

*Pokyny:*

- Podpíšte sa aj na papier so zadaním a odovzdajte ho spolu s riešením.
- Môžete používať kalkulačku a ľahák A4.
- Neodpisujte...

1. (4 body, v každej otázke 0.25 b. za odpoveď, 0.75 b. za zdôvodnenie) Rozhodnite, ktoré z nasledujúcich tvrdení sú pravdivé a ktoré nepravdivé. Svoje tvrdenie zdôvodnite.

- (a) Ak v modeli  $y = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \varepsilon$  testujeme signifikantnosť regresie, testujeme hypotézu  $\alpha_0 = 0, \alpha_1 = 0, \alpha_2 = 0$ .
- (b) Ak je submodel lepší ako pôvodný model, má väčší koeficient determinácie.
- (c) Rozklad sumy štvorcov  $TSS = ESS + RSS$  v modeli  $y = \beta x + \varepsilon$  neplatí.
- (d) Ak je v modeli heteroskedasticita, MNSĎ odhad nie je nevychýlený.

**Riešenie:**

- (a) Nepravdivé, testujeme hypotézu  $\alpha_1 = 0, \alpha_2 = 0$ .
- (b) Nepravdivé, submodel nikdy nemá väčší koeficient determinácie ako pôvodný model.
- (c) Pravdivé, na dôkaz rozkladu sumy štvorcov potrebujeme vlastnosť  $\sum e_i = 0$ , ktorú tento model nemá:

$$\begin{aligned} TSS &= \sum (y_i - \bar{y})^2 = \sum (y_i - \hat{y}_i + \hat{y}_i - \bar{y})^2 = \\ &= \sum (y_i - \hat{y}_i)^2 + \sum (\hat{y}_i - \bar{y})^2 + 2 \sum (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) = \\ &= RSS + ESS + 2 \sum (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) \end{aligned}$$

Posledný sčítanec je

$$2 \sum (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) = 2 \sum e_i(\hat{\beta}x_i - \bar{y}) = 2 \left[ \hat{\beta} \sum e_i x_i - \bar{y} \sum e_i \right] \neq 0,$$

keďže  $\sum x_i e_i = 0$  (nutná podmienka optima),  $\sum e_i \neq 0$  (videli sme v prvej písomke).

- (d) Nepravdivé, k nevychýlenosti potrebujeme predpoklad  $E[\varepsilon] = 0$ , homoskedasticita, resp. heteroskedasticita na to nemá vplyv.

**Poznámky:**

- Model  $y = \beta x + \varepsilon$ , ani  $y = \beta X + \varepsilon$ , nemôže byť maticový zápis modelu  $y = \beta_0 + \beta_1 x_1 + \dots + \beta_{k-1} x_{k-1}$ . V maticovom zápise je  $\beta$   $k$ -rozmerný vektor, t.j. jeho rozmer je  $k \times 1$ ,  $X$  je matica  $n \times k$  (kde  $n$  je počet dát). Súčin  $\beta X$  nie je v tomto prípade definovaný.
2. (3 body) Vyberte si jednu z úloh (a), (b), (c), každá je za 3 body. Ak ich odovzdáte viac, zarátajú sa vám body za tú, za ktorú dostanete viac bodov.
- (a) Dokážte, že v modeli  $y = \alpha + \beta x + \varepsilon$  sa koeficient determinácie  $R^2$  rovná druhej mocnine výberového korelačného koeficientu  $r(x, y)$ .
  - (b) Uvažujme model  $Y = X\beta + \varepsilon$ , kde  $\varepsilon \sim N(0, \sigma^2 I)$  a hypotézu  $R\beta = r$ . Vyjadrite štatistiku likelihood testu na testovanie tejto hypotézy pomocou  $RSS$  a  $RSS_*$ .

(c) Uvažujme model  $y = X\beta + \varepsilon$ ,  $\varepsilon \sim N(0, \sigma^2\Omega)$ , kde  $\Omega$  je známa diagonálna matica  $\text{diag}(\sigma_1^2, \dots, \sigma_n^2)$ . Dokážte, že odhad zovšeobecnenou metódou najmenších štvorcov je riešením optimalizačnej úlohy tvaru

$$\sum_{i=1}^n w_i (y_i - \beta_0 - \beta_1 x_{1i} - \dots - \beta_k x_{ki})^2 \rightarrow \min$$

a určte váhy  $w_i$

**Riešenie:**

(a) V modeli  $y = \alpha + \beta x + \varepsilon$  pre MNŠ odhady platí:

$$\hat{\beta} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}, \quad \bar{y} = \hat{\alpha} + \hat{\beta}\bar{x}.$$

Preto

$$\begin{aligned} R^2 &= \frac{ESS}{TSS} = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} = \frac{\sum [(\hat{\alpha} + \hat{\beta}x_i) - (\hat{\alpha} + \hat{\beta}\bar{x})]^2}{\sum (y_i - \bar{y})^2} = \frac{\hat{\beta}^2 \sum (x_i - \bar{x})^2}{\sum (y_i - \bar{y})^2} \\ &= \frac{[\sum (x_i - \bar{x})(y_i - \bar{y})]^2 \sum (x_i - \bar{x})^2}{[\sum (x_i - \bar{x})^2]^2 \sum (y_i - \bar{y})^2} = \frac{[\sum (x_i - \bar{x})(y_i - \bar{y})]^2}{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2} = [r(x, y)]^2. \end{aligned}$$

- (b) • Model bez reštrikcie:  $\hat{\beta} = \hat{\beta}_{mns}$ ,  $\hat{\sigma}^2 = \frac{RSS}{n}$ .  
 • Model s reštrikciou: Log-likelihood funkcia je

$$\ln L(\beta, \sigma^2) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} (y - X\beta)^T (y - X\beta),$$

maximalizujeme ju za podmienky  $R\beta = r$ . Dostaneme  $\hat{\beta}_*$ ,  $\hat{\sigma}^2 = \frac{RSS_*}{n}$

- Likelihood ratio štatistika:

$$\begin{aligned} LR &= -2 \left[ \ln L(\hat{\beta}_*, \hat{\sigma}_*^2) - \ln L(\hat{\beta}, \hat{\sigma}^2) \right] = \\ &= -2 \left[ \left( -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \frac{RSS_*}{n} - \frac{n}{2} \right) - \left( -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \frac{RSS}{n} - \frac{n}{2} \right) \right] = \\ &= -2 \left[ -\frac{n}{2} \left( \ln \frac{RSS_*}{n} - \ln \frac{RSS}{n} \right) \right] = n \ln \frac{RSS_*}{RSS}. \end{aligned}$$

(c) Optimalizačnú úlohu môžeme zapísať v maticovom tvare:

$$(y - X\beta)^T W (y - X\beta) \rightarrow \min,$$

kde  $W = \text{diag}(w_1, \dots, w_n)$ . Označme

$$F(\beta) = (y - X\beta)^T W (y - X\beta) = y^T W y - 2y^T W X\beta + \beta^T X^T W X\beta,$$

v bode optima  $\beta^*$  je derivácia podľa  $\beta$  rovná nule:

$$\left. \frac{\partial F}{\partial \beta} \right|_{\beta^*} = -2X^T W y + 2X^T W X\beta^* = 0$$

a teda riešenie tejto optimalizácie je

$$\beta^* = (X^T W X)^{-1} (X^T W y).$$

To sa zhoduje s odhadom zovšeobecnenou metódou najmenších štvorcov

$$\hat{\beta}_{gls} = (X^T \Omega^{-1} X)^{-1} (X^T \Omega^{-1} y)$$

pre  $W = \Omega^{-1}$ , čiže  $w_i = \frac{1}{\sigma_i^2}$ .

**Poznámky:**

- Príklady (a), (b) boli v príkladoch na precvičenie ako príklady 5(a) a 9.
- Príklady (c) je podobný príkladu 2(b) vo vzorovej písomke.

3. (3 body) Odhadnutím modelu dostaneme

$$\hat{y} = -6.38 + 10.41x$$

$$(1.93) (3.65)$$

kde v zátvorkách sú odhady štandardných odchýlok. Určte koeficient determinácie, ak model bol odhadnutý zo 150 dát.

**Riešenie:**

- t štatistika na testovanie hypotézy  $\beta = 0$  v modeli  $y = \alpha + \beta x + \varepsilon$  je

$$t = \frac{\hat{\beta}}{\widehat{s.d.}(\hat{\beta})} = \frac{10.41}{3.65}.$$

- F štatistika na testovanie signifikácie tejto regresie je

$$F = \left( \frac{10.41}{3.65} \right)^2.$$

- $R^2$  vyjadríme pomocou F štatistiky na testovanie signifikancie regresie:

$$F = \frac{ESS/(k-1)}{RSS/(n-k)} = \frac{ESS}{RSS/(n-2)} = (n-2) \frac{ESS}{RSS}$$
$$R^2 = \frac{ESS}{TSS} = \frac{ESS}{ESS + RSS} = \frac{\frac{ESS}{RSS}}{\frac{ESS}{RSS} + 1} = \frac{\frac{1}{n-2} F}{\frac{1}{n-2} F + 1}$$

a dosadíme:

$$R^2 = \frac{\frac{1}{148} \left( \frac{10.41}{3.65} \right)^2}{\frac{1}{148} \left( \frac{10.41}{3.65} \right)^2 + 1} = 0.052.$$

**Poznámky:**

- Ide o rovnaký typ príklad, ako bol voliteľný príklad 2(c) v prvej písomke.

4. (10 bodov) Z 22 dát odhadujeme model  $y = \alpha + \beta x + \varepsilon$ ,  $\varepsilon \sim N(0, \sigma^2 I)$ . Platí:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 10, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = 20,$$

$$\sum_{i=1}^n (x_i - \bar{x})^2 = 60 \quad \sum_{i=1}^n (y_i - \bar{y})^2 = 100,$$

$$\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = 30.$$

( $n$  je počet dát). Vypočítajte:

- odhad parametrov  $\hat{\alpha}$ ,  $\hat{\beta}$
- koeficient determinácie

(c) hodnotu štatistiky na testovanie hypotézy  $H_0 : \beta = 1$  a určte jej rozdelenie za platnosti  $H_0$

(d) rezidálnu sumu štvorcov

**Riešenie:**

(a) Odhady parametrov sú

$$\hat{\beta} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sum(x_i - \bar{x})^2} = \frac{30}{60} = \frac{1}{2},$$
$$\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x} = 20 - \frac{1}{2} \cdot 10 = 15.$$

(b) Podľa príkladu 2(a) v tejto písomke (resp. podľa príkladu 5(a) z príkladov na precvičenie) máme

$$R^2 = [r(x, y)]^2 = \left[ \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2} \sqrt{\sum(y_i - \bar{y})^2}} \right]^2 = \left[ \frac{30}{\sqrt{60 \times 100}} \right]^2 = \frac{3}{20}.$$

(c) Testovacia štatistika je

$$t = \frac{\hat{\beta} - 1}{s.d.(\hat{\beta})}$$

a za platnosti  $H_0$  má Studentovo  $t_{n-k} = t_{22-2} = t_{20}$  rozdelenie. Potrebujeme teda  $s.d.(\hat{\beta})$ :

- V príklade 3 sme pre model  $y = \alpha + \beta x + \varepsilon$  odvodili, že  $R^2 = \frac{\frac{1}{n-2}F}{\frac{1}{n-2}F+1}$ , kde  $F$  je štatistika na testovanie signifikancie regresie.
- Z toho:  $F = (n-2) \frac{R^2}{1-R^2}$ .
- Keďže  $F = \left[ \frac{\hat{\beta}}{s.d.(\hat{\beta})} \right]^2$ , dostaneme

$$s.d.(\hat{\beta}) = \sqrt{\frac{\hat{\beta}^2}{(n-2) \frac{R^2}{1-R^2}}}.$$

- Dosadíme:

$$t = \frac{\frac{1}{2} - 1}{\sqrt{\frac{(\frac{1}{2})^2}{(22-2) \frac{\frac{3}{20}}{1-\frac{3}{20}}}}} = -1.8787.$$

(d)  $RSS = TSS(1 - R^2) = 100 \left(1 - \frac{3}{20}\right) = 100 - 15 = 85$ .