

- 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

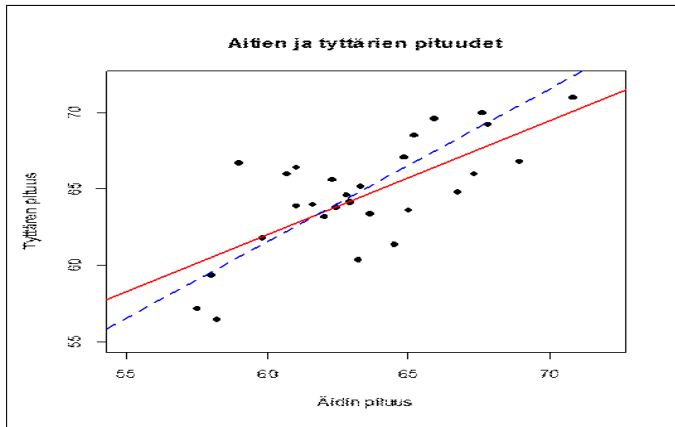
Malli $Y_i = \beta_1 + \beta_2 x_i + \varepsilon_i$, $i = 1, \dots, n$, $\varepsilon_1, \dots, \varepsilon_n \stackrel{\text{i.i.d.}}{\parallel}$, $\varepsilon_i \sim N(0, \sigma^2)$

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 $y = 1.53 + x$



- Lineaarialgebraa

- $\mathbf{a} \in \mathbb{R}^n$, $\|\mathbf{a}\| = (\mathbf{a}'\mathbf{a})^{1/2} = (a_1^2 + \dots + a_n^2)^{1/2}$ (\mathbf{a} :n normi) ja

$\mathbf{a} \perp \mathbf{b} \in \mathbb{R}^n \Leftrightarrow \mathbf{a}'\mathbf{b} = \sum_{i=1}^n a_i b_i = 0$ (\mathbf{a} :n ja \mathbf{b} :n kohtisuoruus)

- Matriisin \mathbf{X} ($n \times p$), $r(\mathbf{X}) = p$, sarakeavaruus

$\mathcal{R}(\mathbf{X}) = \{\mathbf{u} \in \mathbb{R}^n : \mathbf{u} = \mathbf{X}\mathbf{b} \text{ jollain } \mathbf{b} \in \mathbb{R}^p\}$, \mathbb{R}^n :n p -ul. aliav.

- $\mathcal{R}(\mathbf{X})$:n ortogonaalinen komplementti

$\mathcal{R}(\mathbf{X})^\perp = \{\mathbf{v} \in \mathbb{R}^n : \mathbf{X}'\mathbf{v} = \mathbf{0}\}$, \mathbb{R}^n :n $(n - p)$ -ul. aliav.

- $\mathbf{x} \in \mathbb{R}^n \Rightarrow \exists$ yksikäs. $\mathbf{u} \in \mathcal{R}(\mathbf{X})$ ja $\mathbf{v} \in \mathcal{R}(\mathbf{X})^\perp$ s.e. $\mathbf{x} = \mathbf{u} + \mathbf{v}$

- PNS-estimointi: Minimoitava

- $S(\boldsymbol{\beta}) = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2$, $\boldsymbol{\beta} \in \mathbb{R}^p$, tai

- $\|\mathbf{y} - \boldsymbol{\mu}\|$ ehdolla $\boldsymbol{\mu} \in \mathcal{R}(\mathbf{X})$

SU-estimointi

PNS-estimointi geometrisesti

- PNS-estimointi: Minimoitava $\|\mathbf{y} - \boldsymbol{\mu}\|$ ehdolla $\boldsymbol{\mu} \in \mathcal{R}(\mathbf{X})$ eli ehdolla $\boldsymbol{\mu} = \mathbf{X}\boldsymbol{\beta}$ jollain $\boldsymbol{\beta} \in \mathbb{R}^p$
- Lin. algebra \Rightarrow minimi saavutetaan, kun $\boldsymbol{\mu} = \hat{\boldsymbol{\mu}} = \mathbf{y}$:n ortog. projektio $\mathcal{R}(\mathbf{X})$:lle
 - Tällöin $\mathbf{y} = \hat{\boldsymbol{\mu}} + (\mathbf{y} - \hat{\boldsymbol{\mu}})$, jossa $\hat{\boldsymbol{\mu}} \in \mathcal{R}(\mathbf{X})$ ja $\mathbf{y} - \hat{\boldsymbol{\mu}} \in \mathcal{R}(\mathbf{X})^\perp$ ovat yksikäsitteisiä.
- Siis, $\hat{\boldsymbol{\mu}}$ valittava s.e. $\mathbf{y} - \hat{\boldsymbol{\mu}} \in \mathcal{R}(\mathbf{X})^\perp$ tai yhtäpitävästi s.e.

$$\mathbf{X}'(\mathbf{y} - \hat{\boldsymbol{\mu}}) = \mathbf{0} \Leftrightarrow \mathbf{X}'\mathbf{y} = \mathbf{X}'\hat{\boldsymbol{\mu}}$$

- Oletuksesta $r(\mathbf{X}) = p$ seuraa, että \exists yksikäsitteinen $\hat{\boldsymbol{\beta}}$ s.e. $\hat{\boldsymbol{\mu}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ ja myös, että $\mathbf{X}'\mathbf{X}$ on kääntövä, joten

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

- Siis, PNS-estimaatti $\hat{\boldsymbol{\beta}}$ minimoi jäännösneliösummafunktion $S(\boldsymbol{\beta})$

SU-estimointi

PNS-estimointi geometrisesti

- PNS-estimoinnista saadaan vektorille $\mathbf{y} = (y_1, \dots, y_n)$ hajotelma

$$\mathbf{y} = \hat{\mathbf{y}} + \hat{\boldsymbol{\varepsilon}}, \text{ jossa } \hat{\mathbf{y}}' \hat{\boldsymbol{\varepsilon}} = 0 \text{ eli } \hat{\mathbf{y}} \perp \hat{\boldsymbol{\varepsilon}},$$

ja $\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ on sovitevektori ja $\hat{\boldsymbol{\varepsilon}} = \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}$ on residuaalivektori.

- Lisäksi, jos $\mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ ($n \times n$), niin

$$\hat{\mathbf{y}} = \mathbf{P}\mathbf{y} \quad \text{ja} \quad \hat{\boldsymbol{\varepsilon}} = (\mathbf{I}_n - \mathbf{P})\mathbf{y}.$$

- \mathbf{P} on (ortog.) projektio(matriisi), joka projisoi \mathbb{R}^n :n vektorit matriisin \mathbf{X} p -ulotteiselle sarakeavaruudelle $\mathcal{R}(\mathbf{X})$.
- $\mathbf{I}_n - \mathbf{P}$ on (ortog.) projektio(matriisi), joka projisoi \mathbb{R}^n :n vektorit avaruuden $\mathcal{R}(\mathbf{X})$ ($n - p$)-ulotteiselle ortog. komplementille $\mathcal{R}(\mathbf{X})^\perp$.
- PNS-estimoinnissa selitettävän muuttujan vektori \mathbf{y} tulee siis esitetyksi yksikäsitteisesti kahden ortogonaalisen vektorin $\hat{\mathbf{y}} \in \mathcal{R}(\mathbf{X})$ ja $\hat{\boldsymbol{\varepsilon}} \in \mathcal{R}(\mathbf{X})^\perp$ summana.

- Tarkastellaan mallia

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

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

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

jossa jälkimmäinen yhtälö perustuu edellä todettuun identiteettiin.





- Selityssasteella ominaisuus

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

SU-estimointi

PNS-estimointi ja selitysaste

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



- 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

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

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