

Ekstraoppgave 4

Vi ser på den multiple linære regresjonsmodellen, der de stokastiske variablene Y_1, \dots, Y_n er gitt ved

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + \epsilon_i \quad (1)$$

og ϵ_i -ene er uavhengige og $N(0, \sigma^2)$ -fordelte. I denne oppgaven vil vi anta at forklaringsvariablene er sentrerte, dvs.

$$\sum_{i=1}^n x_{ij} = 0 \quad \text{for } j = 1, \dots, k \quad (2)$$

og ortogonale (ukorrelerte), dvs.

$$\sum_{i=1}^n x_{ij} x_{i\ell} = 0 \quad \text{for alle } j \neq \ell. \quad (3)$$

- a) Vis at minste kvadraters estimatorer er gitt ved

$$\hat{\beta}_0 = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i \quad (4)$$

og

$$\hat{\beta}_j = \frac{\sum_{i=1}^n x_{ij} Y_i}{\sum_{i=1}^n x_{ij}^2} \quad \text{for } j = 1, \dots, k. \quad (5)$$

Sammenlign (5) med den estimatoren du ville fått for den enkle linære regresjonsmodellen med x_{ij} som eneste forklaringsvariabel.

- b) Forklar at $\hat{\beta}_j$ -ene er normalfordelte, og vis at

$$E(\hat{\beta}_j) = \beta_j \quad \text{og} \quad V(\hat{\beta}_j) = \frac{\sigma^2}{\left(\sum_{i=1}^n x_{ij}^2\right)^2} \quad \text{for } j = 1, \dots, k$$

og at

$$\text{Cov}(\hat{\beta}_j, \hat{\beta}_\ell) = 0 \quad \text{for alle } j \neq \ell$$

De tilpassede verdiene er gitt ved

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}.$$

Fra den generelle teorien for multippel lineær regresjon har vi at

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

der

$$\text{SST} = \sum_{i=1}^n (Y_i - \bar{Y})^2, \quad \text{SSR} = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad \text{og} \quad \text{SSE} = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2.$$

c) Vis at vi kan skrive SSR på formen:

$$\text{SSR} = \hat{\beta}_1^2 \sum_{i=1}^n x_{i1}^2 + \hat{\beta}_2^2 \sum_{i=1}^n x_{i2}^2 + \cdots + \hat{\beta}_k^2 \sum_{i=1}^n x_{ik}^2.$$

d) Vis at vi kan skrive R^2 som

$$R^2 = r_1^2 + r_2^2 + \cdots + r_k^2,$$

der

$$r_j = \frac{\sum_{i=1}^n x_{ij} Y_i}{\sqrt{\left(\sum_{i=1}^n x_{ij}^2\right) \left(\sum_{i=1}^n (Y_i - \bar{Y})^2\right)}}$$

er den empiriske korrelasjonen mellom responsen og den j -te forklaringsvariabelen.