


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 $(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)$ anpassa en rät linje $y = kx + m$ som ligger närmast punkterna.
inte samma m



Vad betyder "närmast"?


Låt $\epsilon = (\epsilon_1, \dots, \epsilon_m)$ vara vektorn av skillnader,

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

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

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

Visuellt:



hädanefter istället för $kx+m$ skriva

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

β_0 och β_1 är de sökta parametrarna, och

vi får m ekvationer:

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

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

\vdots

$$\beta_0 + \beta_1 x_m = y_m$$

Detta är uppfyllt om punkterna (x_j, y_j)

ligger på linjen, och då är $\epsilon = 0$.

Vi skriver systemet som $X\beta = y$

$$\text{där } X = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_m \end{bmatrix}, \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} \text{ och } y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix}.$$

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

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

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

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!

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

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

Bilda $X^T X = \begin{bmatrix} 1 & 1 & 0 \\ -1 & 1 & 2 \end{bmatrix} \begin{bmatrix} 1 & -1 \\ 1 & 1 \\ 0 & 2 \end{bmatrix} = \begin{bmatrix} 2 & 0 \\ 0 & 6 \end{bmatrix}$

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

Då ger $X^T X \hat{\beta} = X^T y$ att $\hat{\beta} = \begin{bmatrix} 1/3 \\ 2/3 \end{bmatrix}$.

Notera att $X \hat{\beta} = \begin{bmatrix} 1/3 \\ 5/3 \\ 4/3 \end{bmatrix}$ vilket är rätt

olikt y .

Residualen är $e = y - \hat{y} = y - X \hat{\beta} = \begin{bmatrix} 2/3 \\ -2/3 \\ 2/3 \end{bmatrix}$

Så minstakvadratfelet är $\|e\| = \sqrt{\frac{4}{9} + \frac{4}{9} + \frac{4}{9}} = \sqrt{\frac{4}{3}} = \frac{2\sqrt{3}}{3}$

Jämför med $\|y\| = \sqrt{6}$:

Det relativa felet är $\frac{\frac{2\sqrt{3}}{3}}{\sqrt{6}} = \frac{2}{3\sqrt{2}} = \frac{\sqrt{2}}{3} \approx \frac{1.41}{3} = 0.47$

dvs. 47%!

Inte särskilt bra anpassning (men bästa);

kan antyda att punkterna inte följer ett linjärt samband eller att mätfeLEN 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

Där för 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.

Mer generell regression

Istället för linjer kan vi även anpassa polynom av högre grad (vi antog ju bara $X \in \mathbb{R}^{m \times 3}$)

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

$$X\beta = y \quad \text{där}$$

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

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.