

# OLS, ML og MM i den lineære regressionsmodel

Erik Bennike

20. januar 2005

Denne note udleder OLS-estimatoren i en lineær regressionsmodel på tre forskellige måder, der alle tjener til at illustrere en anvendelse af disse metoder.

## 1 Den lineære regressionsmodel

Vi betragter en multipel lineær regressionsmodel

$$y_i = x_i' \beta + \epsilon_i, \quad (1)$$

hvor  $x_i$  og  $\beta$  er  $k$ -dimensionale vektorer. Der er således  $k - 1$  forklarende variable i modellen. Tilsvarende skrives i matrix notation:

$$y = X\beta + \epsilon, \quad (2)$$

hvor  $X$  er en  $n \times k$ -dimensional matrix,  $y$  og  $\epsilon$  er  $n$ -dimensionale vektorer og  $\beta$  er en  $k$ -dimensional vektor. Om der undervejs anvendes matrix-notation eller ej er et spørgsmål om bekvemmelighed. Vi vil løbende antage at de reducerede Gauss-Markov betingelser er opfyldt (opskrevet på matrixform):

$$E[\epsilon|X] = 0 \Rightarrow E[\epsilon X] = 0 \quad (3)$$

$$\text{var}[\epsilon|X] = \sigma^2 I_n \quad (4)$$

### 1.1 Ordinary Least Squares

Termen *OLS* stammer fra den oprindelige udledningsmetode - nemlig *Ordinary Least Squares*, hvilket indikerer at man ønsker at minimere de kvadrerede residualer. Dvs. at vi

opstiller følgende minimeringsproblem:

$$\min_{\beta} (y_i - x'_i \beta)^2$$

For at minimere udtrykket udnyttes de  $k$  førsteordensbetingelser:

$$\begin{aligned} 2 \sum_{i=1}^n (y_i - x'_i \hat{\beta})(-x_i) &= 0 \Rightarrow \\ \sum_{i=1}^n x_i (y_i - x'_i \hat{\beta}) &= 0 \Rightarrow \\ \sum_{i=1}^n x_i x'_i \hat{\beta} &= \sum_{i=1}^n x_i y_i \Rightarrow \\ \hat{\beta}_{OLS} &= \left( \sum_{i=1}^n x_i x'_i \right)^{-1} \sum_{i=1}^n x_i y_i = (X'X)^{-1} X'Y \end{aligned} \quad (5)$$

Bemærk at vi undervejs har antaget at matricen  $\sum_{i=1}^n x_i x'_i = X'X$  er invertibel. Dette kræver at den er regulær, hvilket igen kræver at der ikke er lineært afhængige søjler i matricen. Hvis der er lineært afhængige søjler i matricen er vi i tilfældet med perfekt multikollinearitet. OLS-estimatoren er således kun defineret under fravær af perfekt multikollinearitet.

Variansen kan estimeres ud fra det faktum, at  $\sigma^2 = E[u^2] \Rightarrow \hat{\sigma}^2 = n^{-1} \sum_{i=1}^n \hat{\epsilon}_i^2$ . Problemet er bare, at denne estimator for variansen viser sig at være biased. Derfor anvendes i stedet estimatoren:

$$\hat{\sigma}^2 = \frac{1}{n-k} \sum_{i=1}^n \hat{\epsilon}_i^2 \quad (6)$$

## 1.2 Maximum Likelihood

For at kunne opstille likelihood ligningerne er vi udover antagelserne (3) og (4) nødt til også at specificere en fordeling for  $\epsilon_i$ . Her vælger vi at antage at fejleddet er normalfordelt. Dvs. en ekstra antagelse er her, at

$$\epsilon_i | x_i \sim N(0, \sigma^2) \Rightarrow y_i | x_i \sim N(x'_i \beta, \sigma^2)$$

Tæthedsfunktionen for normalfordelingen giver os, at

$$f(y_i | x_i, \beta, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp \left\{ -\frac{1}{2} \frac{(y_i - x'_i \beta)^2}{\sigma^2} \right\},$$

som er sandsynligheden for at observere  $y_i$ . Idet observationerne er antaget at være i.i.d. kan vi opskrive sandynligheden for at observere den rent faktisk observerede følge af  $y_i$ 'er,  $\{y_i\}_{i=1}^n$  som

$$f(\{y_i\}_{i=1}^n | \{x_i\}_{i=1}^n, \beta, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp \left\{ -\frac{1}{2} \frac{(y_i - x_i'\beta)^2}{\sigma^2} \right\}.$$

Dermed kan vi opskrive likelihood funktionen som

$$L(\beta, \sigma^2) = \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \cdot \prod_{i=1}^n \exp \left\{ -\frac{1}{2} \frac{(y_i - x_i'\beta)^2}{\sigma^2} \right\}.$$

Det er betragteligt lettere at maksimere log-likelihood funktionen:

$$\log L(\beta, \sigma^2) = -\frac{n}{2} \cdot \log(2\pi\sigma^2) - \frac{1}{2} \cdot \sum_{i=1}^n \frac{(y_i - x_i'\beta)^2}{\sigma^2}.$$

Vi vælger derefter estimatorerne for  $\beta$  og  $\sigma^2$ , således at de maksimerer ovenstående udtryk. Førsteordensbetingelserne mht.  $\beta$  er

$$\begin{aligned} \sum_{i=1}^n \frac{x_i(y_i - x_i'\hat{\beta})}{\sigma^2} &= 0 \Rightarrow \\ \sum_{i=1}^n x_i(y_i - x_i'\hat{\beta}) &= \sum_{i=1}^n (x_i y_i - x_i x_i' \hat{\beta}) = 0 \Rightarrow \\ \hat{\beta}_{ML} &= \left( \sum_{i=1}^n x_i x_i' \right)^{-1} \sum_{i=1}^n x_i y_i = (X'X)^{-1} X'Y = \hat{\beta}_{OLS} \end{aligned} \quad (7)$$

Også her må vi således antage fravær af perfekt multikollinearitet, idet matrixen  $X'X$  ikke må være singular. Førsteordensbetingelserne mht.  $\sigma^2$  er

$$\begin{aligned} -\frac{n}{2\sigma^2} + \frac{1}{2} \frac{(y_i - x_i'\hat{\beta})^2}{\sigma^4} &= 0 \Rightarrow \\ \frac{1}{2} \frac{\hat{\epsilon}_i^2}{\sigma^4} &= \frac{n}{2\sigma^2} \Rightarrow \\ \hat{\sigma}_{ML}^2 &= \frac{1}{n} \sum_{i=1}^n \hat{\epsilon}_i^2 \end{aligned} \quad (8)$$

Denne estimator for variansen er biased, men konsistent, jf. diskussionen ovenfor.

### 1.3 Method of Moments

I MM metoden tages udgangspunkt i de såkaldte momentbetingelser. Vi benytter antagelsen (3), og opstiller momentbetingelsen for hele populationen på matrixform her:

$$E[X\epsilon] = E[X(y - X\beta)] = 0$$

Den tilsvarende sample momentbetingelse er:

$$g_n(\beta) = \frac{1}{n}X'(y - X\beta) = \frac{1}{n}(X'y - X'X\beta) = 0 \Rightarrow$$
$$X'y = X'X\beta \Rightarrow$$

$$\hat{\beta}_{MM} = (X'X)^{-1}X'y \quad (9)$$

Som vi såvel OLS som ML må vi således også for MM estimation antage fravær af perfekt multikollinearitet, endnu engang fordi vi må kræve at matricen  $X'X$  er regulær.