



# Analiza podataka upotrebom linearne regresije

Milena Jelić

Fakultet tehničkih nauka  
Univerzitet u Novom Sadu

13. maj 2024.

- Proučavanje veze između dve kontinualne promenljive
- Zavisna ( $y$ ) i nezavisna ( $x$ ) promenljiva
- Deterministička (funkcionalna) zavisnost nam nije od interesa jer možemo odrediti tačnu vrednost

- Proučavanje veze između dve kontinualne promenljive
- Zavisna ( $y$ ) i nezavisna ( $x$ ) promenljiva
- Deterministička (funkcionalna) zavisnost nam nije od interesa jer možemo odrediti tačnu vrednost
- $O = 2r\pi$

- Posmatramo probleme gde imamo neku statističku zavisnost između podataka, nemamo "formulu"
- Primer takve zavisnosti: visina i težina ljudi

- Linearna zavisnost znači da je regresiona funkcija linearna po koeficijentima
- Ako želimo pravu, imamo dva koeficijenta:  $\hat{y} = ax + b$
- Određivanje dva koeficijenta na osnovu mnogo više od 2 para vrednosti daje preodređen sistem
- Moguća je situacija da dva podatka imaju istu vrednost  $x$ , a različito  $y$

- Greška predstavlja razliku između prave vrednosti i predviđene vrednosti
- Kvadratna funkcija greške:  $SSE = \sum_{i=1}^n (\hat{y}_i - y_i)^2$



- Polinom stepena  $m$ :  $p(x) = \sum_{j=0}^m a_j x^j$
- Imamo  $m + 1$  parametar, a ne 2
- Opet dobijemo preodređen sistem

- Najpribližnije rešenje kod preodređenih sistema
- $SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - ax_i - b)^2$
- $a = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \frac{Cov(x,y)}{Var(x)}$
- $b = \frac{1}{n} \sum_{i=1}^n (y_i - ax_i) = \bar{y} - a\bar{x}$



- Linearnost
- Nezavisnost grešaka
- Normalnost grešaka
- Jednake varijanse

- Na osnovu 2 ili više nezavisne promenljive predviđa se zavisna
- Primer:  $y = 5x_1 + 7x_2 + 3$

- Sve prethodno pomenute pretpostavke
- Dodatna pretpostavka o kolinearnosti - ne postoji savršena kolinearnost

- Koeficijent korelacije - broj u intervalu od  $-1$  do  $1$
- Savršena pozitivna kolinearnost - koeficijent korelacije je  $1$
- Savršena negativna kolinearnost - koeficijent korelacije je  $-1$
- Ne želimo da imamo 2 kolone koje su u savršenoj kolinearnosti, jednu od te dve kolone treba ukloniti
- $x_i = ax_j + b$

- Korelacija u intervalu  $(-1, -0.8] \cup [0.8, 1)$
- Pretpostavka nije narušena, ali vredi obratiti pažnju
- Matrica korelacije

- Koeficijent determinacije - uzima vrednosti u opsegu  $[0, 1]$ . Što je  $r^2$  bliže 1, to je model bolji
- $r^2 = \frac{SSR}{SST}$
- $SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
- $SST = \sum_{i=1}^n (y_i - \bar{y})^2$

- Koeficijent determinacije ne uzima u obzir količinu podataka i broj nezavisnih promenljivih
- vrednost  $r^2$  nikad ne opada sa dodavanjem novih kolona
- $\bar{r}^2 = 1 - (1 - r^2) \cdot \frac{n-1}{n-p-1}$
- $n$  - broj podataka u skupu
- $p$  - broj nezavisnih promenljivih

Hvala na pažnji!

Pitanja?