


IDAG: Minstakvadrat-metoden  
och (linjär) regression

- Mål:
- "Lösa" L.E.S. som saknar lösning
  - Approximera experimentell data med t.ex. polynom

Linjär regression har vi förmodligen stött på redan i gymnasiet (utan riktig förklaring).

Det handlar om att givet några par av datapunkter  $(x_1, y_1), (x_2, y_2), \dots, (x_p, y_p)$  anpassa en rät linje  $y = kx + m$  som ligger närmast punkterna.



Vad betyder "närmast"?


Låt  $\varepsilon = (\varepsilon_1, \dots, \varepsilon_p)$  vara vektorn av skillnader,

$$\varepsilon_j = y_j - (kx_j + m) \quad , j=1, \dots, p.$$

Den bästa approximativa linjen är den som minimerar  $\|\varepsilon\|$ . Man kan använda olika normer  $\|\cdot\|$ , men vi tar den vi definierat, dvs. minimera  $\sqrt{\sum_{j=1}^p \varepsilon_j^2} = \|\varepsilon\|_2$

OBS:  $\Leftrightarrow$  minimera  $\sum_{j=1}^p \epsilon_j^2$  (utan kvadratrot)

Visuellt:



Vi kallar  $y_j$  observationen,  
 $kx_j + m$  prediktionen och  
 $\epsilon$  residualen.

Självva linjen motsvarar en minstakvadrat-lösning  
 (p.g.a. vad vi minimerar).

För att använda samma notation som de flesta  
 ingenjörer och statistiker kommer vi

hädanefter istället för  $kx+m$  skriva

$$y = \beta_0 + \beta_1 x$$

$\beta_0$  och  $\beta_1$  är de sökta parametrarna, och  
 vi får  $p$  ekvationer:

$$\beta_0 + \beta_1 x_1 = y_1$$

$$\beta_0 + \beta_1 x_2 = y_2$$

⋮

$$\beta_0 + \beta_1 x_p = y_p$$

Detta är uppfyllt om punkterna  $(x_j, y_j)$   
 ligger på linjen, och då är  $\epsilon = 0$ .

Vi skriver systemet som  $X\beta = y$

$$\text{där } X = \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_p \end{bmatrix}, \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} \text{ och } y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_p \end{bmatrix}.$$

Om systemet inte har en lösning  
(dvs. punkterna ligger ej på linjen) så har vi  
fortfarande  $\varepsilon = X\beta - y$ ,

så vår uppgift är att minimera  $\|X\beta - y\|$ .

Def. Låt  $X \in \mathbb{R}^{m \times n}$ ,  $y \in \mathbb{R}^m$ . Då är  $\hat{\beta}$  en  
minstakvadrat-lösning till  $X\beta = y$  om

$$\|X\hat{\beta} - y\| \leq \|X\beta - y\| \quad \text{för alla } \beta \in \mathbb{R}^n.$$

OBS: Mer generellt  $X$  än tidigare!  $\begin{pmatrix} m \text{ punkter/ekv.} \\ n \text{ variabler} \end{pmatrix}$

Eftersom  $\{X\beta \mid \beta \in \mathbb{R}^n\} = \text{Col}(X)$  så är

$X\hat{\beta}$  den ortogonala projektionen av  $y$  på  $\text{Col}(X)$ .  
(Sats 6.3.9)

Vi skriver  $\hat{y} = X\hat{\beta} = \text{proj}_{\text{Col } X} y$ .

Vi vet att  $\hat{y} - y \in (\text{Col } X)^\perp$ .

Men enligt Sats 6.1.3 är  $(\text{Col } X)^\perp = \text{Nul}(X^T)$ ,

så  $X^T(\hat{y} - y) = 0$  dvs.  $X^T(X\hat{\beta} - y) = 0$

Alltså har vi

$$X^T X \hat{\beta} = X^T y$$

Detta kallas normalekvationerna för  $X\beta = y$ .

Notera att om  $X \in \mathbb{R}^{m \times n}$  så är  $X^T X \in \mathbb{R}^{n \times n}$

och  $X^T y \in \mathbb{R}^n$  så om vi har  $m > n$  (fler ekv. än variabler)

så har ändå normalekv.  $n$  ekv. och  $n$  variabler.

Ex. Låt  $X = \begin{bmatrix} 1 & -1 \\ 1 & 0 \\ 1 & 1 \end{bmatrix}$  och  $y = \begin{bmatrix} 1 \\ 1 \\ 2 \end{bmatrix}$ .

Då har  $X\beta = y$  inga lösningar ( $\beta_1 = 0$  och  $\beta_2 = 1$ !).

Bilda  $X^T X = \begin{bmatrix} 1 & 1 & 1 \\ -1 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & -1 \\ 1 & 0 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 3 & 0 \\ 0 & 2 \end{bmatrix}$

$$X^T y = \begin{bmatrix} 1 & 1 & 1 \\ -1 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 2 \end{bmatrix} = \begin{bmatrix} 4 \\ 1 \end{bmatrix}$$

Då ger  $X^T X \hat{\beta} = X^T y$  att  $\hat{\beta} = \frac{1}{6} \begin{bmatrix} 8 \\ 3 \end{bmatrix}$ .

Notera att  $X \hat{\beta} = \frac{1}{6} \begin{bmatrix} 5 \\ 8 \\ 11 \end{bmatrix}$  vilket är nära

$y$ , men inte lika med  $y$ .

Residualen är  $\varepsilon = y - \hat{y} = y - X \hat{\beta} = \frac{1}{6} \begin{bmatrix} 1 \\ -2 \\ 1 \end{bmatrix}$

Så minstakvadrat felet är  $\|\varepsilon\| = \frac{1}{6} \sqrt{1^2 + (-2)^2 + 1^2} = \frac{\sqrt{6}}{6}$

Jämför med  $\|y\| = \sqrt{6}$ :

Det relativa felet är  $\frac{\frac{\sqrt{6}}{6}}{\sqrt{6}} = \frac{1}{6} \approx 0.167$ ,

dvs. 16.7%.

Inte särskilt bra anpassning (men bästa);  
kan antyda att punkterna inte följer ett  
linjärt samband eller att mätfelet är väldigt stora.

I MATLAB fås  $\hat{\beta}$  genom  $\hat{\beta} = X \setminus y$ ,

dvs. samma syntax som när  $X\beta = y$  har  
en lösning!  $\longrightarrow$

Därför viktigt att kontrollera om det verkligen är en lösning eller en minstakvadrat-lösning.

MATLAB använder också  $A=QR$  istället för normalekvationerna: Läs kort om detta i lag (och på nästa sida).

### Mer generell regression

Istället för linjer kan vi även anpassa polynom av högre grad (vi antog ju bara  $X \in \mathbb{R}^{m \times m}$ )

Om t.ex.  $y = \beta_0 + \beta_1 x + \beta_2 x^2$  får vi

$X\beta = y$  där

$$X = \begin{bmatrix} 1 & x_1 & x_1^2 \\ \vdots & \vdots & \vdots \\ 1 & x_m & x_m^2 \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{bmatrix} \quad \text{och} \quad y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix}$$

Ännu mer generellt kan vi ta

$$y = \beta_0 f_0(x) + \beta_1 f_1(x) + \dots + \beta_k f_k(x)$$

Då blir

$$X = \begin{bmatrix} f_0(x_1) & f_1(x_1) & \dots & f_k(x_1) \\ f_0(x_2) & f_1(x_2) & \dots & f_k(x_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_0(x_m) & f_1(x_m) & \dots & f_k(x_m) \end{bmatrix}$$

Minstakvadrat-lösningen minimerar då

$$\|e\|^2 = \sum_{j=1}^m (y_j - \beta_0 f_0(x_j) - \dots - \beta_k f_k(x_j))^2$$

# MATLAB-DEMO

Där vi anpassar en linje och ett polynom av grad 3 till data från verkligheten, och ser farorna med extrapolation.

## QR för minsta-kvadrat-problem

I stället för att lösa normalekvationerna direkt

kan vi QR-faktorisera först:  $X = QR$

med  $Q$  ortogonal och  $R$  övertriangulär.

Vi får

$$X^T X \beta = X^T y \Leftrightarrow R^T Q^T Q R \beta = R^T Q^T y$$

Men  $Q^T Q = I$ , och om  $X$  har lin.ober. kolonner är  $R$  inv. (lag), så

$$X^T X \beta = X^T y \Leftrightarrow R \beta = Q^T y$$

Triangulärt system: lös med bakåt substitution!

Lite billigare beräkning, men säkrare:

Om  $X$  är känslig så är  $X^T X$  "kvadratiskt" känslig, medan  $Q^T R$  är ungefär som  $X$ .

Med konditionstal (lab 3):

$$\kappa(X^T X) \approx \kappa(X)^2 \quad \text{men} \quad \kappa(Q^T R) \approx \kappa(X).$$