

**P1.** Muuttujien  $x$  ja  $Y$  havaitut arvot ovat

$x$	0.4	1.1	1.4	2.2	2.3	2.4
$y$	-0.5	1.4	1.6	3.3	4.1	4.2

Tästä otoksesta on laskettu seuraavat tunnusluvut:

$s_x^2$	$s_y^2$	$s_{xy}$
0.64267	3.3950	1.4640

- Määritä regressiomallin  $Y_j = \beta_0 + \beta_1 x_j + \varepsilon_j$  kertoimien  $\beta_0$  ja  $\beta_1$  (pienimmän neliosumman) estimaatit.
- Piirrä pistediagrammi sekä estimoitu suora.
- Laske jäännösvarianssin estimaatti  $s^2$  ja testaa nollihypoteesia  $\beta_0 = -1$  merkitsevyydellä 0.05 (olettaen, että satunnaismuuttujat  $\varepsilon_j$  ovat riippumattomia ja  $N(0, \sigma^2)$ -jakautuneita).

*Ratkaisu:* (a) Tässä tarvitaan keskiarvot  $\bar{x}$  ja  $\bar{y}$  ja ne ovat

$$\bar{x} = 1.6333,$$


$$\bar{y} = 2.35.$$

Parametrien  $\beta_0$  ja  $\beta_1$  estimaatit ovat näiden tietojen perusteella:

$$b_1 = \frac{s_{xy}}{s_x^2} \approx 2.278,$$

$$b_0 = \bar{y} - b_1 \bar{x} \approx -1.3707.$$

(b)



(c) Jännösvarianssin estimaattia varten tarvitsemme korrelaatiokeroimen ja se on  $r_{xy} = \frac{s_{xy}}{\sqrt{s_x^2 s_y^2}} = 0.99112$  joten jäännösvarianssin estimaatti on

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n (b_0 + b_1 x_i - y_i)^2 = \frac{n-1}{n-2} s_y^2 (1 - r_{xy}^2) \approx 0.075.$$

Parametrin  $\beta_0$  estimaattorista  $B_0$  tiedämme, että testimuuttuja

$$W_0 = \frac{B_0 - \beta_0}{\sqrt{S^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{(n-1)s_x^2} \right)}}$$

on  $t(n-2)$ -jakautunut. Kun nollahypoteesi on  $\beta_0 = -1$  niin tämän testimuuttujan arvoksi tulee tässä tapauksessa  $-1.3557$ . Koska nollahypoteesin negaatio on kaksisuuntainen niin  $p$ -arvoksi tulee

$$p = 2F_{t(4)}(-1.3557) = 0.24667,$$

joten nollahypoteesia ei hylätä.

---

**P2.** Otoksesta  $(x_j, y_j)$ ,  $j = 1, 2, \dots, 16$  laskettiin seuraavat tunnusluvut:

$\bar{x}$	$\bar{y}$	$s_x^2$	$s_y^2$	$r_{xy}$
0.5	4.8	4.4	6.2	0.7

- Määritä regressiomallin  $Y = \beta_0 + \beta_1 x + \varepsilon$  kertoimien  $\beta_0$  ja  $\beta_1$  (pienimmän neliösumman) estimaatit.
- Laske jäännösvarianssin estimaatti  $s^2$  ja testaa nollahypoteesia  $\beta_1 \leq 0.3$  merkitsevyystasolla 0.05 (olettaen, että satunnaismuuttujat  $\varepsilon_j$  ovat riippumattomia ja  $N(0, \sigma^2)$ -jakautuneita).
- Mikä on mallin selitysaste?

*Ratkaisu:* Tässä tehtävässä ei ole annettu otoskovarianssia  $s_{xy}$  mutta koska  $r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}$  niin  $s_{xy} = r_{xy} \cdot s_x \cdot s_y$  joten saamme parametrien  $\beta_1$  ja  $\beta_0$  estimaateiksi

$$b_1 = \frac{s_{xy}}{s_x^2} = r_{xy} \frac{s_y}{s_x} = 0.83094$$

$$b_0 = \bar{y} - b_1 \bar{x} = 4.3845.$$

Jäännösvarianssin estimaatiksi tulee nyt

$$s^2 = \frac{n-1}{n-2} s_y^2 (1 - r_{xy}^2) = 3.3879.$$

Kun testaamme nollahypoteesia  $\beta_1 \leq 0.3$  niin käytämme testimuuttujaa

$$W_1 = \frac{B_1 - \beta_1}{\sqrt{\frac{s^2}{(n-1)s_x^2}}}$$

joka on  $t(n-2)$ -jakautunut. Tämän testimuuttujan arvoksi tulee

$$w_1 = \frac{0.83094 - 0.3}{\sqrt{\frac{3.3879}{15 \cdot 4.4}}} = 2.3434.$$

Koska nollahypoteesin negaatio on yksisuuntainen niin  $p$ -arvoksi tulee

$$p = 1 - F_{t(14)}(2.3434) = 0.017197,$$

joten nollahypoteesi hylätään merkitsevyystasolla 0.05.

Määritelmän mukaan mallin selitysaste on  $r_{xy}^2 = 0.49$ .

---

**P3.** Fossiiliset hiilidioksidipäästöt (CO<sub>2</sub>-foss) olivat vuosina 2008–2012 kotitalouksien osalta seuraavat (yksikkönä miljoona tonnia)

2008	2009	2010	2011	2012
6.79	6.32	6.25	5.60	5.66

Määritä näiden lukujen perusteella 95%:n luottamusväli vuoden 2013 päästöjen odotusarvolle kun oletat että päästöjä voidaan kuvata mallilla  $Y_j = \beta_0 + \beta_1 x_j + \varepsilon_j$  missä  $Y_j$  on päästöt vuonna  $x_j$  ja satunnaismuuttujat  $\varepsilon_j$  ovat riippumattomia ja  $N(0, \sigma^2)$ -jakautuneita.

Voit käyttää hyväksi seuraavia tunnuslukuja:

$\bar{x}$	$\bar{y}$	$s_x^2$	$s_y^2$	$s_{xy}$
2010	6.124	2.5	0.24693	-0.745

ja muista että jos vaihdat vuosiluvut luvuiksi  $x_j - 2013$  ainoastaan  $\bar{x}$  muuttuu ja sinun pitää laskea luottamusväli kertoimelle  $\beta_0$ .

*Ratkaisu:* Jos  $z_j = x_j - 2013$  niin  $\bar{z} = -3$  mutta  $s_z^2 = s_x^2$  ja  $s_{zy} = s_{xy}$ . Vastaus: [4.62, 5.84].

Näiden lukujen perusteella voimme laskea estimaatit parametreille  $\beta_0$  ja  $\beta_1$  regressiomallissa  $Y_j = \beta_0 + \beta_1 z_j + \varepsilon_j$  ja saamme.

$$b_1 = \frac{s_{zy}}{s_z^2} = -0.298,$$

$$b_0 = \bar{y} - b_1 \bar{z} = 5.23.$$

Mallin  $Y_j = \beta_0 + \beta_1 z_j + \varepsilon_j$  ennustamat vuoden 2013 päästöt saadaan sijoittamalla  $z_j = 0$  jolloin päästöjen odotusarvoksi tulee  $\beta_0$  jonka estimaatti on  $b_0 = 5.23$ .

Jotta voisimme laskea 95% luottamusvälin meidän pitää laskea jäännösvarianssin estimaatti  $s^2$  ja sitä varten laskemme ensin otoskorrelaatiokertoimen:

$$r_{xy} = r_{zy} = \frac{s_{zy}}{s_z s_y} = b_1 \frac{s_z}{s_y} = -0.94820,$$

$$s^2 = \frac{n-1}{n-2} s_y^2 (1 - r_{xy}^2) = 0.03323.$$

Jos  $B_0 = \bar{Y} - \frac{s_{xy}}{s_x^2} \bar{z}$  niin  $B_0$  on parametrin  $\beta_0$  estimaattori ja pätee

$$W_0 = \frac{B_0 - \beta_0}{\sqrt{S^2 \left( \frac{1}{n} + \frac{\bar{z}^2}{(n-1)s_z^2} \right)}} \sim t(n-2).$$

Nyt  $\Pr(-3.1824 \leq W_0 \leq 3.1824) = 0.95$  koska  $3.1824 = F_{t(3)}^{-1}(0.975)$  josta seuraa, että

$$\Pr \left( B_0 - 3.1824 \sqrt{S^2 \left( \frac{1}{n} + \frac{\bar{z}^2}{(n-1)s_z^2} \right)} \leq \beta_0 \leq B_0 + 3.1824 \sqrt{S^2 \left( \frac{1}{n} + \frac{\bar{z}^2}{(n-1)s_z^2} \right)} \right) = 0.95.$$

Jos nyt sijoitetaan  $B_0$ :n paikalle sen estimaatti  $b_0$  ja  $S^2$ :n paikalle sen estimaatti  $s^2$  samoin kuin  $\bar{z}$ ,  $s_z^2$  ja  $n$  niin saadaan luottamusväliksi

$$[4.62, 5.84].$$

**P4.** Tutkija T tutki monen eri satunnaismuuttujan välisiä riippuvuuksia ja kun hän laski 400 otoskorrelaatiokerrointa hän löysi 27 kertaa kertoimen joka poikkesi nollassa merkitsevyystasolla 5%.

Valitse ensin nollahypoteesiksi, että kaikki satunnaismuuttujat ovat riippumattomia. Tästä voit johtaa uuden nollahypoteesin joka koskee todennäköisyyttä, että löydät korrelaatiokertoimen joka poikkeaa nollassa merkitsevyystasolla 5% ja voit ottaa tämän nollahypoteesin sellaiseksi, että vaihtoehto sille on yksisuuntainen. Testaa tätä nollahypoteesia merkitsevyystasolla 5% käyttäen tutkija T:n tuloksia.

*Ratkaisu:* Jos kaikki tutkitut satunnaissuureet ovat riippumattomia niin kaikki korrelaatiokertoimet ovat nolliä, eli korrelaatiokertoimien testauksessa käytetty nollahypoteesi on voimassa. Koska tutkija T testasi tämän nollahypoteesin merkitsevyystasolla 5% niin merkitsevyystason määritelmästä seuraa, että todennäköisyys että nollahypoteesi hylätään, kun se on voimassa, on 5%. Näin ollen otamme nollahypoteesiksi, että todennäköisyys, että tutkija T löytää merkitsevästi nollassa poikkeavan korrelaatiokertoimen on korkeintaan 0.05. (Epäyhtälö otetaan tässä toisaalta yksinkertaistamaan laskuja ja toisaalta koska ei tunnu järkevältä että hylkäisimme nollahypoteesin riippumattomuudesta jos olisi löytynyt vain vähän nollassa poikkeavia korrelaatiokertoimia.)

Jos  $X$  on merkitsevästi nollassa poikkeavien otoskorrelaatiokertoimien lukumäärä niin nollahypoteesin (ääritapauksen) nojalla  $X$  on  $\text{Bin}(400, 0.05)$ -jakautunut satunnaismuuttuja. Näin ollen

$$p = \Pr(X \geq 27) = 1 - \Pr(X \leq 26) = 1 - F_{\text{Bin}(400, 0.05)}(26) \approx 0.0726.$$

Jos käytämme normaaliaprosimaatiota niin vastaava lasku on seuraavanlainen:

$$\begin{aligned} p = \Pr(X \geq 27) &= \Pr\left(\frac{X - E(X)}{\sqrt{\text{Var}(X)}} \geq \frac{27 - E(X)}{\sqrt{\text{Var}(X)}}\right) \\ &= \Pr\left(\frac{X - E(X)}{\sqrt{\text{Var}(X)}} \geq \frac{27 - 0.05 \cdot 400}{\sqrt{0.05 \cdot 0.95 \cdot 400}}\right) \\ &= \Pr\left(\frac{X - E(X)}{\sqrt{\text{Var}(X)}} \geq 1.60591\right) \approx 1 - F_{N(0,1)}(1.60591) = 0.0541. \end{aligned}$$

Joka tapauksessa nollahypoteesia ei hylätä merkitsevyystasolla 0.05 eli ei ole erityisen epätodennäköistä että tutkija T löytää näin monta merkitsevästi nollassa poikkeavia otoskorrelaatiokertoimia.

**P5.** Havaintoaineistosta  $(x_i, y_i)$ ,  $i = 1, \dots, n$  on laskettu regressiosuora  $y = b_0 + b_1x$  kun  $x$  on ”selittävä” muuttuja (eli kun oletetaan, että  $Y_i = \beta_0 + \beta_1x_i + \varepsilon_i$ ) ja (käänteisregressiosuora)  $x = a_0 + a_1y$  kun  $y$  on ”selittävä” muuttuja (eli kun oletetaan, että  $X_i = \alpha_0 + \alpha_1y_i + \epsilon_i$ ). Lisäksi on laskettu otoskorrelaatiokerroin  $r_{xy}$  ja on todettu, että nollahypoteesi  $H_0 : \beta_1 = 0$  voidaan hylätä merkitsevyystasolla 0.01. Mitä voidaan sanoa seuraavista väitteistä (olettaen, että  $s_x > 0$  ja  $s_y > 0$ ):

- Suorat  $y = b_0 + b_1x$  ja  $x = a_0 + a_1y$  ovat samat jos ja vain jos  $|r_{xy}| = 1$ .
- Jos testataan hypoteesia  $H_0 : \alpha_1 = 0$  ne sekin voidaan hylätä merkitsevyystasolla 0.01.

*Vihje:* Regressiosuorat voidaan kirjoittaa muodossa  $y - \bar{y} = b_1(x - \bar{x})$  ja  $x - \bar{x} = a_1(y - \bar{y})$ .

*Ratkaisu:* (a) Molemmat suorat kulkevat pisteen  $(\bar{x}, \bar{y})$  kautta joten suorat ovat samat jos kulmakertoimet ovat samat. Nyt  $b_1 = r_{xy} \frac{s_y}{s_x}$  ja  $a_1 = r_{xy} \frac{s_x}{s_y}$  ja kulmakertoimet ovat  $b_1$  ja  $\frac{1}{a_1}$  joten nämä ovat samat täsmälleen silloin kun  $r_{xy} = \pm 1$  eli väite pätee.

(b) Testisuureen arvo voidaan molemmissa tapauksissa (koska nimenomaan testataan hypoteeseja  $\beta_1 = 0$  ja  $\alpha_1 = 0$ ) esittää muodossa  $\frac{r_{xy}\sqrt{n-2}}{\sqrt{1-r_{xy}^2}}$  joten kyseessä on molemmissa tapauksissa sama testi, eli väite pätee.

---