



Lineær regresjon

Torstein Fjeldstad

Institutt for matematiske fag, NTNU

04.04.2019

I dag

- Repetisjon
- Eksempel OL
- Eksempel imdb



Spørretimer/kontortid



- Det blir 3-4 spørretimer før eksamen på sal (tilsvarende statistikklab)
- Eg vil ha kontortid (send meg helst ein e-post på førehand for å avtale tid)

Spørretimer/kontortid



- Det blir 3-4 spørretimer før eksamen på sal (tilsvarende statistikklab)
- Eg vil ha kontortid (send meg helst ein e-post på førehand for å avtale tid)

Følg med på heimesida for tid og stad



Repetisjon

Enkel lineær regresjon



Situasjon: har observert par $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.

- x_1, x_2, \dots, x_n er kjende tal
- y_1, y_2, \dots, y_n er realisasjonar frå uavhengige stokastiske variablar Y_1, Y_2, \dots, Y_n med

$$Y_i|x_i \sim n(y_i; \alpha + \beta x_i, \sigma^2)$$

Merk:

$$E(Y_i|x_i) = \alpha + \beta x_i = \mu_i$$

$$\text{Var}(Y_i|x_i) = \sigma^2$$

Mål: estimere α, β og σ^2

Egenskapar til estimatorane

$$\hat{\beta} \sim n \left(z; \beta, \sqrt{\frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \right)$$

$$\hat{\alpha} \sim n \left(z; \alpha, \sqrt{\frac{\sigma^2 \sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2}} \right)$$

Merk

$$E(\hat{\sigma}^2) = \frac{n-2}{n} \sigma^2,$$

me nyttar derfor

$$S^2 = \frac{n}{n-2} \hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} x_i)^2$$

$$\frac{(n-2)S^2}{\sigma^2} \sim \chi^2_{n-2}$$

Typisk to mål med lineær regresjon



- Forstå samanhengen mellom x og y
- Predikere/forutsjå y -verdi for ein ny verdi $x = x_0$



Eksempel (eksamen desember 2012)

Eksempel




Vinnertid på 800 m løping for menn i OL
(siden 1912).

- Y_i er vinnertid i OL nummer i
 - x_i er årstal for OL nummer i
- for $i = 1, 2, \dots, 23$

Eksempel

Vinnertid på 800 m løping for menn i OL (siden 1912).


- Y_i er vinnertid i OL nummer i
 - x_i er årstal for OL nummer i
- for $i = 1, 2, \dots, 23$



Eksempel

Vinnertid på 800 m løping for menn i OL (siden 1912).

- Y_i er vinnertid i OL nummer i
 - x_i er årstal for OL nummer i
- for $i = 1, 2, \dots, 23$



Anta følgjande lineære samanheng

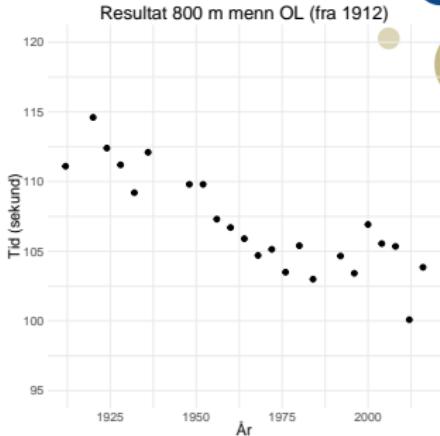
$$Y_i = \alpha + \beta x_i + \varepsilon_i$$

der $\varepsilon_i \sim n(\epsilon; 0, \sigma)$ og uavhengige.

Eksempel

Vinnertid på 800 m løping for menn i OL (siden 1912).

- Y_i er vinnertid i OL nummer i
 - x_i er årstal for OL nummer i
- for $i = 1, 2, \dots, 23$




Anta følgjande lineære samanheng

$$Y_i = \alpha + \beta x_i + \varepsilon_i$$

der $\varepsilon_i \sim n(\epsilon; 0, \sigma)$ og uavhengige.

Utlei eit $(1 - \alpha) \cdot 100\%$ konfidensintervall for β


Resultat eksempel



To typer intervall


- Konfidensintervall for $\mu_{Y|x_0}$ (regresjonslinja)
- Prediksjonsintervall for ein ny observasjon Y_0

Resultat 800 m menn OL (fra 1912)




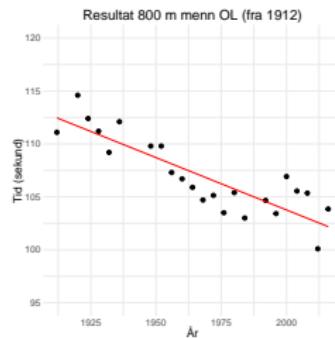
Undersøke modellantakingar

Frå 1912



Undersøke modellantakingar





Frå 1912



Undersøke modellantakingar

Frå 1912

Frå 1896



Modellantaktingar




- $E(Y_i|x_i) = \alpha + \beta x_i$
- $\text{Var}(Y_i|x_i) = \sigma^2$
- Y_i -ane er normalfordelt
- Y_i -ane er uavhengige




imdb eksempel

Publikumscore mot inntekt



Publikumscore mot inntekt



Publikumscore mot inntekt




Figure: Predikert verdi mot standardisert residual






Figure: Standardisert residual

Filmkritikerscore mot publikumscore



Filmkritikerscore mot publikumscore



Filmkritikerscore mot publikumscore




Figure: Predikert verdi mot standardisert residual




Figure: Standardisert residual

Neste veke



- Måndag: gjennomgang av heile pensum med nokre eksempel
- Torsdag: tidlegare eksamensoppgåver (send inn forslag innan måndag 08.04 kl. 16:00)