quad \Rightarrow \quad \text{funkční (úplná) závislost}$$

$$|r_{xy}| \rightarrow 0 \quad \Rightarrow \quad \text{slabá lineární závislost}$$

$$|r_{xy}| \rightarrow 1 \quad \Rightarrow \quad \text{silná lineární závislost}$$

### **Test hypotézy o nulové hodnotě korelačního koeficientu**

1)  $H_0 : \rho_{yx} = 0$  (lineární nezávislost  $x$  a  $y$ )

$H_1 : \text{non } H_0$

2) **Testové kritérium:**

$$t = \frac{r_{yx} \cdot \sqrt{n-2}}{\sqrt{1-r_{yx}^2}} ; \quad \text{Statistika } t \text{ má při platnosti } H_0 \text{ rozdělení } t \text{ s } (n-2) \text{ stupni volnosti .}$$

3) **Kritický obor:**

$$W \equiv \left\{ t; t \leq t_{\frac{\alpha}{2}}(n-2) \cup t \geq t_{1-\frac{\alpha}{2}}(n-2) \right\}$$

4) **Závěr testu:**

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme  $H_0$  a přijímáme  $H_1$ , tzn. prokázali jsme hypotézu o lineární závislosti proměnných  $x$  a  $y$ .

## Pořadová korelace

- Pokud chceme získat rychlou představu o síle závislosti mezi 2 kvantitativními znaky nebo určit závislost mezi pořadími znaků, nahradíme původní hodnoty  $x_i$  a  $y_i$  jejich pořadovými čísly  $i_x$  a  $i_y$  podle toho, která místa hodnoty zaujímají v uspořádané řadě.

$$\text{Spearmanův koeficient pořadové korelace: } r_s = 1 - \frac{6 \sum_{i=1}^n (i_x - i_y)^2}{n(n^2 - 1)} ; \quad r_s \in \langle -1; 1 \rangle$$

- varianta korelačního koeficientu;
- měří sílu lineární závislosti dvou pořadí.

**Interpretace:** stejná jako u korelačního koeficientu.

## Test hypotézy o nezávislosti pořadovou korelací

1)  $H_0 : \rho_s = 0$  (nezávislost pořadí)

$H_1 : \text{non } H_0$

2) **Testové kritérium:**

$$t = \frac{r_s \cdot \sqrt{n-2}}{\sqrt{1-r_s^2}} ; \quad \text{Statistika } t \text{ má při platnosti } H_0 \text{ rozdělení } t \text{ s } (n-2) \text{ stupni volnosti .}$$

3) **Kritický obor:**

$$W \equiv \left\{ t; t \leq t_{\frac{\alpha}{2}}(n-2) \cup t \geq t_{1-\frac{\alpha}{2}}(n-2) \right\}$$

4) **Závěr testu:**

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme  $H_0$  a přijímáme  $H_1$ , tzn. prokázali jsme hypotézu o lineární závislosti obou pořadí.