

Seksjon 6.6: Maskinlæring og lineære modeller

Anta at vi er gitt punkter $(x_1, y_1), \dots, (x_n, y_n)$, og vil finne linjen $y = \beta_0 + \beta_1 x$ som "best tilpasser" disse punktene

linear modell

- $\{y_i\}$ kalles observeerde verdier. $\vec{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}$ kalles en observasjonsvektor
- $\{\beta_0 + \beta_1 x_i\}$ kalles predikerte verdier for y_j
- Differansene $y_j - (\beta_0 + \beta_1 x_j)$ kalles residualer.

"best tilpasser": Det som gir minst mulig avvik mellom observeerde og predikerte verdier:

$$\sum_j (y_j - (\beta_0 + \beta_1 x_j))^2$$

$$= \left\| \vec{y} - \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} \right\|^2$$

komponent j :

$$[1 \ x_j] \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \beta_0 + \beta_1 x_j$$

Med andre ord: $\begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$ er minste kuradraters løsningen til

$$\begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}$$

$X \quad \vec{\beta} \quad \vec{y}$

Konsepter:

- Linja $\beta_0 + \beta_1 x$ kalles en regressionslinje, eller minste kuradraters linje

- β_0, β_1 kalles regressionskoeffisienter, eller parametre

- $\begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix}$ kalles designmatrisen

Oppgave 2 Finn minste kvaradraters linjen som best tilpasser punktene $(1,0), (2,2), (3,7), (4,9)$.

Løsning: Observasjonsvektoren: $\vec{y} = \begin{bmatrix} 0 \\ 2 \\ 7 \\ 9 \end{bmatrix}$

Designmatrisen: $X = \begin{bmatrix} 1 & 1 \\ 1 & 2 \\ 1 & 3 \\ 1 & 4 \end{bmatrix}$

$$X^T X = \begin{bmatrix} 4 & 10 \\ 10 & 30 \end{bmatrix} \quad X^T \vec{y} = \begin{bmatrix} 18 \\ 61 \end{bmatrix}$$

$$[X^T X \quad X^T \vec{y}] = \begin{bmatrix} 4 & 10 & 18 \\ 10 & 30 & 61 \end{bmatrix} \sim \begin{bmatrix} 1 & 5/2 & 9/2 \\ 10 & 30 & 61 \end{bmatrix}$$

$$\sim \begin{bmatrix} 1 & 5/2 & 9/2 \\ 0 & 5 & 16 \end{bmatrix} \sim \begin{bmatrix} 1 & 5/2 & 9/2 \\ 0 & 1 & 16/5 \end{bmatrix}$$

$$\sim \begin{bmatrix} 1 & 0 & -7/2 \\ 0 & 1 & 16/5 \end{bmatrix}$$

minste kvaradraters linjen blir $\underline{\underline{y = -\frac{7}{2} + \frac{16}{5}x}}$

minste kvaradraters feil blir $\|\vec{y} - X\vec{\beta}\| \approx 1.3416$ ■

Det er ikke sikkert observasjonene våre lar seg tilnærme bra med en rett linje.

Lå oss prøve i stedet å finne $\beta_0, \beta_1, \beta_2$ s.a.

$$y_j \approx \beta_0 + \beta_1 x_j + \beta_2 x_j^2.$$

mer generelt, finn $\beta_0, \beta_1, \dots, \beta_k$ s.a.

$$y_j \approx \beta_0 + \beta_1 x_j + \dots + \beta_k x_j^k$$

Sum av kvadrater av residualer:

$$\begin{aligned} & \sum_j (y_j - (\beta_0 + \beta_1 x_j + \dots + \beta_k x_j^k))^2 \\ &= \sum_j \left(y_j - [1 \ x_j \ \dots \ x_j^k] \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \right)^2 \\ &= \| \vec{y} - \begin{bmatrix} 1 & x_1 & \dots & x_1^k \\ 1 & x_2 & \dots & x_2^k \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & \dots & x_n^k \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \| \end{aligned}$$

ny designmatrise regressjonskoeffisienter/parametre

Oppgave 2 igjen Finn minste kvadraters parabolen som best tilpasser punktene.

Løsning: Nå får vi

$$X = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 4 \\ 1 & 3 & 9 \\ 1 & 4 & 16 \end{bmatrix} \quad \vec{y} = \begin{bmatrix} 0 \\ 2 \\ 7 \\ 9 \end{bmatrix}$$

$$X^T X = \begin{bmatrix} 4 & 10 & 30 \\ 10 & 30 & 100 \\ 30 & 100 & 354 \end{bmatrix} \quad X^T \vec{y} = \begin{bmatrix} 18 \\ 61 \\ 215 \end{bmatrix}$$

I Matlab: $X^T X \setminus X^T \vec{y}$ gir resultat $\hat{\vec{x}} = \begin{bmatrix} -\frac{7}{2} \\ 16/5 \\ 0 \end{bmatrix}$

$$\text{minste kvadraters parabel } y = \beta_0 + \beta_1 x + \beta_2 x^2 \Rightarrow y = -\frac{7}{2} + \frac{16}{5}x + 0x^2$$

Fikk samme som forminste kvadraters linjen!

Hva med minste kvadraters tredjegrads tilnærming for oppgave 2?

$$Ny designmatrise: \quad X = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 4 & 8 \\ 1 & 3 & 9 & 27 \\ 1 & 4 & 16 & 64 \end{bmatrix}$$

$$X^T X \setminus X^T \vec{y} \quad \text{gir n\o} \quad \vec{\beta} = \begin{bmatrix} 7 \\ -\frac{27}{2} \\ \frac{15}{2} \\ -1 \end{bmatrix} \begin{array}{l} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \end{array}$$

$$\text{regressjonspolynomet: } \underline{7 - \frac{27}{2}x + \frac{15}{2}x^2 - x^3}$$

$$\text{Minste kvadraters feil: } \| \vec{y} - X\vec{\beta} \| = 0.$$

Hvis man istedet vil finne en minste kvaraters tilnærming på formen $A \cos x + B \sin x$:

Vi får designmatrisen $X = \begin{bmatrix} \cos x_1 & \sin x_1 \\ \cos x_2 & \sin x_2 \\ \vdots & \vdots \\ \cos x_n & \sin x_n \end{bmatrix}$, regresjonskoeffisienter $\begin{bmatrix} A \\ B \end{bmatrix}$

Se oppgave 6.6.15 til neste uke.