

Lineaariset mallit, kl 2016, Harjoitus 4, viikko 16

1. Tarkastellaan (täysiasteista) lineaarista mallia

$$\begin{aligned} Y_i &= \beta_1 x_{i1} + \cdots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n, \\ \varepsilon_1, \dots, \varepsilon_n &\stackrel{\text{||}}{\sim}, \quad \varepsilon_i \sim \mathbf{N}(0, w_i \sigma^2), \end{aligned} \quad (1)$$

jossa w_1, \dots, w_n ovat tunnettuja positiivisia reaalilukuja. Määrittelemällä diagonaalimatriisi $\mathbf{W} = \text{diag}[w_1 \cdots w_n]$ (ks. monisteen s. 47) nähdään, että kysymyksessä on tehtävän 3.5 mallin erikoistapaus, jossa kovarianssimatriisi $\mathbf{\Sigma} = \sigma^2 \mathbf{W}$.

(i) Muunna malliyhtälöä (1) niin, että päädyt tavanomaiset oletukset toteuttavaan lineaariseen malliin, jonka parametrit ovat $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)$ ja σ^2 .

(ii) Esitä kohdassa (i) saamasi muunnettu malli matriisimuodossa ja päättele kurssilla esitettyjä tuloksia soveltaen mitkä ovat parametrien $\boldsymbol{\beta}$ ja σ^2 SU-estimaatit.

(iii) Käyttäen kohdassa (i) saamaasi muunnettua mallia ja Lausetta 2.1 selvitä parametrien $\boldsymbol{\beta}$ ja σ^2 SU-estimaattorien todennäköisyysjakaumat.

Huom.: Yksi (joskaan ei ainoa) tapa esittää parametrien $\boldsymbol{\beta}$ ja σ^2 SU-estimaatit on

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{W}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{W}^{-1}\mathbf{y} \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n}(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})'\mathbf{W}^{-1}(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}),$$

jossa $\mathbf{y} = [y_1 \cdots y_n]'$ ja $\mathbf{X} = [x_{ij}]$ ($i = 1, \dots, n, j = 1, \dots, p$). Näin saatu $\boldsymbol{\beta}$:n estimaatti tunnetaan painotettuna PNS-estimaattina. Luvut w_i tunnetaan esimerkiksi, kun selitettävän muuttujan havainnot ovat keskiarvotietoja eli y_i on keskiarvo n_i :stä riippumattomasta havainnosta, joiden vaihtelu on saman kokoista. Tällöin $w_i = 1/n_i$ (vrt. otoskeskiarvon varianssi riippumattomien samoin jakautuneiden havaintojen tapauksessa). Joissakin tapauksissa virhevarianssin voidaan olettaa olevan verrannollinen (positiivisarvoisen) selittäjän x_j kanssa, jolloin $w_i = x_{ij}$ (tämän oletuksen realistisuutta voidaan tutkia sen jälkeen, kun mallin parametrit on estimoitu).

2. Tarkastellaan kahden riippumattoman normaalisen otoksen mallia

$$Y_1, \dots, Y_n \stackrel{\text{||}}{\sim}, \quad Y_i \sim \begin{cases} \mathbf{N}(\mu_1, \sigma^2), & \text{kun } i = 1, \dots, n_1 \\ \mathbf{N}(\mu_2, \sigma^2), & \text{kun } i = n_1 + 1, \dots, n_1 + n_2 = n \end{cases}$$

($\mu_1, \mu_2 \in \mathbb{R}, \sigma^2 > 0, n_1, n_2 > 1$).

(i) Harjoitustehtävän 3.2 ratkaisusta saadaan parametrin $\boldsymbol{\mu} = [\mu_1 \quad \mu_2]'$ PNS-estimaattori $\hat{\boldsymbol{\mu}}$ ja sen todennäköisyysjakauma. Mikä on parametrin σ^2 harhaton estimaattori ja sen jakauma?

(ii) Estimoi parametrit μ_1 ja μ_2 ehdolla $\mu_1 = \mu_2$ ja selvitä μ_1 :n (ja μ_2 :n) rajoitetun PNS-estimaattorin jakauma. Mikä on tässä tapauksessa parametrin σ^2 harhaton estimaattori ja sen jakauma? (Monisteen s. 16-17 esitetyistä estimointitavoista kannattaa etsiä yksinkertaisinta.)

3. Tarkastellaan kahta riippumatonta lineaarista mallia

$$\mathbf{Y}_i = \mathbf{X}_i\boldsymbol{\beta}_i + \boldsymbol{\varepsilon}_i, \quad \boldsymbol{\varepsilon}_i \sim N_{n_i}(\mathbf{0}, \sigma^2 \mathbf{I}_{n_i}), \quad \boldsymbol{\varepsilon}_1 \perp \boldsymbol{\varepsilon}_2, \quad \boldsymbol{\beta}_i \in \mathbb{R}^p, \quad \sigma^2 > \mathbf{0}, \quad r(\mathbf{X}_i) = p, \quad i = 1, 2.$$

Muodosta näistä matriiseja käyttäen yksi malli ja esitä parametrin $\boldsymbol{\beta} = [\boldsymbol{\beta}'_1 \quad \boldsymbol{\beta}'_2]'$ PNS-estimaattorin $\hat{\boldsymbol{\beta}} = [\hat{\boldsymbol{\beta}}'_1 \quad \hat{\boldsymbol{\beta}}'_2]'$ jakauma. Ovatko PNS-estimaattorit $\hat{\boldsymbol{\beta}}_1$ ja $\hat{\boldsymbol{\beta}}_2$ riippumattomia?

Aputulos: Jos \mathbf{A} ja \mathbf{B} ovat epäsingulaarisia neliömatriiseja, niin

$$\begin{bmatrix} \mathbf{A} & \mathbf{0} \\ \mathbf{0} & \mathbf{B} \end{bmatrix}^{-1} = \begin{bmatrix} \mathbf{A}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{B}^{-1} \end{bmatrix}.$$

4. Jatkoa edelliselle. Estimoi parametri $\boldsymbol{\beta} = [\boldsymbol{\beta}'_1 \quad \boldsymbol{\beta}'_2]'$ ehdolla $\boldsymbol{\beta}_1 = \boldsymbol{\beta}_2$. Mikä on $\boldsymbol{\beta}_1$:n (ja $\boldsymbol{\beta}_2$:n) rajoitetun PNS-estimaattorin jakauma? (Tässä on käytännön kannalta oletuksena, että rajoite $\boldsymbol{\beta}_1 = \boldsymbol{\beta}_2$ on muuttujien luonne huomioon ottaen mielekäs, mikä on mahdollisesti todettu myös formaalissa testauksessa. Tässäkin tapauksessa monisteen s. 16-17 esitettyistä estimointitavoista kannattaa etsiä yksinkertaisinta.)

5. Tarkastellaan tehtävän 3 mallin erikoistapauksena kahta riippumatonta yhden selittäjän lineaarista regressiomallia

$$Y_1, \dots, Y_n \perp\!\!\!\perp, \quad Y_i \sim \begin{cases} N(\beta_1 + \beta_2 x_i, \sigma^2), & \text{kun } i = 1, \dots, n_1 \\ N(\beta_3 + \beta_4 x_i, \sigma^2), & \text{kun } i = n_1 + 1, \dots, n_1 + n_2 = n. \end{cases}$$

(i) Muotoile tilanne lineaarisena mallina käyttäen matriiseja.

(ii) Asetetaan parametreja β_2 ja β_4 sitova rajoite $\beta_2 = \beta_4$. Ilmaise tämä rajoite matriisimuodossa käyttäen monisteen yhtälöitä (2.7) ($\mathbf{A}\boldsymbol{\beta} = \mathbf{c}$) ja (2.9) ($\boldsymbol{\beta} = \mathbf{C}\boldsymbol{\phi} + \mathbf{d}$).

(iii) Esitä rajoitetun PNS-estimaatin lauseke, kun rajoite $\beta_2 = \beta_4$ muotoillaan yhtälön (2.9) mukaisesti.

(iv) Pohdi rajoitteen $\beta_2 = \beta_4$ tulkintaa, kun selitettävä muuttuja on lääkäreiden kuukausipalkka, selittävä muuttuja on työvuosien määrä ja sukupuoli määrää ryhmäjaon.