

- Havaintovektori $\mathbf{Y} = (y_1, \dots, y_n)$ toteuttaa $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$.
- MN-jakauman tiheysfunktion kaavasta saadaan

$$f_{\mathbf{Y}}(\mathbf{y}; \boldsymbol{\beta}, \sigma^2) = (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \right\}$$

- Siis, parametrien $\boldsymbol{\beta}$ ja σ^2 log-uskottavuusfunktio on

$$l(\boldsymbol{\beta}, \sigma^2; \mathbf{y}) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} S(\boldsymbol{\beta}),$$

jossa

$$S(\boldsymbol{\beta}) = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) = \sum_{i=1}^n (y_i - \mathbf{x}'_i \boldsymbol{\beta})^2$$

on ns. *jäännöseliösummafunktio* (\mathbf{x}'_i matriisin \mathbf{X} i . rivi).

- SU-estimaatit $\hat{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}}(\mathbf{y})$ ja $\hat{\sigma}^2 = \hat{\sigma}^2(\mathbf{y})$:

$$S(\hat{\boldsymbol{\beta}}) = \min_{\boldsymbol{\beta}} S(\boldsymbol{\beta}) \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n} S(\hat{\boldsymbol{\beta}})$$

- SU-estimaatit $\hat{\beta} = \hat{\beta}(\mathbf{y})$ ja $\hat{\sigma}^2 = \hat{\sigma}^2(\mathbf{y})$:

$$S(\hat{\beta}) = \min_{\beta} S(\beta) \quad \text{ja} \quad \hat{\sigma}^2 = \frac{1}{n} S(\hat{\beta})$$

- Minimointitehtävän ratkaisu johtaa *normaaliyhtälöihin*

$$\mathbf{X}'\mathbf{X}\beta = \mathbf{X}'\mathbf{y}.$$

- Oletuksesta $r(\mathbf{X}) = p$ seuraa $r(\mathbf{X}'\mathbf{X}) = p$ ja siten yksikäsitteinen ratkaisu (*pienimmän neliösumman (PNS) estimaatti*)

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}.$$


- Tämän jälkeen

$$\hat{\sigma}^2 = \frac{1}{n}(\mathbf{y} - \mathbf{X}\hat{\beta})'(\mathbf{y} - \mathbf{X}\hat{\beta}) = \frac{1}{n} \sum_{i=1}^n (y_i - \mathbf{x}'_i \hat{\beta})^2 = \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i^2.$$

SU-estimointi


Malli $Y_i = \beta_1 + \beta_2 x_i + \varepsilon_i$, $i = 1, \dots, n$, $\varepsilon_1, \dots, \varepsilon_n \perp\!\!\!\perp$, $\varepsilon_i \sim N(0, \sigma^2)$

PNS-estimaatti $\hat{\beta} = (\hat{\beta}_1, \hat{\beta}_2)$ minimoi funktion $\sum_{i=1}^n (y_i - \beta_1 - \beta_2 x_i)^2$ eli kuvan pystysuorien janojen pituuksien neliösumman.



SU-estimointi

Äitien ja tyttärien pituudet (tuumissa): $n=30$, punainen PNS-suora $y = 17.29 + 0.75x$, sininen katkoviiva $y = 1.53 + x$



- Tarkastellaan mallia

$$Y_i = \beta_1 + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i, \quad \varepsilon_1, \dots, \varepsilon_n \text{ i.i.d.}, \quad \varepsilon_i \sim N(0, \sigma^2).$$

- PNS-sovite ja -residuaali ovat $\hat{y}_i = y_i - \hat{\beta}_1 - \hat{\beta}_2 x_{i2} - \cdots - \hat{\beta}_p x_{ip}$ ja $\hat{\varepsilon}_i = y_i - \hat{y}_i$.
- Koska matriisin \mathbf{X} ensimmäinen sarake on nyt ykkösvektori $\mathbf{1}_n$, seuraa normaaliyhtälöistä $\mathbf{X}'\hat{\boldsymbol{\varepsilon}} = \mathbf{0}$ ja edelleen $\mathbf{1}'_n \hat{\boldsymbol{\varepsilon}} = \hat{\varepsilon}_1 + \cdots + \hat{\varepsilon}_n = 0$ ja

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i + \hat{\varepsilon}_i) = \frac{1}{n} \sum_{i=1}^n \hat{y}_i.$$

- Määritellään käsitteet:

- Kokonaisneliösumma $SST = \sum_{i=1}^n (y_i - \bar{y})^2$
- Regressionneliösumma $SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
- Residuaalineliosumma $SSE = \sum_{i=1}^n \hat{\varepsilon}_i^2$

- Määritellään käsitteet:

- Kokonaisneliösumma $SST = \sum_{i=1}^n (y_i - \bar{y})^2$
- Regressioneliösumma $SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
- Residuaalineliosumma $SSE = \sum_{i=1}^n \hat{\varepsilon}_i^2$

- *Kun mallissa on vakio*, näiden välillä on yhteys

$$SST = SSR + SSE.$$

- Mallin *selitysaste* on

$$R^2 = 1 - \frac{SSE}{SST} = \frac{SSR}{SST},$$

jossa jälkimmäinen yhtälö perustuu edellä todettuun identiteettiin.





- Selitysasteella ominaisuus

$$0 \leq R^2 \leq 1.$$

SU-estimointi

PNS-estimointi ja selityksaste

Simuloituihin aineistoihin sovitettuja PNS-suoria eri selityksastein, $n = 50$



- Selityssasteelle pätee

$$R^2 = r_{y\hat{y}}^2,$$

jossa $r_{y\hat{y}}$ on selitettävän muuttujan havaintojen y_i ja sovitteiden \hat{y}_i ($1, \dots, n$) välinen otoskorrelaatiokerroin.

- Koska

$$R = \sqrt{1 - \text{SSE}/\text{SST}} \quad \text{ja} \quad \text{SSE} = \min_{\beta} (\mathbf{y} - \mathbf{X}\beta)' (\mathbf{y} - \mathbf{X}\beta),$$

valitsee PNS-menetelmä sovitteeksi sen selittäjien lineaarikombinaation, jonka otoskorrelaatio selitettävän muuttujan kanssa maksimoituu (huomaa tulkinnan laskennallinen luonne).