


4. Lineære mindste kvadraters problemer pp 55 – 60

Eksempel 4.1. Målt længden ℓ_i for forskellige belastninger p_i af en fjeder.

i	p_i	ℓ_i
1	0.8	7.97
2	1.6	10.2
3	2.4	14.2
4	3.2	16.0
5	4.0	21.2



Punkterne ligger omkring en ret linie $\ell = x_1 + x_2 p$ (Hookes lov)

Ønsker at bestemme parametrene x_1 og x_2

Data fitting: Givet $(t_1, y_1), (t_2, y_2), \dots, (t_n, y_n)$, som antages at opfylde $y_i = Y(t_i) + \varepsilon_i$, hvor $Y: \mathbb{R} \mapsto \mathbb{R}$ er en vis "baggrunds-funktion" og $\{\varepsilon_i\}$ er "støj", fx målefejl.

Videre har vi givet (eller vælger) en **fitte model**

$$M(\mathbf{x}, t) = x_1 f_1(t) + x_2 f_2(t) + \dots + x_n f_n(t)$$

hvor $\{f_j\}$ er kendte funktioner og $n \leq m$. Ofte $n \ll m$.

Vi ønsker at bestemme parametrene $\{x_j\}$, dvs n -vektoren \mathbf{x} , så $M(\mathbf{x}, t)$ er den "bedst mulige" tilnærmelse til $Y(t)$ i intervallet $\min\{t_i\} \leq t \leq \max\{t_i\}$

"Bedst mulig" ? Udnyt tilgængelig information.

$$\begin{aligned} \text{Residuer } r_i(\mathbf{x}) &= y_i - M(\mathbf{x}, t_i) \\ &= y_i - (x_1 f_1(t_i) + x_2 f_2(t_i) + \dots + x_n f_n(t_i)) \end{aligned}$$

Mindste kvadrater: Bestem $\hat{\mathbf{x}}$, det sæt parametre, som minimerer kvadratsummen af residuerne, dvs minimerer funktionen $\varphi(\mathbf{x}) = r_1(\mathbf{x})^2 + r_2(\mathbf{x})^2 + \dots + r_m(\mathbf{x})^2$

Udnytter at parametrene optræder **lineært** :

$$\mathbf{r}(\mathbf{x}) = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{pmatrix} - \begin{pmatrix} f_1(t_1)x_1 + f_2(t_1)x_2 + \dots + f_n(t_1)x_n \\ f_1(t_2)x_1 + f_2(t_2)x_2 + \dots + f_n(t_2)x_n \\ \vdots \\ f_1(t_m)x_1 + f_2(t_m)x_2 + \dots + f_n(t_m)x_n \end{pmatrix} = \mathbf{y} - \mathbf{F}\mathbf{x}$$

hvor \mathbf{F} er $m \times n$ matricen

$$\mathbf{F} = \begin{pmatrix} f_1(t_1) & f_2(t_1) & \dots & f_n(t_1) \\ f_1(t_2) & f_2(t_2) & \dots & f_n(t_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(t_m) & f_2(t_m) & \dots & f_n(t_m) \end{pmatrix}$$

Eksempel 4.2. Fjeder problem. Last omdøbes fra

p til t . $M(\mathbf{x}, t) = x_1 + x_2 t$, dvs

$$f_1(t) = 1, \quad f_2(t) = t$$

$$\mathbf{y} = \begin{pmatrix} 7.97 \\ 10.2 \\ 14.2 \\ 16.0 \\ 21.2 \end{pmatrix}, \quad \mathbf{F} = \begin{pmatrix} 1 & 0.8 \\ 1 & 1.6 \\ 1 & 2.4 \\ 1 & 3.2 \\ 1 & 4.0 \end{pmatrix}$$


Vi vil forudsætte, at søjlerne i \mathbf{F} er lineært uafhængige

Eksempel. $m = n$: \mathbf{F} er en kvadratisk, regulær (iflg forudsætningen) matrix, og $\mathbf{r}(\mathbf{x}) = \mathbf{0}$ (og dermed $\varphi(\mathbf{x}) = 0$) for $\hat{\mathbf{x}} = \mathbf{F}^{-1}\mathbf{y}$, dvs løsningen til det lineære ligningssystem $\mathbf{F}\mathbf{x} = \mathbf{y}$

Hvis $m > n$ kan vi normalt ikke finde en \mathbf{x} , som opfylder alle ligninger i det **overbestemte system** $\mathbf{F}\mathbf{x} = \mathbf{y}$

Eksempel 4.3 – 4.4. $m = 3, n = 2$. Alle vektorer $\mathbf{z} = \mathbf{F}\mathbf{x}$ ligger i **billedrummet** for \mathbf{F} , som er planen udspændt af de to søjler i \mathbf{F} .

Pythagoras: $\varphi(\mathbf{x}) = \|\mathbf{r}(\mathbf{x})\|^2$ er mindst, når \mathbf{r} er vinkelret på billedrummet



$\hat{\mathbf{r}} = \mathbf{y} - \mathbf{F}\hat{\mathbf{x}}$ ortogonal til alle søjler i \mathbf{F} : $\mathbf{F}^T(\mathbf{y} - \mathbf{F}\hat{\mathbf{x}}) = \mathbf{0} \Leftrightarrow$

Normalligninger: $(\mathbf{F}^T\mathbf{F})\hat{\mathbf{x}} = \mathbf{F}^T\mathbf{y}$

Tidligere vist: $n \times n$ matricen $\mathbf{A} = \mathbf{F}^T\mathbf{F}$ er **SPD**: symmetrisk og positivt definit.

Kan udnyttes til at vise, at løsningen til normalligningerne faktisk minimerer φ :

$$\mathbf{r}(\hat{\mathbf{x}} + \mathbf{u}) = \mathbf{y} - \mathbf{F}(\hat{\mathbf{x}} + \mathbf{u}) = \hat{\mathbf{r}} - \mathbf{F}\mathbf{u} \quad \mathbf{F}^T\hat{\mathbf{r}} = \mathbf{0}$$


$$\begin{aligned} \varphi(\hat{\mathbf{x}} + \mathbf{u}) &= (\hat{\mathbf{r}} - \mathbf{F}\mathbf{u})^T(\hat{\mathbf{r}} - \mathbf{F}\mathbf{u}) \\ &= \hat{\mathbf{r}}^T\hat{\mathbf{r}} - \hat{\mathbf{r}}^T\mathbf{F}\mathbf{u} - \mathbf{u}^T\mathbf{F}^T\hat{\mathbf{r}} + \mathbf{u}^T\mathbf{F}^T\mathbf{F}\mathbf{u} \\ &= \hat{\mathbf{r}}^T\hat{\mathbf{r}} + \mathbf{u}^T\mathbf{A}\mathbf{u} > \hat{\mathbf{r}}^T\hat{\mathbf{r}} \quad \text{hvis } \mathbf{u} \neq \mathbf{0} \end{aligned}$$

Eksempel 4.5. Fjeder

$$\mathbf{y} = \begin{pmatrix} 7.97 \\ 10.2 \\ 14.2 \\ 16.0 \\ 21.2 \end{pmatrix}, \quad \mathbf{F} = \begin{pmatrix} 1 & 0.8 \\ 1 & 1.6 \\ 1 & 2.4 \\ 1 & 3.2 \\ 1 & 4.0 \end{pmatrix}, \quad \begin{pmatrix} 5 & 12 \\ 12 & 35.2 \end{pmatrix} \begin{pmatrix} \hat{x}_1 \\ \hat{x}_2 \end{pmatrix} = \begin{pmatrix} 69.57 \\ 192.776 \end{pmatrix},$$

$$\hat{\mathbf{x}} = \begin{pmatrix} 4.2360 \\ 4.0325 \end{pmatrix}$$

Dvs $M(\hat{\mathbf{x}}, p) = 4.2360 + 4.0325p$ er den bedste model i mindste kvadraters forstand



Eksempel 4.6. Koncentration af medicin i nyrerne.

Compartment model $Y(t) = c_1 e^{\lambda_1 t} + c_2 e^{\lambda_2 t}$


Hvis vi kender λ_1 og λ_2 , er

$$M(\mathbf{x}, t) = x_1 e^{\lambda_1 t} + x_2 e^{\lambda_2 t}$$

en god fitte model. Fittet er beregnet med

$\lambda_1 = -0.15$, $\lambda_2 = -0.30$, og mindste kvadraters

løsningen er $\hat{x}_1 = 1.006$, $\hat{x}_2 = -1.011$



Hvis vi ikke kender λ_1 og λ_2 , kan vi bruge fitte modellen

$$M(\mathbf{x}, t) = x_1 e^{x_3 t} + x_2 e^{x_4 t}$$

Ulineær model. Bestemmelsen af $\hat{\mathbf{x}}$ er et af emnerne i kursus 02610 *Optimering og data fitting*

MATLAB: Data i søjle-vektorer \mathbf{t} og \mathbf{y} . `lam = [-0.15, -0.30]` (række-vektor)

`F = exp(t*lam); xh = F \ y`

\mathbf{xh} indeholder mindste kvadraters løsningen.

Hvordan beregnes den ? (Ikke via normalligningerne)

4. Lineære mindste kvadraters problemer pp 61 – 66

Givet m -vektoren \mathbf{y} og $m \times n$ -matricen \mathbf{F} (med $n \leq m$). Søger $\hat{\mathbf{x}}$, den \mathbf{x} , som minimerer $\|\mathbf{y} - \mathbf{F}\mathbf{x}\|$. Samme vektor, som minimerer

$$\|\mathbf{y} - \mathbf{F}\mathbf{x}\|^2 = \|\mathbf{r}(\mathbf{x})\|^2 = \mathbf{r}(\mathbf{x})^T \mathbf{r}(\mathbf{x}) = r_1(\mathbf{x})^2 + r_2(\mathbf{x})^2 + \dots + r_m(\mathbf{x})^2$$

Eksempel. Data fitting.

Givet (måle)punkter $(t_1, y_1), (t_2, y_2), \dots, (t_m, y_m)$ og lineær fitte model


$$M(\mathbf{x}, t) = x_1 f_1(t) + x_2 f_2(t) + \dots + x_n f_n(t)$$

$$r_i(\mathbf{x}) = y_i - M(\mathbf{x}, t_i) = y_i - \mathbf{F}_{i,:} \mathbf{x},$$

idet $(\mathbf{F})_{ij} = f_j(t_i)$

Figur: Lys-intensitet i optisk fiber efter afbrydelse af lyskilden. Fit med 6. grads polynomium,


$$f_1(t) = 1, f_2(t) = t, \dots, f_7(t) = t^6$$



Mindste kvadraters løsningen kan findes via **Normalligningerne** : $(F^T F) \hat{x} = F^T y$.

Mere nøjagtige beregninger via

4.2. QR faktorisering. Kan bestemme en **ortogonal** matrix $Q = \begin{pmatrix} \hat{Q} & \check{Q} \end{pmatrix}$ så



Lineært uafhængige søjler i $F \iff$ alle $r_{ii} \neq 0$. Forudsættes

$F = \hat{Q}R$ er økonomiudgaven af QR faktoriseringen.

Søjlerne i \hat{Q} er en ortonormal basis for billedrummet for F

Vilkårlig ortogonal Q : $\|Qr\|^2 = r^T Q^T Q r = r^T r = \|r\|^2$

Dvs $\min \|r(x)\|$ for samme x som $\min \|Qr(x)\|$

Brug Q^T fra QR faktoriseringen: $F = Q \begin{pmatrix} R \\ 0 \end{pmatrix} \Rightarrow Q^T F = \begin{pmatrix} R \\ 0 \end{pmatrix}$

$$\mathbf{Q}^T \mathbf{r}(x) = \mathbf{Q}^T (\mathbf{y} - \mathbf{F}x) = \mathbf{Q}^T \mathbf{y} - \begin{pmatrix} \mathbf{R} \\ 0 \end{pmatrix} x = \begin{pmatrix} \hat{\mathbf{Q}}^T \mathbf{y} - \mathbf{R}x \\ \check{\mathbf{Q}}^T \mathbf{y} \end{pmatrix}$$

$$\left\| \begin{pmatrix} \hat{Q}^T \mathbf{y} - R\mathbf{x} \\ \check{Q}^T \mathbf{y} \end{pmatrix} \right\|^2 = \|\hat{Q}^T \mathbf{y} - R\mathbf{x}\|^2 + \|\check{Q}^T \mathbf{y}\|^2$$

Minimum $\|Q^T r(x)\| = \|r(x)\|$ for \hat{x} bestemt ved $R\hat{x} = \hat{Q}^T y$

Hvis forudsætningen er opfyldt, er R regulær, og \hat{x} éntydig

Eksempel 4.7. MATLAB

$$x = F \setminus y$$

beregner løsningen via QR faktorisering af F

$$[Q, RR] = q_r(F)$$

returnerer hele Q og $m \times n$ matricen $\begin{pmatrix} R \\ 0 \end{pmatrix}$. $R = R(1:n, :)$ giver R

$$[Qh, R] = q_r(F, 0)$$

giver økonomiudgaven \hat{Q} og R