

Statistické zpracování dat

3. prezentace

Jednoduchá regresní analýza

Mgr. Radmila Krkošková, Ph.D.



**SLEZSKÁ
UNIVERZITA**

OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

Závislosti mezi kvantitativními statistickými znaky



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

- Problém závislosti 2 znaků řeší jednoduchá **regresní analýza** (lineární a nelineární)
- **Příklad:** *Závislost zisku z prodeje výrobku na výdajích za reklamu*
- Východiskem je vždy **grafické znázornění**
- Mírami závislosti jsou **regresní koeficienty**, resp. **koeficienty determinace (a korelace)**
- Někdy je výhodné využít z kvantitativních dat pouze ordinální informaci (tj. uspořádání) a aplikovat ANOVA
- Míry asociace mezi více znaky řeší vícenásobné regresní a korelační metody

Příklad – výdaje na reklamu



č. firmy	Výdaje na reklamu	Výdaje na reklamu	Zisk
1	malé	6	50
2	malé	8	80
3	malé	9	90
4	malé	9	120
5	středně velké	12	210
6	středně velké	15	250
7	středně velké	16	320
8	středně velké	20	360
9	středně velké	22	380
10	středně velké	23	410
11	velké	25	400
12	velké	26	450
13	velké	28	430
14	velké	30	460
15	velké	30	480
16	velké	31	480

Příklad – grafické znázornění



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

Závislost zisku na výdajích za reklamu



Jednoduchá (jednorozměrná) lineární RA



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

- Východiskem je vždy grafické znázornění
- Uspořádání bodů má tvar přímky

regresní přímka: $Y = B_0 + B_1 X$

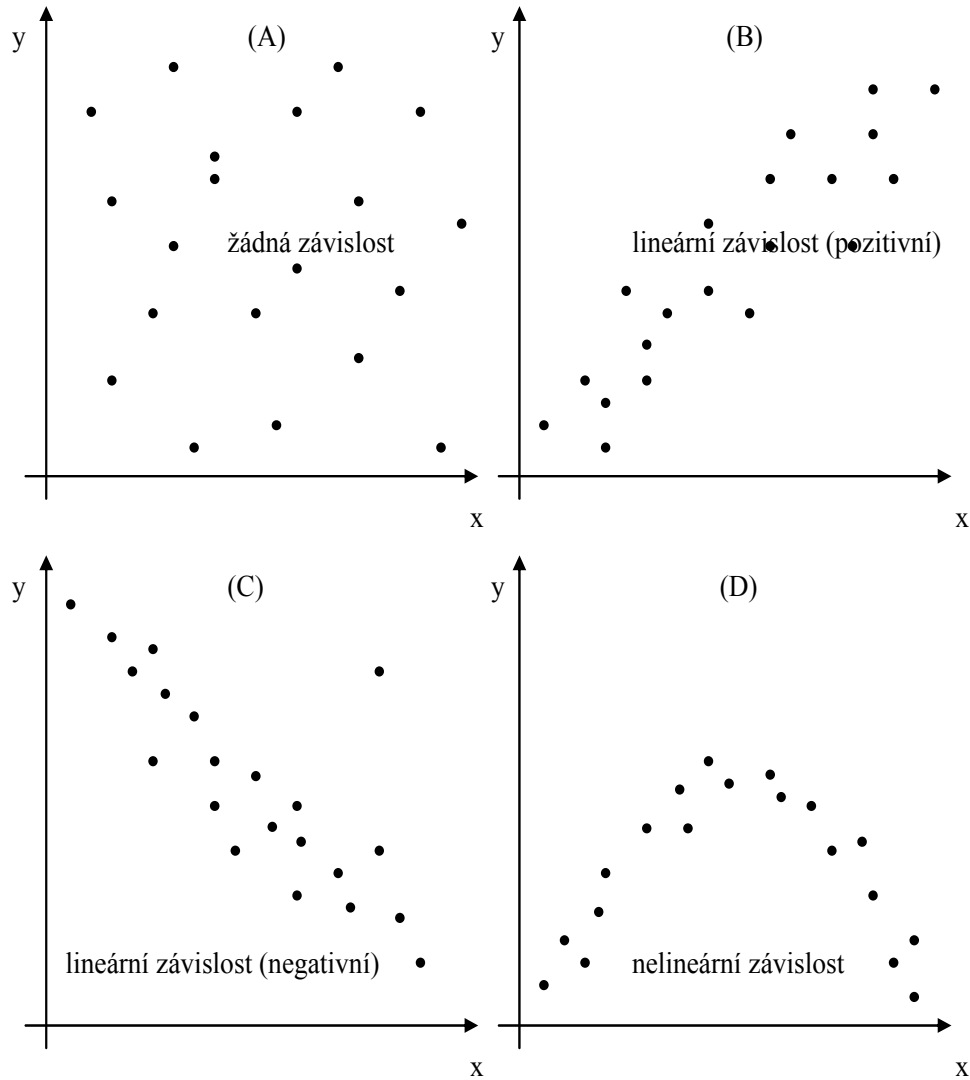
regresní model: $y_i = B_0 + B_1 x_i + \varepsilon_i, i = 1, 2, \dots, n$

- **Cíl:** nalezení nejlepších odhadů regresních koeficientů

Bodový diagram (Scatter diagram)



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ



(K. F. Gauss, 1777 – 1855)

- Data – body: $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$
- Odhady regresních koeficientů B_0, B_1 :

$$\sum_{i=1}^n (y_i - (b_1 x_i + b_0))^2 \rightarrow \min$$

$$b_1 = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \quad b_0 = \bar{y} - b_1 \bar{x}$$



- Interpretace regresních koeficientů:


b_0 - úroveň kritéria y při nulové úrovni prediktoru x

b_1 - přírůstek kritéria y při jednotkovém přírůstku prediktoru x

Přiléhavost dat k regresní křivce



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ



Přiléhavost regresní přímky k datům



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

- Teoretický součet čtverců: $S_T = \sum_{i=1}^n (Y_i - \bar{y})^2$

Y_i - teoretické hodnoty („na regresní přímce“)

- Reziduální součet čtverců: $S_R = \sum_{i=1}^n (y_i - Y_i)^2$

- Celkový součet čtverců: $S_y = \sum_{i=1}^n (y_i - \bar{y})^2$

- Platí vztah: $S_y = S_T + S_R$



Koeficient determinace –

míra přiléhavosti dat k regresní křivce:

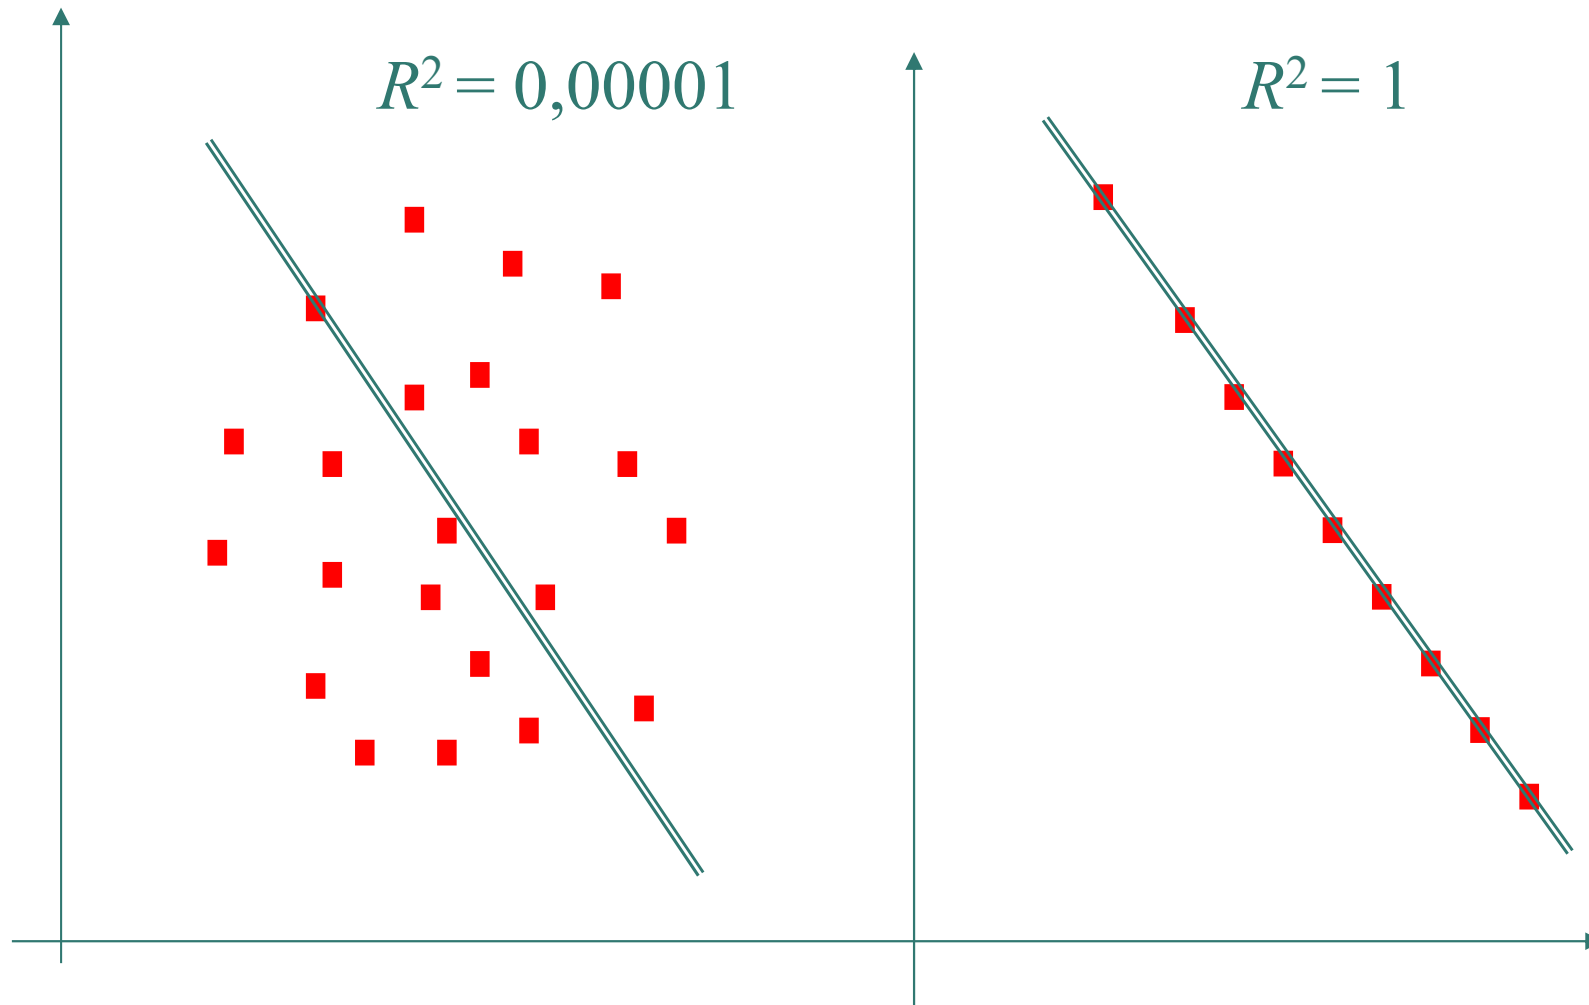
$$R^2 = \frac{S_T}{S_y} = 1 - \frac{S_R}{S_y}$$

- Platí: $0 \leq R^2 \leq 1$
- **Pozor!** R^2 má platnost pro libovolný typ regresní funkce!

Extrémní hodnoty koeficientu determinace R^2



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ





Předpoklady:

1. Vysvětlující proměnná X je nestochastická – vyplývá z povahy problému
2. **Střední hodnota náhodné chyby ε je 0**, tj.
 $E(\varepsilon) = 0$ – pro MNČ vždy splněno!
3. **Rozptyl náhodné chyby ε je konstantní**, tj.
 $Var(\varepsilon) = \sigma^2$ - test, např. Chi-kvadrát (**Homoskedasticta**)
4. **Náhodné chyby ε jsou nekorelované**, tj. **Autokorelace = 0**,
tj. $Cov(\varepsilon_i, \varepsilon_j) = 0$ pro $i \neq j$ – test nulovosti korelačního koeficientu
5. **Náhodná chyba má normální rozdělení**,
tj. $\varepsilon \sim N(0, \sigma^2)$ – test normality



Děkuji Vám za pozornost!!!