

# Linearni problem najmanjših kvadratov

- 1 Uvod
- 2 Normalni sistem
- 3 QR razcep
- 4 Gram-Schmidtova ortogonalizacija
- 5 Givensove rotacije
- 6 Householderjeva zrcaljenja
- 7 Singularni razcep

## Primer

*Hitrost  $v$  je linearno odvisna od časa  $t$ , torej  $v(t) = \alpha t + \beta$ . Hitrost smo izmerili ob več časih  $t_j$ ,  $j = 1, 2, \dots, N$ . Torej imamo na voljo približke  $v_j \approx v(t_j)$ ,  $j = 1, 2, \dots, N$ . Kako na podlagi meritev "najbolje" določiti koeficienta  $\alpha$  in  $\beta$ ?*

# Normalni sistem

- V splošnem je problem naslednji: dana je matrika  $A \in \mathbb{R}^{m \times n}$ ,  $m > n$  in vektor  $\mathbf{b} \in \mathbb{R}^m$ , iščemo vektor  $\mathbf{x} \in \mathbb{R}^n$ , da bo napaka  $\|A\mathbf{x} - \mathbf{b}\|_2$  minimalna (lahko uporabimo tudi druge norme, a je problem tedaj ponavadi težji). Takemu vektorju  $\mathbf{x}$  rečemo **rešitev** po metodi najmanjših kvadratov.
- Če  $A$  ni polnega ranga, rešitev ni enolična.
- Privzamemo, da je  $A$  polnega ranga, torej  $\text{rang}(A) = n$ .
- Normalni sistem enačb je

$$A^T A \mathbf{x} = A^T \mathbf{b}.$$

## Lema

*Rešitev normalnega sistema je rešitev po metodi najmanjših kvadratov.*

- Normalni sistem rešujemo z **razcepom Choleskega**.
- **Metoda je preprosta, vendar ni stabilna** (težave, ko so stolpci matrike  $A$  skoraj linearno odvisni).

# QR razcep

- Denimo, da poznamo razcep  $A = QR$ ,  $Q \in \mathbb{R}^{m \times n}$  z ortonormiranimi stolpci in  $R \in \mathbb{R}^{n \times n}$  zgornja trikotna (razcepu pravimo QR razcep).

- Potem je

$$\mathbf{x} = (A^T A)^{-1} A^T \mathbf{b} = \dots = R^{-1} Q^T \mathbf{b}.$$

- Rešiti moramo torej samo zgornji trikotni sistem

$$R\mathbf{x} = Q^T \mathbf{b}.$$

- Reševanje preko QR razcepa je stabilnejše od reševanja normalnega sistema.

# Gram-Schmidtova ortogonalizacija

## Izrek

*Naj bo  $A \in \mathbb{R}^{m \times n}$ ,  $m \geq n$ ,  $\text{rang}(A) = n$ . Potem obstaja enolični QR razcep, kjer je  $Q \in \mathbb{R}^{m \times n}$  matrika z ortonormiranimi stolpci,  $R \in \mathbb{R}^{n \times n}$  pa zgornja trikotna matrika s pozitivnimi diagonalnimi elementi.*

- Poznamo več postopkov za QR razcep.
- **Klasični Gram-Schmidtov postopek (CGS)** (ortogonaliziramo vseskozi glede na originalno matriko).
- **Modificirani Gram-Schmidtov postopek (MGS)** (ortogonaliziramo glede na že izračunano matriko).
- Izkaže se, da je **MGS stabilnejši od GS**.

```
function [Q,R]=gram_schmidt(A,tip)
%GRAM_SCHMIDT je Gram-Schmidtova ortogonalizacija
%[Q,R]=GRAM_SCHMIDT(A,tip)
%Q je ortogonalna, R zgornja trikotna
%A je matrika mxn, m>=n, rang(A)=n
%tip='gs' za klasicni Gram-Schmidt
%tip='mgs' za modificirani Gram-Schmidt

[m,n]=size(A);
Q=zeros(m,n);
R=zeros(n);
```



```
switch tip
case 'gs'
    for k=1:n
        Q(:,k)=A(:,k);
        for i=1:k-1
            R(i,k)=Q(:,i)' $\cdot$ A(:,k);
            Q(:,k)=Q(:,k)-R(i,k)*Q(:,i);
        end
        R(k,k)=norm(Q(:,k),2);
        Q(:,k)=Q(:,k)/R(k,k);
    end
end
```

```
case 'mgs'  
  for k=1:n  
    Q(:,k)=A(:,k);  
    for i=1:k-1  
      R(i,k)=Q(:,i)'  
      *Q(:,k);  
      Q(:,k)=Q(:,k)-R(i,k)*Q(:,i);  
    end  
    R(k,k)=norm(Q(:,k),2);  
    Q(:,k)=Q(:,k)/R(k,k);  
  end  
end
```

- Pri reševanju predoločenega sistema z GMS moramo paziti, da **ne** izračunamo najprej QR razcepa in potem rešujemo trikotni sistem.
- Namesto tega razcepimo razširjeno matriko  $[A \mathbf{b}]$ , torej

$$[A \mathbf{b}] = [Q \mathbf{q}_{n+1}] \begin{bmatrix} R & \mathbf{z} \\ & \rho \end{bmatrix}$$

in rešujemo  $R\mathbf{x} = \mathbf{z}$ .

# Givensove rotacije

- Rotacija vektorja  $\mathbf{x} \in \mathbb{R}^2$  za kot  $\varphi$  v negativni smeri je dana z matriko

$$R^\top = \begin{bmatrix} c & s \\ -s & c \end{bmatrix},$$

kjer je  $c = \cos \varphi$  in  $s = \sin \varphi$ .

- To posplošimo na rotacijo v ravnini  $(i, k)$  prostora  $\mathbb{R}^n$

$$R_{ik}([i, k], [i, k])^\top = \begin{bmatrix} c & s \\ -s & c \end{bmatrix}.$$

- Če je  $\mathbf{y} = R_{ik}^\top \mathbf{x}$ , je

$$y_j = x_j, \quad j \neq i, k$$

$$y_i = c x_i + s x_k$$

$$y_k = -s x_i + c x_k$$

in  $c$  ter  $s$  lahko izberemo tako, da bo  $y_k = 0$ :

$$r = \sqrt{x_i^2 + x_k^2}$$

$$c = x_i / r$$

$$s = x_k / r.$$

- Matriko  $R_{ik}$  imenujemo **Givensova rotacija**.
- Z ustreznim vrstnim redom rotacij lahko izračunamo QR razcep matrike  $A$ .

- Za QR razcep z Givensovimi rotacijami potrebujemo približno

$$3 m n^2 - n^3$$

operacij.

- Če potrebujemo še  $Q$ , je še dodatnih

$$6 m n^2 - 3 m n^2$$

operacij.

```
function [Q,R]=qr_givens(A)
%QR_GIVENS izvede QR razcep z Givensovimi rotacijami
%[Q,R]=QR_GIVENS(A)
%A je mxn matrika
%Q je mxm ortogonalna
%R je 'zgornje' trikotna

[m,n]=size(A);
korakov=min([n,m-1]);
Q=eye(m);
```

```

for j=1:korakov
    for i=j+1:m
        if A(i,j)~=0
            r=sqrt(A(j,j)^2+A(i,j)^2);
            c=A(j,j)/r;
            s=A(i,j)/r;
            rot=[c s;-s c];
            A([j,i],j:end)=rot*A([j,i],j:end);
            Q([j,i],:)=rot*Q([j,i],:);
        end
    end
end
R=triu(A);
Q=Q';

```



# Householderjeva zrcaljenja

- Za  $\mathbf{w} \in \mathbb{R}^n$ ,  $\mathbf{w} \neq \mathbf{0}$  definiramo matriko

$$P = I - \frac{2}{\mathbf{w}^\top \mathbf{w}} \mathbf{w} \mathbf{w}^\top.$$

- Matrika  $P$  je smetrična, ortogonalna in velja  $P^2 = I$ .
- $P$  je zrcaljenje preko hiperravnine, ki je pravokotna na  $\mathbf{w}$ .
- Osnovna naloga: poiskati tak  $P$ , da v danem vektorju  $\mathbf{x}$  uniči vse komponente, razen prve, torej

$$P\mathbf{x} = \pm k \mathbf{e}_1.$$

- Velati mora  $|k| = \|\mathbf{x}\|_2$  in  $\mathbf{w} = \mathbf{x} \pm k \mathbf{e}_1$ .
- Zaradi numeričnih razlogov je najbolje izbrati

$$\mathbf{w} = \begin{bmatrix} x_1 + \text{sign}(x_1)\|\mathbf{x}\|_2 \\ x_2 \\ \vdots \\ x_n \end{bmatrix},$$

pri čemer je

$$\text{sign}(x) = \begin{cases} 1; & x \geq 0, \\ -1; & x < 0. \end{cases}$$

- Podobno kot pri Givensovih rotacijah sedaj uporabimo Householderjeva zrcaljenja za QR razcep.
- Postopoma “uničujemo” elemente pod diagonalo v posameznem stolpcu.
- Pri tem pazimo, da ne “pokvarimo” prej pridobljenih ničel.
- Na posameznem koraku torej množimo z matriko

$$\tilde{P}_i = \begin{bmatrix} I_i & \mathbf{0}^\top \\ \mathbf{0} & P_i \end{bmatrix},$$

kjer je  $I_i$  identiteta dimenzije  $i$  in  $P_i$  Householderjevo zrcaljenje, ki v  $i$ -tem stolpcu “uniči” elemente na mestih  $i + 1, i + 2, \dots, n$ .

- Zaporedje takih množenj producira matriko  $R$ , torej

$$\tilde{P}_n \tilde{P}_{n-1} \cdots \tilde{P}_1 A = R.$$

- Ker so  $\tilde{P}_i$  simetrične ortogonalne, je

$$Q = \tilde{P}_1 \cdots \tilde{P}_n.$$

- Ponavadi namesto računanja  $Q$  shranimo vektorje  $\mathbf{w}_i$ .
- Števil operacij za reševanje predoločenega sistema s Householderjevimi zrcaljenji je približno

$$2mn^2 - \frac{2}{3}n^3.$$

- Seveda lahko QR uporabimo tudi za reševanje nesingularnega kvadratnega sistema  $A\mathbf{x} = \mathbf{b}$ .

Primerjava metod za reševanje predoločenega in kvadratnega sistema  $A\mathbf{x} = \mathbf{b}$ :

- Reševanje predoločenega sistema  $A\mathbf{x} = \mathbf{b}$ ,  $m \gg n$ :
  - ▶ normalni:  $m n^2$ ,
  - ▶ MGS:  $2 m n^2$ ,
  - ▶ Givens:  $3 m n^2 - n^3$
  - ▶ Householder:  $2 m n^2 - \frac{2}{3}n^3$ .
- Reševanje kvadratnega sistema  $A\mathbf{x} = \mathbf{b}$ ,  $m = n$ :
  - ▶ LU razcep:  $\frac{2}{3}n^3$ ,
  - ▶ Givens:  $2n^3$
  - ▶ Householder:  $\frac{4}{3}n^3$ .
- Sta pa Givensova in Householderjeva metoda stabilnejši od LU razcepa z delnim ali kompletnim pivotiranjem.

# Singularni razcep

## Izrek

*Za vsako matriko  $A \in \mathbb{R}^{m \times n}$ ,  $m \geq n$ , obstaja singularni razcep*

$$A = U \Sigma V^T,$$

*kjer sta  $U \in \mathbb{R}^{m \times m}$  in  $V \in \mathbb{R}^{n \times n}$  ortogonalni matriki in  $\Sigma \in \mathbb{R}^{m \times n}$  "kvazidiagonalna" matrika z elementi  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$ . Elementom  $\sigma_j$  rečemo tudi singularne vrednosti, stolpci matrike  $U$  so levi singularni vektorji, stolpci matrike  $V$  pa desni singularni vektorji.*

## Lema

Če je  $A \in \mathbb{R}^{m \times n}$  in  $\text{rang}(A) = n$ , je minimum  $\|A\mathbf{x} - \mathbf{b}\|_2$  dosežen pri vektorju

$$\mathbf{x} = \sum_{j=1}^n \frac{\mathbf{u}_j^\top \mathbf{b}}{\sigma_j} \mathbf{v}_j.$$

## Izrek

Naj bo  $A = U \Sigma V^\top$  singularni razcep matrike  $A \in \mathbb{R}^{m \times n}$ ,  $m \geq n$ , in  $\text{rang}(A) > k$ . Naj bo

$$A_k = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^\top.$$

Potem je

$$\min_{\text{rang}(B)=k} \|B - A\|_2 = \|A_k - A\|_2 = \sigma_{k+1}$$

in

$$\min_{\text{rang}(B)=k} \|B - A\|_F = \|A_k - A\|_F = \sqrt{\sum_{i=k+1}^n \sigma_i^2}.$$



- Prejšnji izrek lahko uporabimo pri stiskanju slik. Sliko, ki je predstavljena z matriko, aproksimiramo z matriko nizkega ranga.
- Metoda je relativno preprosta, vendar se dandanes uporabljajo boljše metode (kosinusna transformacija (JPEG) ali valčki (JPEG2000)).
- Singularni razcep je uporaben še na mnogih drugih področjih in je **eden najpomembnejših razcepov v linearni algebri**.
- Poznamo dobre algoritme za izračun singularnega razcepa, ki pa so seveda relativno zapleteni.