

# Numerička matematika

## 7. predavanje

Saša Singer i Nela Bosner

PMF - Matematički odsjek, Zagreb

# Sadržaj predavanja

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

# Minimizacija 2-norme vektora pogreške

Neka je funkcija  $f$

- ▶ zadana na **diskretnom** skupu točaka (čvorova)  $x_0, \dots, x_n$ .

Uzmimo da točaka  $x_0, \dots, x_n$  ima **mного više** nego **nepoznatih** parametara  $a_0, \dots, a_m$  aproksimacijske funkcije  $\varphi$ , tj.  $n \gg m$ .

U **diskretnoj** metodi najmanjih kvadrata, aproksimacijska funkcija

$$\varphi(x) = \varphi(x; a_0, \dots, a_m)$$

određuje se tako da **2-norma** vektora **pogrešaka** u **čvorovima** aproksimacije bude **najmanja moguća**, tj. **minimizira** se

$$S = \sum_{k=0}^n (f(x_k) - \varphi(x_k; a_0, \dots, a_m))^2 \rightarrow \min.$$

# Sustav normalnih jednažbi

Ovdje se  $S$  gleda kao funkcija nepoznatih parametara

$$S = S(a_0, \dots, a_m) : \mathbb{R}^{m+1} \rightarrow \mathbb{R}.$$

Uočimo da uvijek vrijedi  $S \geq 0$ , bez obzira na to kakvi su parametri, jer se radi o zbroju kvadrata.

- ▶ Funkcija  $S$  se minimizira kao funkcija više varijabli  $a_0, \dots, a_m$ .
- ▶ Pretpostavljamo da je  $S$  dovoljno glatka funkcija, kao funkcija parametara  $a_k$ , pa je nužni uvjet ekstrema

$$\frac{\partial S}{\partial a_k} = 0, \quad k = 0, \dots, m.$$

Ovaj pristup vodi na tzv. sustav normalnih jednažbi.

# Diskretna metoda najmanjih kvadrata za pravac

**Primjer.** Zadane su točke  $(x_0, f_0), \dots, (x_n, f_n)$ , koje treba, po diskretnoj metodi najmanjih kvadrata, aproksimirati **pravcem**


$$\varphi(x) = a_0 + a_1x.$$

**Suma kvadrata grešaka** ove aproksimacije u čvorovima je (to je izraz kojeg **minimiziramo**)

$$\begin{aligned} S &= S(a_0, a_1) = \sum_{k=0}^n (f_k - \varphi(x_k))^2 \\ &= \sum_{k=0}^n (f_k - a_0 - a_1x_k)^2 \rightarrow \min. \end{aligned}$$

# Diskretna metoda najmanjih kvadrata za pravac

Slika **zadanih** točaka u ravnini i **pravca** koji ih aproksimira:



Uočiti da se **greška** u svakoj točki “mjeri” u **smjeru** osi **y**, pa je

$$S = S(a_0, a_1) = \sum_{k=0}^n (f_k - a_0 - a_1 x_k)^2 \rightarrow \min.$$

Može se gledati i “**okomita**” udaljenost do pravca  $\rightarrow$  problem “**potpunih**” najmanjih kvadrata (engl. “total least squares”).



# Diskretna metoda najmanjih kvadrata za pravac

Parcijalne derivacije po parametrima  $a_0$  i  $a_1$  su:

$$0 = \frac{\partial S}{\partial a_0} = -2 \sum_{k=0}^n (f_k - a_0 - a_1 x_k),$$

$$0 = \frac{\partial S}{\partial a_1} = -2 \sum_{k=0}^n (f_k - a_0 - a_1 x_k) x_k.$$

Dijeljenjem s  $-2$  i sređivanjem po nepoznanicama  $a_0$ ,  $a_1$ , dobivamo **linearni sustav**

$$a_0(n+1) + a_1 \sum_{k=0}^n x_k = \sum_{k=0}^n f_k$$

$$a_0 \sum_{k=0}^n x_k + a_1 \sum_{k=0}^n x_k^2 = \sum_{k=0}^n f_k x_k.$$

# Diskretna metoda najmanjih kvadrata za pravac

Uvedemo li standardne **skraćene oznake**

$$s_\ell = \sum_{k=0}^n x_k^\ell, \quad t_\ell = \sum_{k=0}^n f_k x_k^\ell, \quad \ell \geq 0,$$

onda linearni sustav možemo napisati kao

$$s_0 a_0 + s_1 a_1 = t_0$$

$$s_1 a_0 + s_2 a_1 = t_1.$$

Matrica ovog sustava je (**Gramova** matrica)


$$M = \begin{bmatrix} n+1 & \sum_{k=0}^n x_k \\ \sum_{k=0}^n x_k & \sum_{k=0}^n x_k^2 \end{bmatrix} = X^T X, \quad X = \begin{bmatrix} 1 & x_0 \\ 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix}.$$

Uz **uvjet** da imamo **barem dvije različite** točke  $x_k$ , stupci od  $X$  su linearno nezavisni, pa je  $M$  **regularna**.

U tom slučaju, postoji **jedinstveno** rješenje sustava.

## Diskretna metoda najmanjih kvadrata za pravac

Slika **situacije** u kojoj problem najmanjih kvadrata za pravac **nema** rješenja, s tim da je  $n \geq m = 1$ , tj. imamo barem **dvije** točke podataka:



Ako imamo **više različitih** podataka u **jednoj** jedinjoj točki  $x_0$ ,

- ▶ aproksimacijski **pravac** (očito) **postoji** i jedinstven je,
- ▶ ali je **okomit** na  $x$ -os (jednadžba je  $x = x_0$ ),
- ▶ pa njegova jednadžba **nema** oblik  $y = a_0 + a_1 x$ .

# Minimalnost rješenja?

Je li dobiveno rješenje zaista minimum?

- ▶ To nije teško pokazati, korištenjem drugih parcijalnih derivacija — dovoljan uvjet minimuma je pozitivna definitnost Hesseove matrice (v. kasnije, za opći slučaj).

Provjera je li to minimum, može i puno lakše, jer se radi o zbroju kvadrata. Onda,

- ▶  $S$  predstavlja paraboloid s otvorom prema gore, u varijablama  $a_0, a_1$ , tj. nad  $(a_0, a_1)$ -ravninom,
- ▶ pa je očito da takav paraboloid ima minimum.

Zbog toga se nikad ni ne provjerava je li dobiveno rješenje minimum za  $S$ .

# Najmanji kvadrati za polinome

Za funkciju  $\varphi$  mogli bismo uzeti i **polinom višeg stupnja**,

$$\varphi(x) = a_0 + a_1x + \cdots + a_mx^m.$$

Međutim, tu postoji **opasnost** — za malo veće  $m$  ( $m \approx 10$ )

- ▶ dobiveni sustav je (skoro sigurno) **vrlo loše uvjetovan**,
- ▶ pa dobiveni **rezultati** mogu biti jako **pogrešni**.

U praksi se to **nikada** direktno ne radi (na ovaj način), čim je  $m \geq 2, 3$ .

Ako se koriste aproksimacije **polinomima viših stupnjeva**,

- ▶ onda se to radi korištenjem tzv. **ortogonalnih polinoma** (vidjeti kasnije).

# Najmanji kvadrati za opće linearne funkcije

**Linearni model** diskretnih najmanjih kvadrata je potpuno primjenjiv na **opću linearnu funkciju**

$$\varphi(x) = a_0\varphi_0(x) + \cdots + a_m\varphi_m(x),$$

gdje su  $\varphi_0, \dots, \varphi_m$  poznate (zadane) funkcije.

- ▶ **Linearnost** se ovdje odnosi na **linearnu ovisnost** aproksimacijske funkcije  $\varphi$  o parametrima  $a_0, \dots, a_m$ .

**Zadatak.** Zadane su točke  $(x_0, f_0), \dots, (x_n, f_n)$ , koje treba, po diskretnoj metodi najmanjih kvadrata, aproksimirati funkcijom oblika

$$\varphi(x) = a_0\varphi_0(x) + a_1\varphi_1(x).$$

**Rješenje.** Ide sasvim analogno (pogledati u skripti).

# Što s nelinearnim funkcijama?

Što ako  $\varphi$  **nelinearno** ovisi o parametrima?

- ▶ Dobivamo **nelinearni** sustav jednačbi, koji se relativno **teško** rješava.
- ▶ Problem postaje **ozbiljan** optimizacijski problem, koji se može **približno** rješavati.
- ▶ Metode koje se najčešće koriste su **metode pretraživanja** ili **Levenberg–Marquardt** metoda.

Postoji i **drugi** pristup.

- ▶ Katkad se jednostavnim **transformacijama** problem može transformirati u **linearni** problem najmanjih kvadrata.
- ▶ Rješenja lineariziranog i nelinearnog problema **nisu jednaka**, jer je i greška (**nelinearno**) transformirana!

# Primjer nelinearnih najmanjih kvadrata

**Primjer.** Zadane su točke  $(x_0, f_0), \dots, (x_n, f_n)$ , koje, po diskretnoj metodi najmanjih kvadrata, treba aproksimirati funkcijom oblika

$$\varphi(x) = a_0 e^{a_1 x}.$$

Uočite da  $\varphi$  **nelinearno** ovisi o parametru  $a_1$ .

**Direktni pristup** problemu vodi na minimizaciju

$$\begin{aligned} S &= S(a_0, a_1) = \sum_{k=0}^n (f_k - \varphi(x_k))^2 \\ &= \sum_{k=0}^n (f_k - a_0 e^{a_1 x_k})^2 \rightarrow \min. \end{aligned}$$



# Primjer nelinearnih najmanjih kvadrata

Parcijalnim deriviranjem po varijablama  $a_0$  i  $a_1$  dobivamo

$$0 = \frac{\partial S}{\partial a_0} = -2 \sum_{k=0}^n (f_k - a_0 e^{a_1 x_k}) e^{a_1 x_k},$$

$$0 = \frac{\partial S}{\partial a_1} = -2 \sum_{k=0}^n (f_k - a_0 e^{a_1 x_k}) a_0 x_k e^{a_1 x_k}.$$

To je **nelinearan** sustav jednažbi, kojeg ne znamo riješiti!

S **druge** strane, ako **logaritmujemo** relaciju

$$\varphi(x) = a_0 e^{a_1 x},$$

dobivamo

$$\ln \varphi(x) = \ln(a_0) + a_1 x.$$

## Primjer nelinearnih najmanjih kvadrata

Moramo **logarimirati** još i zadane vrijednosti funkcije  $f$  u točkama  $x_k$ . Uz supstitucije

$$h(x) = \ln f(x), \quad h_k = h(x_k) = \ln f_k, \quad k = 0, \dots, n,$$

i

$$\psi(x) = \ln \varphi(x) = b_0 + b_1 x,$$

gdje je

$$b_0 = \ln a_0, \quad b_1 = a_1,$$

dobivamo **linearni** problem najmanjih kvadrata

$$\begin{aligned} \tilde{S} &= \tilde{S}(b_0, b_1) = \sum_{k=0}^n (h_k - \psi(x_k))^2 \\ &= \sum_{k=0}^n (h_k - b_0 - b_1 x_k)^2 \rightarrow \min. \end{aligned}$$

# Primjer nelinearnih najmanjih kvadrata

Grafički, to je **pravac** u tzv. **lin–log** skali. Iz rješenja  $b_0$  i  $b_1$ , lako izlaze  $a_0$  i  $a_1$

$$a_0 = e^{b_0}, \quad a_1 = b_1.$$

Napomene uz **linearizaciju**:

- ▶ Pri linearizaciji smo pretpostavili da je  $f_k > 0$ , da bismo mogli **logaritmirati**.
- ▶ Ovako dobiveno rješenje **uvijek** daje **pozitivan**  $a_0$ , tj. linearizirani  $\varphi(x)$  će uvijek biti veći od 0.
- ▶ Kad su **neki**  $f_k \leq 0$ , korištenjem **translacije** svih podataka treba dobiti  $f_k + \text{translacija} > 0$ , pa onda linearizirati.
- ▶ Pokušajte **korektno** formulirati takvu **linearizaciju**!
- ▶ Ako su **svi**  $f_k < 0$ , onda napravimo supstituciju  $f \mapsto -f$ .

# Tipične linearizacije — opća potencija

Kratki pregled nekih funkcija koje se često koriste i njihovih standardnih linearizacija u problemu najmanjih kvadrata.

(a) Funkcija

$$\varphi(x) = a_0 x^{a_1}$$

linearizira se logaritmiranjem (u nekoj izabranoj bazi)

$$\begin{aligned}\psi(x) &= \log \varphi(x) = \log(a_0) + a_1 \log x, \\ h_k &= \log f_k, \quad k = 0, \dots, n.\end{aligned}$$

Uvedimo oznake

$$b_0 = \log(a_0), \quad b_1 = a_1.$$

# Tipične linearizacije — opća potencija

Linearizirani problem najmanjih kvadrata glasi

$$\tilde{S} = \tilde{S}(b_0, b_1) = \sum_{k=0}^n (h_k - b_0 - b_1 \log(x_k))^2 \rightarrow \min,$$

Grafički, to odgovara pravcu u tzv. log–log skali.

U ovom slučaju, da bismo mogli provesti linearizaciju,

- ▶ mora biti i  $x_k > 0$  i  $f_k > 0$ .

# Tipične linearizacije — 1 / linearna funkcija

(b) Funkcija

$$\varphi(x) = \frac{1}{a_0 + a_1 x}$$

linearizira se na sljedeći način

$$\psi(x) = \frac{1}{\varphi(x)} = a_0 + a_1 x,$$
$$h_k = \frac{1}{f_k}, \quad k = 0, \dots, n.$$

Pripadni **linearni** problem najmanjih kvadrata je

$$\tilde{S} = \tilde{S}(a_0, a_1) = \sum_{k=0}^n (h_k - a_0 - a_1 x_k)^2 \rightarrow \min.$$

# Tipične linearizacije — $x$ / linearna funkcija

(c) Funkciju

$$\varphi(x) = \frac{x}{a_0 + a_1 x}$$

možemo linearizirati na **više** načina.

1. način:

$$\psi(x) = \frac{1}{\varphi(x)} = a_0 \frac{1}{x} + a_1,$$
$$h_k = \frac{1}{f_k}, \quad k = 0, \dots, n.$$

Pripadni **linearni** problem najmanjih kvadrata je

$$\tilde{S} = \tilde{S}(a_0, a_1) = \sum_{k=0}^n \left( h_k - a_0 \frac{1}{x_k} - a_1 \right)^2 \rightarrow \min.$$

# Tipične linearizacije — $x$ / linearna funkcija

2. način:

$$\psi(x) = \frac{x}{\varphi(x)} = a_0 + a_1 x,$$

$$h_k = \frac{x_k}{f_k}, \quad k = 0, \dots, n.$$

Pripadni **linearni** problem najmanjih kvadrata je

$$\tilde{S} = \tilde{S}(a_0, a_1) = \sum_{k=0}^n (h_k - a_0 - a_1 x_k)^2 \rightarrow \min.$$



# Tipične linearizacije — još jedan primjer

(d) Funkcija

$$\varphi(x) = \frac{1}{a_0 + a_1 e^{-x}}$$

linearizira se stavljanjem

$$\psi(x) = \frac{1}{\varphi(x)} = a_0 + a_1 e^{-x},$$
$$h_k = \frac{1}{f_k}, \quad k = 0, \dots, n.$$

Pripadni **linearni** problem najmanjih kvadrata je

$$\tilde{S} = \tilde{S}(a_0, a_1) = \sum_{k=0}^n (h_k - a_0 - a_1 e^{-x_k})^2 \rightarrow \min.$$

# Primjer

**Primjer.** Uvaženi znanstvenik **dr. Zurić**, Ulica astronoma 69, dobio je ideju da se Zemlja giba oko Sunca po **eliptičnoj orbiti**, sa Suncem u jednom fokusu.

Nakon niza opažanja i mjerenja (uz dosta računa), dobio je slijedeće podatke

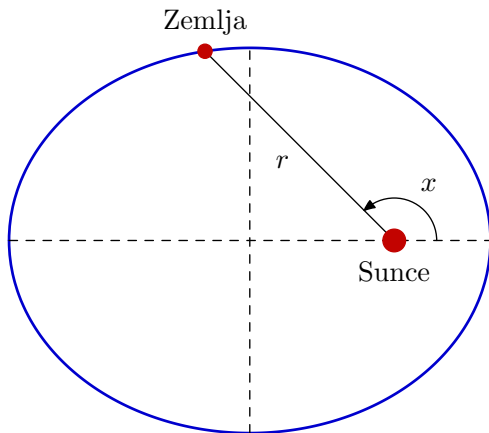
$x [^\circ]$	0	45	90	135	180
$r [10^6 \text{ km}]$	147	148	150	151	152

u kojima je

- ▶  $r$  **udaljenost** od Zemlje do Sunca (u  $10^6$  km),
- ▶ a  $x$  je **kut** između **spojnice** Zemlja–Sunce i **glavne osi** elipse (u **stupnjevima**). [radijani =  $\pi \cdot$  stupnjevi/180]!

# Zemlja na elipsi oko Sunca

Skica problema:



Podsjetnik: Ako **elipsa** ima veliku os  $a$  i malu os  $b$ , onda je  $e = \sqrt{a^2 - b^2}$  i  $\epsilon = e/a$ .

## Primjer (nastavak)

Dr. Zurić, naravno, zna da se **elipsa** može opisati jednačbom

$$r(x) = \frac{\rho}{1 + \varepsilon \cos x},$$

gdje je  $\varepsilon$  **numerički ekscentricitet** elipse, a  $\rho = b^2/a$  je tzv. **“srednja”** udaljenost elipse od fokusa.

Pomognite mu da nađe  $\rho$  i  $\varepsilon$ , **diskretnom linearnom** metodom najmanjih kvadrata, nakon **preuređenja** ove jednačbe.

**Rješenje.** Pomnožimo jednačbu s **nazivnikom** funkcije, pa dobivamo

$$r(1 + \varepsilon \cos x) = \rho,$$

odnosno,

$$-\varepsilon r \cos x + \rho = r.$$

## Primjer (nastavak)

Relaciju  $-\varepsilon r \cos x + \rho = r$  gledamo kao funkciju oblika

$$au + b = v,$$

gdje je

$$u = r \cos x, \quad v = r, \quad a = -\varepsilon, \quad b = \rho.$$

Zatim se primijeni **linearna** metoda najmanjih kvadrata za **pravac**, s nepoznatim koeficijentima  $a$  i  $b$ .

Prema tome, treba minimizirati

$$S = \sum_{i=0}^4 (v_i - au_i - b)^2 \rightarrow \min.$$

# Primjer (nastavak)

Deriviranjem izlazi

$$\frac{\partial S}{\partial a} = -2 \sum_{i=0}^4 (v_i - au_i - b)u_i = 0$$

$$\frac{\partial S}{\partial b} = -2 \sum_{i=0}^4 (v_i - au_i - b) = 0.$$

Nakon sređivanja, uz  $n + 1 = 5$ , dobivamo linearni sustav

$$\begin{bmatrix} \sum_{i=0}^4 u_i^2 & \sum_{i=0}^4 u_i \\ \sum_{i=0}^4 u_i & 5 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} \sum_{i=0}^4 u_i v_i \\ \sum_{i=0}^4 v_i \end{bmatrix}.$$

## Primjer (nastavak)

Kad se radi “na ruke”, traženi podaci se obično slože u **tablicu**

$i$	$v_j = r_j$	$u_j = r_j \cos x_j$	$u_j^2$	$u_j v_j$
0	147	147	21609	21609
1	148	104.6518036	10952	15488.46693
2	150	0	0	0
3	151	-106.7731240	11400.5	-16122.74172
4	152	-152	23104	-23104
$\Sigma$	748	-7.1213204	67065.5	-2129.27479

Brojevi na dnu tablice su **poznati** elementi linearnog sustava.

## Primjer (nastavak)

Linearni sustav za nepoznate koeficijente je

$$\begin{bmatrix} 67065.5 & -7.1213204 \\ -7.1213204 & 5 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} -2129.27479 \\ 748 \end{bmatrix}.$$

Rješenje tog sustava je

$$a = -1.58663722 \cdot 10^{-2}, \quad b = 149.5774021,$$

pa je

$$\varepsilon = 1.58663722 \cdot 10^{-2}, \quad \rho = 149.5774021.$$

Ove vrijednosti su **vrlo blizu** pravih, kad se sjetimo značenja:

- ▶  $\varepsilon$  je **ekscentricitet** Zemljine orbite,
- ▶  $\rho$  je “**srednja**” udaljenost od Zemlje do Sunca.



# Izbor aproksimacijske funkcije

Kad smo jednom odabrali oblik aproksimacijske funkcije pitamo se — jesmo li **dobro** izabrali njezin oblik?

Kad nađemo aproksimaciju, moramo pogledati **graf pogreške**.

- ▶ Ako on “**jednoliko**” oscilira oko **nule**, i
- ▶ te oscilacije izgledaju kao “**slučajne**”, a **ne** “sistematske”, onda je aproksimacijska funkcija **dobro** odabrana.

**Bitno**: Metoda **najmanjih kvadrata** smanjuje **slučajne greške** (recimo, kod mjerenja). To joj je osnovna svrha u **statistici**!

- ▶ Postoji tzv. **Gauss–Markovljev** teorem koji opravdava metodu najmanjih kvadrata.

# Primjer uklanjanja slučajne greške

**Primjer.** Eksperimentalni podaci uzeti su tako da se egzaktne  $y$ -koordinate točaka na pravcu

$$y(x) = 4x + 3$$

za  $x = 0, 1, \dots, 100$ , perturbiraju za

- ▶ **uniformno** distribuirani **slučajni** broj, između  $-1$  i  $1$ .

Tako se dobiju početni podaci  $(x_i, f_i)$ , gdje je  $x_i = i$ , a

$$f_i = 4x_i + 3 + (\text{slučajna perturbacija između } -1 \text{ i } 1),$$

za  $i = 0, \dots, 100$ .

# Primjer uklanjanja slučajne greške

Prvih nekoliko **podataka** izgleda ovako:

$x_i$	$y(x_i)$	$f_i$
0	3	3.481757957246973
1	7	7.905987449877890
2	11	11.931070097690015
3	15	15.495131876084549
4	19	18.681441353019998
5	23	22.984820207108194

Kad se metodom najmanjih kvadrata za **pravac**  $\varphi(x) = ax + b$  izračunaju **parametri**, dobijemo

$$a = 3.99598, \quad b = 3.20791.$$

# Primjer uklanjanja slučajne greške


Pogledajmo što su **aproksimacije**  $\varphi(x_i)$  za vrijednosti  $f_i$  u prvih nekoliko podataka:

$x_i$	$y(x_i)$	$\varphi(x_i)$
0	3	3.207905163100534
1	7	7.203881519200112
2	11	11.199857875299690
3	15	15.195834231399269
4	19	19.191810587498847
5	23	23.187786943598425

Uočite da su greške  $\varphi(x_i)$  obzirom na  $y(x_i)$  **znatno manje** nego **polazne** greške  $f_i$  obzirom na  $y(x_i)$ .

## Primjer uklanjanja slučajne greške

Pogledajmo kako se ponaša greška  $f_i - \varphi(x_i)$  u **svim** točkama.



Greška izgleda **skoro** kao **slučajna varijabla** koja oscilira oko nule, što znači da smo dobro odabrali aproksimaciju, i **smanjili** slučajnu grešku u podacima.

Krivac za “**skoro slučajni**” = ulazni podaci imaju **sistematsku** grešku na početku (uglavnom su  $> 0$ ) i zato je **b** prevelik!

# Demo primjeri

Diskretnom metodom najmanjih kvadrata aproksimiraju se

- ▶ **izmjereni** podaci za **viskoznost 40%** etilnog alkohola, u ovisnosti o temperaturi.

Primjer pokazuje **način izbora** aproksimacijske funkcije i

- ▶ **različita** rješenja, ako problem **lineariziramo**, ili ako ga **ne lineariziramo** (rješenja nelinearnih problema = **Nelder–Mead** metoda).

Cijeli demo je na sljedećim stranicama.

# Demo primjer — viskoznost “votke”

Promatramo kako **ovisi**

- ▶ **viskoznost 40%** etilnog alkohola o **temperaturi**.

Treba naći:

- ▶ “zgodan” **oblik** aproksimacijske funkcije i
- ▶ **parametre** za **dobru** aproksimaciju.

Za aproksimaciju koristimo **metodu najmanjih kvadrata**.

Ovaj primjer pokazuje:

- ▶ **način izbora** aproksimacijske funkcije,
- ▶ i **različita** rješenja — koja dobivamo kad problem **lineariziramo**, odnosno, kad ga **ne lineariziramo**.

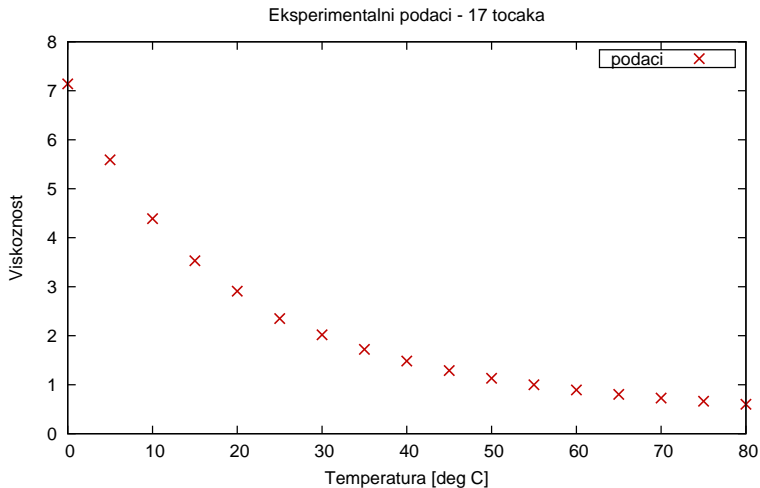
# Eksperimentalno izmjereni podaci — tablica

Eksperimentalno su **izmjereni** sljedeći podaci (17 točaka):

Temperatura	Viskoznost	Temperatura	Viskoznost
0	7.14	45	1.289
5	5.59	50	1.132
10	4.39	55	0.998
15	3.53	60	0.893
20	2.91	65	0.802
25	2.35	70	0.727
30	2.02	75	0.663
35	1.72	80	0.601
40	1.482		



# Eksperimentalno izmjereni podaci — slika



# Prva aproksimacija — oblik i parametri

Izmjereni podaci imaju

- ▶ “eksponencijalno” padajući oblik, a **ne** polinomni!

**Nelinearni** model:

$$f(x) = e^{ax+b}$$

ima parametre

$$a = -3.848637 \cdot 10^{-2}, \quad b = 1.911946.$$


**Linearizirani** model:

$$\ln f(x) = ax + b$$

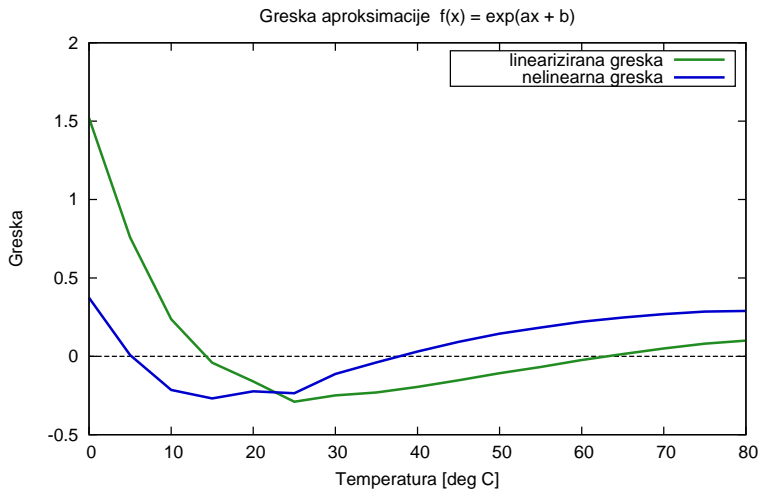
ima parametre

$$a = -3.022676 \cdot 10^{-2}, \quad b = 1.726233.$$

# Prva aproksimacija



# Greške prve aproksimacije



## Druga aproksimacija — oblik i parametri

Dobivene **greške nisu** “slučajne”, pa **nismo** baš pogodili **oblik**.

- ▶ Ponašanje upućuje na “**popravak**” **kvadratnim** članom.

**Nelinearni** model:

$$f(x) = e^{ax^2+bx+c}$$

ima parametre

$$a = 2.487568 \cdot 10^{-4}, \quad b = -4.977411 \cdot 10^{-2}, \quad c = 1.962208.$$


**Linearizirani** model:

$$\ln f(x) = ax^2 + bx + c$$

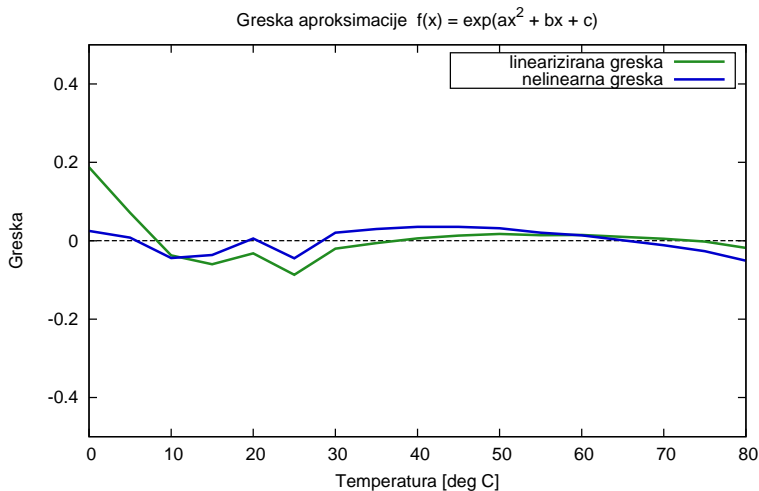
ima parametre

$$a = 2.128853 \cdot 10^{-4}, \quad b = -4.725758 \cdot 10^{-2}, \quad c = 1.939119.$$

# Druga aproksimacija



# Greške druge aproksimacije



## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

**Matrična formulacija linearnog problema najmanjih kvadrata**

QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje



# Matrična formulacija

Diskretni **linearni** problem najmanjih kvadrata najčešće se rešava u **matričnom** obliku.

Da bismo formirali **matrični zapis** linearnog problema najmanjih kvadrata, zgodno je **preimenovati** nepoznanice,

- ▶ tako da **matricu**,
- ▶ vektor **desne** strane i
- ▶ **nepoznanice** u linearnom sustavu

pišemo u uobičajenoj formi:

- ▶ **standardno** su nepoznanice  $x_1, \dots, x_m$ ,
- ▶ a ne  $a_0, \dots, a_m$ .

# Matrična formulacija — oznake

Pretpostavimo da skup podataka  $(t_k, y_k)$ , za  $k = 1, \dots, n$ , želimo aproksimirati **linearnom** funkcijom

$$\varphi(t) = x_1\varphi_1(t) + \dots + x_m\varphi_m(t).$$

Funkcija  $\varphi$  je neka **linearna** kombinacija izabranih **funkcija baze**  $\varphi_1, \dots, \varphi_m$ .

Želimo **pronaći** parametre  $x_j$  tako da zadani podaci  $(t_k, y_k)$  zadovoljavaju

$$y_k = \sum_{j=1}^m x_j\varphi_j(t_k), \quad k = 1, \dots, n.$$

Primijetite da to **nije** uvijek moguće, jer je podataka, uobičajeno, **znatno više** nego parametara ( $n \gg m$ ), pa je zapravo “=” → “ $\approx$ ”

# Matrična formulacija — preodređeni sustav

Uz oznake

$$a_{kj} = \varphi_j(t_k), \quad b_k = y_k,$$

prethodne jednačbe možemo napisati kao

$$y_k = \sum_{j=1}^m a_{kj} x_j = [ a_{k1} \quad a_{k2} \quad \cdots \quad a_{km} ] \cdot \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix}, \quad k=1, \dots, n,$$

što daje konačni **matrični oblik** jednačbi

$$Ax = b.$$

**Oprez:** ovdje je  $A$  matrica tipa  $n \times m$ , a ne  $m \times n$ , kao inače!  
Budući da je matrica  $A$  “**visoka i tanka**” ( $n \geq m$ ), imamo

- ▶ **preodređen** sustav linearnih jednačbi.

## Matrična formulacija — min norme reziduala

Taj sustav **ne mora** uvijek **imati** rješenje, tj. može se dogoditi, a gotovo uvijek se i događa u praksi, da je

$$r := b - Ax \neq 0, \quad \text{za svaki } x \in \mathbb{R}^m.$$

Postavlja se pitanje: Što je onda “**najbolje**” rješenje  $x$  ovog sustava  $Ax = b$ ? Prirodni odgovor:

- ▶ onaj vektor  $x \in \mathbb{R}^m$  za kojeg dobivamo “**najmanji**” rezidual  $r = r(x)$ .

Naravno, “**najmanji**” se mjeri u nekoj **normi** na prostoru  $\mathbb{R}^n$ .

Najčešće,  $x$  određujemo tako da se minimizira **Euklidska norma reziduala**  $r = b - Ax$ , tj. tražimo rješenje problema

$$\min_x \|r\|_2 = \min_x \|Ax - b\|_2, \quad A \in \mathbb{R}^{n \times m}, \quad b \in \mathbb{R}^n.$$

# Matrična formulacija — min norme reziduala

Problem “**najmanjih kvadrata**” svodi se na minimizaciju norme  $\|Ax - b\|_2$ . To vidimo iz sljedeće analize:

Minimizacija norme  $\|Ax - b\|_2$  ekvivalentna je minimizaciji **kvadrata** norme  $\|Ax - b\|_2^2$ , a on je dalje jednak

$$\begin{aligned}\|Ax - b\|_2^2 &= \sum_{i=1}^n (Ax - b)_i^2 = \sum_{i=1}^n \left( \sum_{j=1}^m a_{ij}x_j - b_i \right)^2 \\ &= \sum_{i=1}^n \left( \sum_{j=1}^m \varphi_j(t_i)x_j - y_i \right)^2 \\ &= \sum_{i=1}^n (\varphi(t_i) - y_i)^2 = S(x_1, \dots, x_n),\end{aligned}$$

funkciji **S** koja se minimizira u problemu **najmanjih kvadrata**.

# Komentar

Ako smo dobro izabrali bazne funkcije  $\varphi_j$ , onda je razumno pretpostaviti da su one linearno nezavisne na zadanim podacima, tj. stupci matrice  $A$  su linearno nezavisni, pa

- ▶ matrica  $A$  ima puni stupčani rang, tj.  $\text{rang}(A) = m$ .

Pokazat ćemo da, uz taj uvjet, problem najmanjih kvadrata uvijek ima jedinstveno rješenje.

S druge strane, ako je  $\text{rang}(A) < m$ , onda

- ▶ rješenje  $x$  sigurno nije jedinstveno,
- ▶ jer mu možemo dodati bilo koji vektor iz nul-potprostora od  $A$ , a da se rezidual ne promijeni.

Za početak, nećemo pretpostaviti nikakva specijalna svojstva matrice  $A$ , tj. tvrdnje u nastavku vrijede za bilo koji problem.

# Rješenje problema najmanjih kvadrata

**Teorem.** Skup svih rješenja problema  $\min_x \|r\|_2$  označimo s

$$\mathcal{S} = \{ x \in \mathbb{R}^m \mid \|Ax - b\|_2 = \min \}.$$

Tada je  $x \in \mathcal{S}$ , tj.  $x$  je rješenje problema najmanjih kvadrata, ako i samo ako vrijedi sljedeća relacija ortogonalnosti

$$A^T(b - Ax) = 0,$$

koju obično nazivamo sustav normalnih jednadžbi i pišemo u obliku

$$A^T Ax = A^T b.$$

# Rješenje problema najmanjih kvadrata

**Dokaz.** Pretpostavimo da je  $x \in \mathcal{S}$ , tj. da  $x$  **minimizira** normu reziduala. Treba pokazati da  $x$  **zadovoljava** sustav normalnih jednažbi.

Kao što smo vidjeli problem  $\min_x \|Ax - b\|_2$  **ekvivalentan** je minimizaciji funkcije

$$S(x) = \sum_{i=1}^n \left( \sum_{j=1}^m a_{ij}x_j - b_i \right)^2.$$

**Nužan uvjet** za postojanje ekstrema je

- ▶  $\nabla S(x) = 0$ , odnosno  $\frac{\partial S(x)}{\partial x_k} = 0$  za  $k = 1, \dots, m$ ,



# Rješenje problema najmanjih kvadrata

Zbog toga računamo:

$$\begin{aligned}\frac{\partial S(x)}{\partial x_k} &= \sum_{i=1}^n 2 \left( \sum_{j=1}^m a_{ij} x_j - b_i \right) a_{ik} \\ &= 2 \sum_{i=1}^n a_{ik} (Ax - b)_i = 2 \sum_{i=1}^n (A^T)_{ki} (Ax - b)_i \\ &= 2(A^T(Ax - b))_k = 0.\end{aligned}$$

Prema tome je

$$\nabla S(x) = 0 \quad \iff \quad A^T(Ax - b) = 0.$$

**Obrat.** Pretpostavimo da  $x$  zadovoljava **normalne** jednačbe, i tada imamo stacionarnu točku funkcije  $S(x)$ . Moramo još provjeriti **Hesseovu** matricu  $H(x) = \left[ \frac{\partial^2 S(x)}{\partial x_k \partial x_\ell} \right]$

# Rješenje problema najmanjih kvadrata

Za drugu derivaciju vrijedi

$$\frac{\partial^2 S(x)}{\partial x_k \partial x_\ell} = 2 \sum_{i=1}^n a_{ik} a_{i\ell} = 2 \sum_{i=1}^n (A^T)_{ki} a_{i\ell} = 2(A^T A)_{k\ell}.$$

Dakle, možemo **zaključiti** da je

$$H(x) = 2A^T A.$$

Matrica  $A^T A$  **simetrična** i **pozitivno semidefinitna**, jer za svaki vektor  $y \in \mathbb{R}^m$  vrijedi

$$y^T A^T A y = (y^T A^T)(A y) = (A y)^T (A y) = \|A y\|_2^2 \geq 0.$$

To znači da je i  $H(x)$  **pozitivno semidefinitna** matrica.

- ▶ Za slučajeve kada je  $H(x)$  **pozitivno definitna** ( $A$  punog stupčanog ranga) dokazali smo teorem, pri čemu
  - ▶ **normalne** jednadžbe imaju jedinstveno rješenje  $x$  (matrica sustava je **regularna**)
  - ▶  $S(x)$  zaista poprima strogi globalni **minimum**.

## Rješenje problema najmanjih kvadrata

- ▶ Za slučajeve kada je  $H(x)$  nije regularna, neka je  $r = b - Ax$  rezidual od  $x$  i vrijedi  $A^T r = 0$ . Za bilo koji vektor  $\hat{x} \in \mathbb{R}^m$ , njegov rezidual  $\hat{r}$  ima oblik

$$\hat{r} = b - A\hat{x} = (r + Ax) - A\hat{x} = r - A(\hat{x} - x).$$

Ako označimo  $e = \hat{x} - x$ , onda je  $\hat{r} = r - Ae$ , pa imamo

$$\begin{aligned}\|\hat{r}\|_2^2 &= \hat{r}^T \hat{r} = (r - Ae)^T (r - Ae) \\ &= r^T r - r^T Ae - (Ae)^T r + (Ae)^T Ae \\ &= \|r\|_2^2 - (A^T r)^T e - e^T (A^T r) + \|Ae\|_2^2 = \{A^T r = 0\} \\ &= \|r\|_2^2 + \|Ae\|_2^2 = \|r\|_2^2 + \|A(\hat{x} - x)\|_2^2.\end{aligned}$$

Zbog  $\|Ae\|_2^2 \geq 0$ , odavde odmah slijedi da je

$$\|\hat{r}\| \geq \|r\|, \quad \text{za svaki } \hat{x} \in \mathbb{R}^m,$$

pa  $x$  **minimizira** normu reziduala, tj. vrijedi  $x \in \mathcal{S}$ .

# Struktura skupa svih rješenja

**Napomena.** Trenutno, još uvijek **ne znamo** je li  $\mathcal{S} \neq \emptyset$ .

Iz zadnje relacije

$$\|\hat{r}\|_2^2 = \|r\|_2^2 + \|Ae\|_2^2 = \|r\|_2^2 + \|A(\hat{x} - x)\|_2^2$$

odmah dobivamo i preciznu **strukturu** skupa  $\mathcal{S}$  **svih** rješenja problema **najmanjih kvadrata**.

**Korolar.** Neka je  $x \in \mathcal{S}$ . Onda je  $\hat{x} \in \mathcal{S}$  **ako i samo ako** je  $\hat{x} - x \in \mathcal{N}(A)$ , tj. skup  $\mathcal{S}$  je **linearna mnogostrukost** u  $\mathbb{R}^m$

$$\mathcal{S} = x + \mathcal{N}(A).$$

**Dokaz.** Očito je  $\hat{x} \in \mathcal{S}$ , ako i samo ako vrijedi  $\|\hat{r}\|_2 = \|r\|_2$ . No, iz prethodne relacije vidimo da je to **ekvivalentno** s  $Ae = A(\hat{x} - x) = 0$ , odnosno,  $\hat{x} - x \in \mathcal{N}(A)$ . ■

Usput (kao dodatak dokazu teorema), onda iz  $\hat{r} = r - Ae$  slijedi  $\hat{r} = r$ , pa i  $\hat{r}$  zadovoljava normalne jednadžbe.

# Egzistencija rješenja — uvijek postoji!

Prethodni teorem, zapravo, kaže da je skup  $\mathcal{S}$  rješenja problema minimizacije  $\|r\|_2$  jednak skupu rješenja sustava normalnih jednažbi

$$A^T A x = A^T b.$$

Odavde odmah slijedi egzistencija rješenja, tj.  $\mathcal{S} \neq \emptyset$ , jer znamo da vrijedi sljedeće:

- ▶ Matrica  $A^T A$  je simetrična i pozitivno semidefinitna.
- ▶ Sustav normalnih jednažbi uvijek ima rješenje, jer je

$$A^T b \in \mathcal{R}(A^T) = \mathcal{R}(A^T A)$$

(v. teorem Kronecker–Capelli). Da  $\mathcal{R}(A^T) = \mathcal{R}(A^T A)$  vrijedi, provjerite sljedeće

- ▶  $\mathcal{R}(A) \subseteq \mathbb{R}^n$ , i kad primijenimo  $A^T$  imamo  $\mathcal{R}(A^T A) \subseteq \mathcal{R}(A^T)$ .
- ▶ Neka je  $z \in \mathcal{R}(A^T)$ , tada je  $z = A^T y$ . Kako je  $\mathbb{R}^n = \mathcal{R}(A) \oplus \mathcal{N}(A^T)$  tada  $y$  možemo raspisati kao  $y = Ax + w$ , gdje je  $w \in \mathcal{N}(A^T)$ . Tada je  $z = A^T Ax + A^T w = A^T Ax \in \mathcal{R}(A^T A)$ , odnosno  $\mathcal{R}(A^T) \subseteq \mathcal{R}(A^T A)$ .

# Jedinstvenost rješenja

Dobivamo čak i jače — zaključak o **jedinstvenosti** rješenja.

**Teorem.** Problem **najmanjih kvadrata** ima **jedinstveno** rješenje, ako i samo ako vrijedi bilo koja od sljedećih tvrdnji:

- ▶  $A$  ima **puni stupčani rang**, tj. vrijedi  $\text{rang}(A) = m$ ,
- ▶ **stupci** matrice  $A$  su **linearno nezavisni**,
- ▶  $A^T A$  je **pozitivno definitna** matrica.

**Dokaz.** Iz korolara o **strukturi** skupa  $\mathcal{S}$  svih rješenja problema najmanjih kvadrata, vidimo da je

- ▶ skup  $\mathcal{S}$  **jednočlan**, ako i samo ako
- ▶ matrica  $A$  ima **trivijalan** nul-potprostor  $\mathcal{N}(A)$ , tj. vrijedi  $\dim \mathcal{N}(A) = 0$ , odnosno,  $x \neq 0 \implies Ax \neq 0$ .

# Jedinstvenost rješenja

Trivijalnost  $\mathcal{N}(A)$  ekvivalentna je sljedećim zaključcima.

1. tvrdnja — koristimo  $\dim \mathcal{N}(A) = 0$ .

- ▶ Iz teorema o **rangu i defektu** za matricu  $A$ , tipa  $n \times m$ , to je ekvivalentno s  $\text{rang}(A) = m$ . Usput, **onda je**  $n \geq m$ .

2. i 3. tvrdnja — koristimo  $x \neq 0 \implies Ax \neq 0$ .

- ▶ Po **definiciji**, stupci  $\{a_1, a_2, \dots, a_m\}$  matrice  $A$  su **linearno nezavisni**, ako i samo ako za svaki skup skalara  $x_1, x_2, \dots, x_m$  kod kojih je bar jedan  $x_k \neq 0$  vrijedi  $\sum_{j=1}^m x_j a_j \neq 0$ . To je ekvivalentno tvrdnji da za svaki vektor  $x = [x_1 \ x_2 \ \dots \ x_m]^T \neq 0$  vrijedi  $Ax \neq 0$ .
- ▶ Znamo da je  $A^T A$  simetrična i pozitivno **semidefinitna**. Onda je gornja implikacija ekvivalentna pozitivnoj **definitnosti** matrice  $A^T A$ , jer za  $x \neq 0$  vrijedi

$$x^T A^T A x = \|Ax\|_2^2 > 0.$$

# Karakterizacija jedinstvenog rješenja

Zadnja tvrdnja — preko pozitivne definitnosti matrice  $A^T A$ , odgovara činjenici da sustav **normalnih** jednažbi

$$A^T A x = A^T b$$

**ima jedinstveno** rješenje, ako i samo ako je  $A^T A$  **regularna** matrica (pozitivno definitna matrica je regularna).

U tom slučaju, **jedinstveno** rješenje problema **najmanjih kvadrata** je

$$x = (A^T A)^{-1} A^T b,$$

a pripadni **rezidual najmanje 2**-norme je

$$r = b - A(A^T A)^{-1} A^T b.$$



# Geometrijska interpretacija općeg rješenja

Desna strana  $b$  može se napisati preko **reziduala** kao

$$b = Ax + r,$$

pri čemu je, očito,  $Ax \in \mathcal{R}(A)$ . Nadalje, iz sustava normalnih jednadžbi odmah vidimo da je

$$A^T(b - Ax) = A^T r = 0,$$

što znači da je za svaki  $Av \in \mathcal{R}(A)$


$$(Av)^T r = (v^T A^T) r = v^T (A^T r) = v^T 0 = 0$$

tj.  $r \perp \mathcal{R}(A)$ , pa vektor  $r$  mora biti **okomit** i na  $Ax$ . To daje **geometrijsku** interpretaciju rješenja problema **najmanjih kvadrata**.

# Geometrijska interpretacija općeg rješenja

Rješenje problema najmanjih kvadrata dobivamo

- ▶ ortogonalnom projekcijom vektora  $b$  na potprostor  $\mathcal{R}(A)$ .



# Struktura skupa rješenja i linearni sustav

Označimo s  $\mathcal{P}(b)$  ortogonalnu projekciju vektora  $b$  na  $\mathcal{R}(A)$ .

- ▶ Taj vektor  $\mathcal{P}(b)$  je sigurno **jedinstven** (kao projekcija).

Prema slici, za rješenje  $x$  mora vrijediti  $Ax = \mathcal{P}(b)$ . Preciznije,

- ▶ **sva** rješenja  $x \in \mathcal{S}$  problema **najmanjih kvadrata** su,
- ▶ upravo, **sva** rješenja **linearnog sustava**  $Ax = \mathcal{P}(b)$ .

Zato skup  $\mathcal{S}$  ima **istu** strukturu — **linearna mnogostrukost**, kao i **opće** rješenje linearnog sustava s matricom  $A$ , s tim da

- ▶ ovdje znamo da je  $\mathcal{S}$  **neprazan**, tj. **postoji**  $x_0 \in \mathcal{S}$ .

Analogno, **jedinstvenost** rješenja  $x$  svodi se na

- ▶ **jedinstvenost** rješenja linearnog sustava s matricom  $A$ , tj. **trivijalnost** nul-potprostora  $\mathcal{N}(A)$ .

# Numeričke metode i jedinstvenost rješenja

Numeričke metode za računanje rješenja problema najmanjih kvadrata imaju smisla samo kad je

- ▶ objekt kojeg računamo jedinstven.

Znamo da linearni problem najmanjih kvadrata uvijek ima rješenje. Osim toga, rješenje je jedinstveno, ako i samo ako

- ▶ matrica  $A$  ima puni stupčani rang.

U nastavku, tražimo efikasne i točne numeričke metode za računanje rješenja. Promatramo samo one probleme

- ▶ u kojima imamo garantiranu jedinstvenost rješenja.

Prije toga — završni komentar o jedinstvenosti.

# Osiguranje jedinstvenosti u općem problemu

Ako matrica  $A$  nema puni rang po stupcima, tj. ako je  $\text{rang}(A) < m$ , onda

- ▶ rješenje problema najmanjih kvadrata nije jedinstveno.

U tom slučaju, jedinstvenost rješenja se dobiva dodatnim uvjetom — pored  $\|Ax - b\|_2 \rightarrow \min$ , još tražimo

- ▶ rješenje  $x \in \mathcal{S}$  koje ima najmanju 2-normu, tj. dodatni uvjet je  $\|x\|_2 \rightarrow \min$ .

Geometrijska interpretacija:

- ▶ Na  $\|x\|_2 \rightarrow \min$  možemo gledati kao na vektor oblika  $x_0 + \sum_{i=1}^d y_i n_i$  kojem minimiziramo normu, pri čemu vektori  $n_i, i = 1, \dots, d$  čine bazu od  $\mathcal{N}(A)$  (znamo da je jezgra matrice vektorski prostor), a  $x_0 \in \mathcal{S}$ .
- ▶ To znači da rješavamo problem  $\|x_0 + Ny\|_2 \rightarrow \min$ , pri čemu je  $N = [n_1 \ \dots \ n_d]$ . Na analogan način kao i kod linearnog problema najmanjih kvadrata zaključujemo da rješenje problema  $x = x_0 + Ny$ , koje je oblika kao rezidual najmanjih kvadrata, mora bit okomito na  $\mathcal{R}(N) = \mathcal{N}(A)$ , tj.  $x \perp \mathcal{N}(A)$ .

# Osiguranje jedinstvenosti u općem problemu

Alternativno, skup rješenja u ovom slučaju čini skup

$$\mathcal{S} = x + \mathcal{N}(A),$$

za bilo koje rješenje  $x$  polaznog problema najmanjih kvadrata.

- ▶ Ako je  $x \perp \mathcal{N}(A)$ , onda je

$$\|x + z\|_2^2 = \|x\|_2^2 + \|z\|_2^2, \quad z \in \mathcal{N}(A),$$

pa je  $x$  jedinstveno rješenje problema najmanjih kvadrata koje ima **minimalnu 2-normu**.

Ovaj pristup ima smisla u primjenama, na pr., u **statistici**.

## Jedinstveno rješenje — ponavljanje

Odsad nadalje, pretpostavljamo (ako drugačije nije rečeno) da matrica  $A$  ima **puni stupčani rang**. Posebno, to znači da

- ▶  $A$  ima **više** redaka nego stupaca,  $n \geq m$ , i
- ▶ **stupci** od  $A$  su **linearno nezavisni**,  $\text{rang}(A) = m$ .

Matrica  $A^T A$  je **pozitivno definitna**, a iz sustava **normalnih** jednadžbi

$$A^T A x = A^T b$$

dobivamo **jedinstveno** rješenje problema **najmanjih kvadrata**

$$x = (A^T A)^{-1} A^T b.$$

Pripadni **rezidual najmanje 2**-norme je

$$r = b - A(A^T A)^{-1} A^T b.$$

# Računanje rješenja problema najmanjih kvadrata

Treba još pronaći način kako **jednostavno** izračunati rješenje. Jasno je da se matrica  $A^T A$  **ne invertira**, nego se **rješava** linearni sustav

$$A^T A x = A^T b.$$

Ovaj **pozitivno definitni** sustav normalnih jednažbi možemo riješiti tako da iskoristimo **faktorizaciju Choleskog** za  $A^T A$ .

**Prednosti/nedostaci** ove metode = “množenje + Cholesky”:

- ▶ ukupan broj aritmetičkih operacija za rješenje je  $nm^2 + \frac{1}{3}m^3 + O(m^2)$ , što je **brzo**,
- ▶ ali, rješavanje na ovaj način **nije** naročito **točno**.

Može se koristiti za **mali** broj parametara  $m$ , ako **ne tražimo jako točno** rješenje (često u praksi — za “**mala**” mjerenja).



# Korištenje QR faktorizacije

Opet, neka  $A$  ima **puni stupčani rang**. Promatramo problem minimizacije

$$\|Ax - b\|_2 \rightarrow \min.$$

Prisjetite se, za **proizvoljnu ortogonalnu** matricu  $Q^T$  vrijedi da **čuva** skalarni produkt — onda i kvadrat norme, pa i normu.

Dakle, rješenje problema minimizacije možemo zapisati kao

$$\|Ax - b\|_2 = \|Q^T(Ax - b)\|_2 = \|Q^T Ax - Q^T b\|_2 \rightarrow \min.$$

**Pitanje.** Kako naći **pogodan**  $Q^T$ , tako da, iz problema ili “sustava” s matricom  $Q^T A$ , **lako** izračunamo rješenje  $x$ ?

**Odgovor.** Korištenjem **QR faktorizacije** — tako da  $Q^T A$  bude **gornja trokutasta** matrica  $R$ , tj. faktorizacijom  $A = QR$ !

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

### QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

# Definicija QR faktorizacije

**Napomena.** U ovom dijelu mijenjamo oznake  $m \leftrightarrow n$ , na uobičajene za matrice:  $m$  = broj redaka, a  $n$  = broj stupaca.

Neka je zadana matrica  $G$  tipa  $(m, n)$  koja ima puni stupčani rang, tj.  $\text{rang}(G) = n \leq m$ . Rastav matrice  $G$  tako da je

$$G = QR = Q \begin{bmatrix} R_0 \\ 0 \end{bmatrix},$$

gdje je

- ▶  $Q$  ortogonalna matrica reda  $m$ , a
- ▶  $R_0$  gornja trokutasta matrica reda  $n$ , s pozitivnim dijagonalnim elementima,

zove se QR faktorizacija matrice  $G$ .

# Definicija QR faktorizacije

Ako postoji, prethodna faktorizacija može se napisati i u **jednostavnijoj** — tzv. **skraćenoj** formi.

- ▶ Prvih  $n$  stupaca matrice  $Q$  označimo s  $Q_0$ , tako da matrica  $Q_0$  ima **isti** tip kao i  $G$ ,
- ▶ a **preostale** stupce, koji su **okomiti** na  $Q_0$ , označimo s  $Q_0^\perp$ .

Onda je

$$G = QR = [ Q_0 \quad Q_0^\perp ] \begin{bmatrix} R_0 \\ 0 \end{bmatrix} = Q_0 R_0, \quad Q_0^T Q_0 = I_n.$$

Ostaje samo pokazati da takva faktorizacija **postoji**.

**Napomena.** Ako je  $m > n$ , onda  $Q_0^\perp$  možemo izabrati na više načina  $\implies$  “**puna**” QR faktorizacija sigurno **nije jedinstvena**.

# Egzistencija i jedinstvenost QR faktorizacije

**Teorem.** Neka je  $G \in \mathbb{R}^{m \times n}$ , za  $m \geq n$ , i neka je  $\text{rang}(G) = n$ . Tada postoji jedinstvena “skraćena” QR faktorizacija, oblika

$$G = Q_0 R_0,$$

gdje je  $Q_0$  matrica tipa  $m \times n$ , s ortonormiranim stupcima, tj. vrijedi

$$Q_0^T Q_0 = I_n,$$

a  $R_0$  je gornja trokutasta matrica s pozitivnim dijagonalnim elementima (dovoljno je fiksirati predznake na dijagonali u  $R$ ).

Pravokutnu matricu  $Q_0$  s ortonormiranim stupcima, također, skraćeno zovemo “ortogonalnom”.

# Egzistencija i jedinstvenost QR faktorizacije

**Dokaz.** Najjednostavniji dokaz ide tako da **stupce** matrice

$$G = [g_1 \ g_2 \ \dots \ g_n]$$

**ortonormiramo** korištenjem **Gram-Schmidtovog** postupka.

**1. korak:** Zbog  $g_1 \neq 0$ , definiramo

$$q'_1 = g_1, \quad q_1 = \frac{q'_1}{\|q'_1\|_2}.$$

**$j$ -ti korak:** Već imamo **ortonormirane** vektore  $q_1, \dots, q_{j-1}$ , koji razapinju **isti** potprostor kao i stupci  $g_1, \dots, g_{j-1}$  matrice  $G$ .

Onda definiramo novi vektor  $q'_j$  i normiramo ga

$$q'_j = g_j - \sum_{i=1}^{j-1} \langle g_j, q_i \rangle q_i, \quad q_j = \frac{q'_j}{\|q'_j\|_2}.$$

# Egzistencija i jedinstvenost QR faktorizacije

Stupci matrice  $G$  su linearno **nezavisni**, što osigurava  $q'_j \neq 0$ .  
Stavljanjem

$$Q_0 = [q_1 \ q_2 \ \dots \ q_n]$$

dobivamo  $m \times n$  **ortogonalnu** matricu (ortonormirani stupci).

Uz oznaku za skalarne produkte i norme iz prethodne formule

$$r_{ij} = \langle g_j, q_i \rangle = q_i^T g_j, \quad r_{jj} = \|q'_j\|_2,$$

koeficijenti  $r_{ij}$  su, upravo, elementi tražene matrice  $R_0$ . **Polazni** stupac  $g_j$  možemo napisati kao **linearnu kombinaciju** prvih  $j$  vektora  $q_i$  **ortonormirane** baze, u obliku

$$G(:, j) = g_j = \sum_{i=1}^j r_{ij} q_i = [q_1 \ q_2 \ \dots \ q_n] \begin{bmatrix} r_{1j} \\ \vdots \\ r_{jj} \\ 0 \\ \vdots \\ 0 \end{bmatrix} = Q_0 \cdot R_0(:, j).$$

tj.  $G = Q_0 R_0$ .

# Gram–Schmidtov postupak ortogonalizacije

U praksi se **nikad** ne koristi **klasični Gram–Schmidtov** postupak ortogonalizacije (skraćeno **CGS**),

- ▶ koji ortogonalizira **originalne** vektore  $g_j$ .
- ▶ Zbog toga jer je **nestabilan** kad su stupci od  $G$  skoro **linearno zavisni**, tj. kad je  $G$  **loše** uvjetovana.

Umjesto CGS-a, može se koristiti tzv. **modificirani Gram–Schmidtov** postupak (skraćeno **MGS**),

- ▶ koji ortogonalizira **modificirane** vektore  $g_j$ , koji su već sami ortogonalni na prethodne vektore  $q_i$ , pa je mnogo stabilniji.
- ▶ No, i kod njega se može dogoditi da je izračunati  $Q_0$  vrlo **daleko** od ortogonalnog, tj.  $\|Q_0^T Q_0 - I_n\| \gg u$ , kad je  $G$  **vrlo loše** uvjetovana.



# Gram–Schmidtov algoritam

Klasični i modificirani Gram–Schmidtov algoritam:

```
za j = 1 do n radi {  
  /* Nađi j-ti stupac od Q_0 i R_0 */  
  q'_j = g_j;  
  za i = 1 do j - 1 radi {  
    /* Oduzmi komponentu od g_j u smjeru q_i */  
  
    /* kod CGS-a je */  
    r_ij = q_iT * g_j;  
  
    /* kod MGS-a je */  
    r_ij = q_iT * q'_j;  
  
    q'_j = q'_j - r_ij * q_i;  
  };
```

## Gram–Schmidtov algoritam (nastavak)

```
r_jj = ||q'_j||2;  
ako je r_jj > 0 onda {  
    q_j = q'_j / r_jj;  
}  
inače {  
    /* Matrica R_0 je singularna - stani */  
};  
};
```

**Napomena:**  $r_{jj} = 0$  je ekvivalentno s tim da je

- ▶  $g_j$  linearna kombinacija **prethodnih** stupaca matrice  $G$  (linearna zavisnost stupaca, pad ranga).

Pokažite da su **dvije** formule za  $r_{jj}$ , ona iz **CGS** i ona iz **MGS**, matematički **ekvivalentne**. **Numerički**, naravno, **nisu** (greške).

# Gram–Schmidtov algoritam — komentari

Gram–Schmidtov algoritam daje **skraćenu QR** faktorizaciju  $G = Q_0 R_0$ . Ako je  $m > n$  (matrica  $Q_0$  nije kvadratna), onda nam za “**punu**” faktorizaciju, tj. za **kvadratni**  $Q$ ,

- ▶ fali **ortogonalni komplement**  $Q_0^\perp$ ,

kojeg **nemamo** iz čega izračunati — “fale” stupci u  $G$ .

Čim je  $\|q'_j\|_2 \neq 0$ , za dijagonalni element  $r_{jj}$  možemo uzeti bilo koji od **dva** predznaka

$$r_{jj} = \pm \|q'_j\|_2.$$

Dakle, bilo kojim **fiksiranjem predznaka** na dijagonali od  $R_0$ ,

- ▶ opet dobivamo **jedinstvenu** skraćenu **QR** faktorizaciju.

## Drugi algoritmi

U praksi, kad želimo **ortogonalni  $Q$** , koristimo

- ▶ ili **Givensove rotacije**,
- ▶ ili **Householderove reflektore**,

kojima **poništavamo** odgovarajuće elemente u matrici  **$G$** . To ponovno daje konstrukciju **QR** faktorizacije i dokaz teorema.

Bitna razlika među ta dva algoritma:

- ▶ **Givensove rotacije** poništavaju po **jedan** element u stupcu,
- ▶ **Householderovi reflektori** poništavaju **sve osim jednog** elementa u (**skraćenom**) stupcu.

Oba algoritma mogu dati **punu** i **skraćenu QR** faktorizaciju.

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

### QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

# Givensove rotacije


Matrica oblika

$$R(\varphi) = \begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix}$$

zove se **Givensova rotacija** u ravnini.

Ova transformacija **rotira** svaki vektor  $x \in \mathbb{R}^2$  za kut  $\varphi$ , u smjeru **obrnutom** od kazaljke na satu = u **pozitivnom** smjeru.

Slika za  $x' = R(\varphi)x$  je





# Poništavanje korištenjem Givensovih rotacija

Matrica  $R(i, j, \varphi)$  je **ortogonalna**. Za zadani vektor  $x \in \mathbb{R}^m$ ,

- ▶ **poništavamo** njegovu  $j$ -tu komponentu  $x_j$ , korištenjem rotacije  $R(i, j, \varphi)$ .

**Množenjem** matrice  $R(i, j, \varphi)$  **slijeva** na  $x$  mijenjamo

- ▶ **samo**  $i$ -tu i  $j$ -tu komponentu u  $x$ ,
- ▶ pa poništavanje možemo gledati samo u  $(i, j)$  ravnini.

Dobiveni sustav jednažbi je

$$\begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix} \begin{bmatrix} x_i \\ x_j \end{bmatrix} = \begin{bmatrix} x'_i \\ 0 \end{bmatrix}.$$

**Traže** se elementi matrice **rotacije**  $R(i, j, \varphi)$  i **novi** element  $x'_i$ .

Za  $x_i = x_j = 0$ , **mora** biti  $x'_i = 0$  i **možemo** uzeti  $R(i, j, \varphi) = I$ .



# Poništavanje korištenjem Givensovih rotacija

U nastavku uzimamo da je  $x_i^2 + x_j^2 > 0$ , tj. bar jedan **nije** nula.

**Drugi** redak u **matričnoj** **jednadžbi** opisuje **ponišavanje**

$$\sin \varphi \cdot x_i + \cos \varphi \cdot x_j = 0.$$

Ako je  $x_j = 0$  (tj. **nemamo** što poništavati), onda je  $\sin \varphi = 0$ .

U **suprotnom**, izlazi

$$\operatorname{ctg} \varphi = -\frac{x_i}{x_j}.$$

Odavde, korištenjem **trigonometrijskog** **identiteta**

$$1 + \operatorname{ctg}^2 \varphi = \frac{1}{\sin^2 \varphi},$$

slijedi

$$\sin^2 \varphi = \frac{x_j^2}{x_i^2 + x_j^2}, \quad \cos^2 \varphi = 1 - \sin^2 \varphi = \frac{x_i^2}{x_i^2 + x_j^2}.$$

# Poništavanje korištenjem Givensovih rotacija

**Predznake** za  $\sin \varphi$  i  $\cos \varphi$  biramo tako da  $x'_i$  bude **pozitivan**.  
Ako stavimo

$$\sin \varphi = -\frac{x_j}{\sqrt{x_i^2 + x_j^2}}, \quad \cos \varphi = \frac{x_i}{\sqrt{x_i^2 + x_j^2}},$$

iz **prve** jednažbe dobivamo

$$\begin{aligned} x'_i &= \frac{x_i}{\sqrt{x_i^2 + x_j^2}} x_i + \frac{x_j}{\sqrt{x_i^2 + x_j^2}} x_j = \frac{x_i^2 + x_j^2}{\sqrt{x_i^2 + x_j^2}} \\ &= \sqrt{x_i^2 + x_j^2} > 0. \end{aligned}$$

Element  $x'_i$  je **norma**  $i$ -te i  $j$ -te komponente polaznog vektora.  
Ove formule vrijede i kad je  $x_j = 0$  (tada je  $\varphi = 0$  ili  $\varphi = \pi$ ).

# Sustavno poništavanje

Sustavnim **poništvanjem** elemenata, konstruirat ćemo **QR** faktorizaciju matrice **G**.

- ▶ Postoji **puno** redosljeda kako **napraviti** nule u matrici **G**.
- ▶ U sljedećem primjeru uzet je “**standardni**” redosljed: **redom**, **po stupcima** ( $\rightarrow$ ), **odozgo nadolje** ( $\downarrow$ ) u stupcu.

## Poništavanje.

- ▶ Počinjemo s **prvim** stupcem i poništavamo redom elemente  $g_{21}, \dots, g_{m1}$ .
- ▶ Ponovimo to isto za **drugi**, **treći** i svaki daljnji stupac, od **dijagonalnog mjesta** nadolje.
- ▶ Time nećemo “**pokvariti**” već sredene **nule** u prethodnim stupcima.

# Sustavno poništavanje — primjer

**Primjer.** Za jednu matricu  $G$ , tipa  $4 \times 3$ , to izgleda ovako.

## 1. stupac:

- ▶ U radnoj matrici  $G$ , redom **poništvamo** elemente

$$g_{i1}, \quad i = 2, \dots, m \quad (m = 4),$$

**rotacijama**  $R(1, i, \varphi_{1i})$ , koje “**nabacuju**” normu **prvog** stupca na **prvi** element u stupcu (to je baš dijagonalni).

$$\begin{bmatrix} x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \end{bmatrix}$$

# Sustavno poništavanje — primjer (nastavak)

## 2. stupac:

- ▶ U radnoj matrici  $G$ , redom **poništvamo** elemente

$$g_{i2}, \quad i = 3, \dots, m \quad (m = 4),$$

**rotacijama**  $R(2, i, \varphi_{2i})$ , koje “**nabacuju**” normu **drugog** stupca (od dijagonale nadalje) na **drugi** element u stupcu.

- ▶ To neće “**pokvariti**” već sredene **nule** u **prvom** stupcu.
- ▶ **Prvi** redak (i stupac) se više **ne mijenja**.

$$\begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & x \end{bmatrix}$$

# Sustavno poništavanje — primjer (kraj)

## 3. stupac:

- ▶ U radnoj matrici  $G$ , redom **poništavamo** elemente

$$g_{i3}, \quad i = 4, \dots, m \quad (m = 4),$$

**rotacijama**  $R(3, i, \varphi_{3i})$ , koje “**nabacuju**” normu **trećeg** stupca (od dijagonale nadolje) na **treći** element u stupcu.

- ▶ To neće “**pokvariti**” već sredene **nule** u prva **dva** stupca.
- ▶ Prva **dva** retka (i stupca) se više **ne mijenjaju**.

$$\begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & 0 \end{bmatrix}$$

# Poredak poništavanja i ocjena greške

## Drugi rasporedi poništavanja.

- ▶ Za **ocjenu greške** zaokruživanja postoji i **bolji** raspored poništavanja elemenata.
- ▶ Gore opisanim algoritmom, pri sređivanju **prvog** stupca, **prvi redak** se mijenja  $m - 1$  puta, a svi ostali samo **jednom**.
- ▶ **Poboljšanje** dobivamo “**ujednačavanjem**”, tako da se svaki redak transformira **podjednak** broj puta.
- ▶ To se postiže korištenjem niza **nezavisnih** rotacija, koje **ne** zahvaćaju **iste** retke.
- ▶ Takav raspored primjene rotacija, usput, još dozvoljava i **paralelizaciju** algoritma.

# Nezavisne rotacije — paralelno poništavanje

Grafički, za jednu matricu tipa  $4 \times 3$  to izgleda ovako.

Crveno i zeleno su nezavisne rotacije koje možemo istovremeno primjenjivati (samo su dvije, jer je  $m$  premalen).

$$\begin{array}{c} \begin{bmatrix} x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ x & x & x \\ 0 & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & 0 & x \end{bmatrix} \\ \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & 0 \end{bmatrix} \end{array}$$

Parovi su: (1, 2) i (3, 4), (1, 3) i (2, 4). Na samom kraju, u zadnja dva retka, više “ne ide” paralelno. Plave 0 su konačne.



# Kako doći do $Q$ ?

Na kraju algoritma, na mjestu matrice  $G$  piše matrica  $R$ .

Do matrice  $Q$  dolazi se **nakupljanjem** primijenjenih rotacija, na pr.

$$R(n, m, \varphi_{nm}) \cdots R(1, 2, \varphi_{12}) G := Q^{-1} G = R.$$

Matricu  $G$  smo **slijeva** pomnožili

- ▶ produktom **ortogonalnih** matrica, kojeg označimo s  $Q^{-1}$ .
- ▶ Produkt ortogonalnih matrica je opet **ortogonalna**, pa i regularna. Isto vrijedi i za njezin inverz  $(Q^{-1})^{-1} = Q$ .
- ▶ Zaključak:  $G = QR$ , gdje je  $Q$  **ortogonalna**.
- ▶ Ako znamo  $Q^{-1} = Q^T$ , onda se  $Q$  **lako** računa iz  $Q^T$ .

Matrica  $Q^{-1} = Q^T$  dobiva se primjenom **istih** rotacija, samo na **početnu** matricu  $I_m$ , reda  $m$  — “što na  $G$ , to na  $I_m$ ”.

## Alternativa za $Q$ , puni i skraćeni $Q$

**Kvadratnu** matricu  $Q$ , u **punoj QR** faktorizaciji, možemo dobiti i **bez** transponiranja — akumulacijom produkta

- ▶ **inverznih** rotacija **zdesna**, na **početnu** matricu  $I_m$ .

**Inverzna** rotacija = rotacija za **suprotni kut** (tj.  $\varphi \mapsto -\varphi$ ).

Na pr.,

$$\begin{aligned} Q &= (R(n, m, \varphi_{nm}) \cdots R(1, 2, \varphi_{12}) I_m)^T \\ &= I_m R(1, 2, -\varphi_{12}) \cdots R(n, m, -\varphi_{nm}). \end{aligned}$$

**Pravokutnu** matricu  $Q_0$  iz **skraćene QR** faktorizacije dobivamo tako da uzmemo **prvih  $n$**  stupaca od završne matrice  $Q$ ,

$$Q_0 = Q(1 : n).$$

A **obratno**? Napravimo **punu QR** faktorizaciju matrice  $Q_0$ !

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

### QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

# Householderovi reflektori

Za zadani **jedinični** vektor  $u \in \mathbb{R}^m$ , matrica  $H$  definirana s

$$H = H(u) := I - 2uu^T, \quad \|u\|_2 = 1,$$

zove se **Householderov reflektor**.

Matrica  $H$  je


- ▶ **simetrična**,
- ▶ i **ortogonalna**, jer je

$$\begin{aligned} HH^T &= H^2 = (I - 2uu^T)(I - 2uu^T) \\ &= I - 4uu^T + 4u(u^T u)u^T \\ &= I - 4uu^T + 4\|u\|_2^2 uu^T = I. \end{aligned}$$

# Zašto baš ime reflektor?

Promatrajmo **hiperravninu** koja je **okomita** na vektor  $u$ .

- ▶ Reflektor  $H$  sve vektore  $x$  preslikava u **simetrične** obzirom na tu hiperravninu,  $x' = Hx$ .



Usput,  $P(u) := I - uu^T$  je projektor na tu hiperravninu.

# Poništavanje Householderovim reflektorima

Neka je zadan vektor  $x$ . Treba naći **Householderov reflektor**  $H$  koji **poništava sve** komponente vektora  $x$ , osim **prve**. Dakle, treba naći **jedinični** vektor  $u$  koji **definira** takav reflektor  $H$ .

Tražimo da je

$$Hx = \begin{bmatrix} c \\ 0 \\ \vdots \\ 0 \end{bmatrix} = c \cdot e_1, \quad c \in \mathbb{R}.$$

Za početak,  $H$  je **unitarna** matrica, pa čuva **normu** vektora,

$$\|x\|_2 = \|Hx\|_2 = |c|.$$

odakle slijedi da je  $c = \pm\|x\|_2$ .

# Poništavanje Householderovim reflektorima

Napišimo traženu jednadžbu preko **nepoznatog** vektora  $u$

$$Hx = (I - 2uu^T)x = x - 2u(u^T x) = \pm \|x\|_2 e_1.$$

Uočimo da je  $u^T x$  broj = skalarni produkt dva vektora.

**Zanemarimo** na trenutak mogućnost da je  $u^T x = 0$ . Onda je

$$u = \frac{1}{2(u^T x)} (x \mp \|x\|_2 e_1).$$

Obzirom na to da  $u^T x$  **ne znamo**, možemo zaključiti da je

$$u = \alpha (x \mp \|x\|_2 e_1), \quad \text{za neki } \alpha \in \mathbb{R},$$

tj. da je  $u$  **paralelan** s vektorom  $\tilde{u} = x \mp \|x\|_2 e_1$ . Konačno, konstantu  $\alpha$  nalazimo **normiranjem** vektora  $\tilde{u}$  na normu 1.

# Poništavanje Householderovim reflektorima

Prema tome,

$$u = \frac{\tilde{u}}{\|\tilde{u}\|_2},$$

ako je  $\tilde{u} \neq 0$ . U protivnom, stavljamo  $u = 0$ , odnosno,  $H = I$ .  
Uočite da izbor predznaka ( $\mp$ ) u definiciji  $\tilde{u}$  daje

$$Hx = c \cdot e_1 = \pm \|x\|_2 e_1.$$

Ako je  $x = 0$ , onda je  $\tilde{u} = 0$ , a to znači da je  $H = I$ . Tada možemo uzeti bilo koji  $u$ , jer je  $H \cdot 0 = 0$  za svaki  $H$ .

U protivnom je i  $\|x\|_2 \neq 0$ , pa barem jedan izbor predznaka ( $\mp$ ) u formuli za  $\tilde{u}$  daje  $\tilde{u} \neq 0$ . Ako jedan izbor daje  $\tilde{u} = 0$ , onda je  $x = \pm \|x\|_2 e_1$ , pa i nemamo što raditi. Dakle, oba reflektora su korektna.



## Izbor predznaka za $u$

Ranija mogućnost da je  $u^T x = 0$  **ne pravi** nikakve poteškoće. Onda je  $Hx = x = \pm \|x\|_2 e_1$  i **samo** tada **bar jedan** izbor predznaka daje  $\tilde{u} = 0$ . Dobiveni  $H(u)$  je i tada korektan!

Za  $x \neq 0$ , u praksi se, zbog **numeričke stabilnosti**, često koristi

$$\tilde{u} = x + \text{sign}(x_1) \|x\|_2 e_1,$$

zato da **nema kraćenja** pri računanju prve komponente od  $\tilde{u}$ , tj. da oba pribrojnika budu **istog** znaka,

$$\tilde{u}_1 = x_1 + \text{sign}(x_1) \|x\|_2.$$

To znači da je  $c = -\text{sign}(x_1) \|x\|_2$ , što ponekad **zbunjuje** u praksi.

- ▶ Na primjer, za  $x = e_1$  dobivamo  $Hx = -e_1$ !

Stvarno, uz **pažljiviji** poredak računanja, to **nije** potrebno!

## Drugi način definicije $H$ , primjena $H$ na vektor

**Napomena.** Normiranje  $\tilde{u} \mapsto u$  se, **formalno**, može **izbjeći**, ako definiramo

$$H(\tilde{u}) = I - 2 \frac{\tilde{u}\tilde{u}^T}{\tilde{u}^T\tilde{u}}.$$

Kako djelovati s  $H$  na **ostale** stupce (ili neki vektor)?

Kad smo izračunali  $u$ , **ne treba** računati **cijelu** matricu  $H$ . Dovoljno je pogledati kako ona djeluje na neki vektor  $z$ :

$$Hz = (I - 2uu^T)z = z - 2u(u^T z).$$

Dakle, treba izračunati **skalarni produkt**  $u^T z$ , a zatim **modificirati** vektor  $z$  (to je neki stupac radne matrice).

Ako koristimo  $H(\tilde{u})$ , onda  $\tilde{u}^T z$  **stalno** treba dijeliti s  $\|\tilde{u}\|_2^2$ .

# QR faktorizacija korištenjem reflektora

QR faktorizacija provodi se sustavnom primjenom **Householderovih reflektora** na matricu  $G$  i to **slijeva**.

- ▶ Prvo se **reflektorom**  $H_1$  **ponište** svi elementi **prvog** stupca (do na prvi), a na ostale stupce se djeluje **reflektorom**  $H_1$ .
- ▶ Zatim se **ponište** elementi dijela **drugog** stupca od dijagonale nadalje (osim dijagonalnog elementa). To se radi “**skraćenim**” **reflektorom**  $H'_2$ .

Na **cijelu** radnu matricu onda djelujemo **reflektorom**

$$H_2 = \begin{bmatrix} 1 & \\ & H'_2 \end{bmatrix}.$$

U pripadnom vektoru  $u$ , prva komponenta je  $u_1 = 0$ .

# QR faktorizacija korištenjem reflektora

I tako redom. U  $k$ -tom koraku, za  $k = 1, \dots, n$ ,

- ▶ reflektorom  $H'_k$  se poništava  $k$ -ti “skraćeni” stupac u radnoj matrici — od dijagonale nadolje.
- ▶ Na cijelu radnu matricu onda djelujemo reflektorom

$$H_k = \begin{bmatrix} I & \\ & H'_k \end{bmatrix},$$

s tim da je  $I$  reda  $k - 1$ , a  $H'_k$  je reda  $m - k + 1$ .

Ako želimo formirati ortogonalnu matricu  $Q$ , onda je

$$H_n H_{n-1} \cdots H_1 G = R, \quad \text{tj.} \quad Q^T = H_n H_{n-1} \cdots H_1,$$

ili

$$Q = (H_n H_{n-1} \cdots H_1)^T = H_1 \cdots H_{n-1} H_n.$$

## Metoda najmanjih kvadrata

Diskretni problem najmanjih kvadrata

Matrična formulacija linearnog problema najmanjih kvadrata

### QR faktorizacija

Givensove rotacije

Householderovi reflektori

QR faktorizacija i pivotiranje

# Računanje QR faktorizacije

Neka je  $G$  zadana matrica tipa  $m \times n$ , s tim da je  $m \geq n$ .

Računanje QR faktorizacije matrice  $G$

- ▶ provodimo u nizu od  $n$  koraka. Ako dozvolimo i  $m < n$ , broj koraka je  $\min\{m, n\}$ .

Na početku algoritma označimo  $R^{(0)} := G$ .

Opišimo kako izgleda  $k$ -ti korak algoritma, za  $k = 1, \dots, n$ .

- ▶ Na početku  $k$ -tog koraka, trenutna radna matrica je  $R^{(k-1)}$ .
- ▶ U njoj, prvih  $k - 1$  stupaca već ima gornjetrokutastu formu, tj. nule ispod dijagonale.
- ▶ Ti stupci se više neće mijenjati!

# Računanje QR faktorizacije — radna matrica

Izgled radne matrice  $R^{(k-1)}$  na početku  $k$ -tog koraka:

$$\left[ \begin{array}{cccc|ccc} r_{1,1}^{(1)} & r_{1,2}^{(2)} & \cdots & r_{1,k-1}^{(k-1)} & r_{1,k}^{(k-1)} & \cdots & r_{1,n}^{(k-1)} \\ & r_{2,2}^{(2)} & \cdots & r_{2,k-1}^{(k-1)} & r_{2,k}^{(k-1)} & \cdots & r_{2,n}^{(k-1)} \\ & & \ddots & \vdots & \vdots & & \vdots \\ & & & r_{k-1,k-1}^{(k-1)} & r_{k-1,k}^{(k-1)} & \cdots & r_{k-1,n}^{(k-1)} \\ & & & & r_{k,k}^{(k-1)} & \cdots & r_{k,n}^{(k-1)} \\ & & & & \vdots & & \vdots \\ & & & & r_{m,k}^{(k-1)} & \cdots & r_{m,n}^{(k-1)} \end{array} \right] \cdot$$

## Računanje QR faktorizacije — $k$ -ti korak

U  $k$ -tom koraku — u matrici  $R^{(k-1)}$

- ▶ **poništavamo** sve elemente  $k$ -tog stupca **ispod** dijagonale, nekom ortogonalnom transformacijom  $Q_k$ .
- ▶ Tako dobivamo **novu** radnu matricu  $R^{(k)}$  koja ima **jedan** “sređeni” stupac **više**.

Ovu transformaciju možemo prikazati u obliku

$$R^{(k)} = Q_k R^{(k-1)}, \quad k = 1, \dots, n.$$

Na **kraju** dobivamo **gornju** trokutastu matricu  $R := R^{(n)}$ .

Nije bitno **kako** računamo  $Q_k$  — rotacijama ili reflektorima!



# Pivotiranje stupaca u QR faktorizaciji

Kod QR faktorizacije, također, možemo koristiti **pivotiranje**, slično kao kod LU faktorizacije ili faktorizacije **Choleskog**.

- ▶ Uobičajeno se koristi pivotiranje (= zamjene) **stupaca**

$$GP = QR,$$

gdje je  $P$  matrica permutacije.

Pivotiranje **stupaca** u  $k$ -tom koraku algoritma ( $k = 1, \dots, n$ ):

- ▶ Ako su  $x_\ell$ , za  $\ell = k, \dots, n$ , **skraćeni** stupci (od  $k$ -tog do  $m$ -tog reda), na “prvo” (tj.  $k$ -to) mjesto dovodi se onaj s **najvećom** normom, tj. tako da  $\|x_k\|_2$  bude **maksimalna**.
- ▶ Zamjene se rade s **cijelim** stupcima, a ne sa skraćenim!

U zadnjem koraku više **nema** zamjena (samo jedan stupac).

# Svrha pivotiranja

## Svrha?

- ▶ Ako matrica  $G$  ima (skoro) linearno zavisne stupce, onda se QR faktorizacijom s pivotiranjem numerički određuje rang matrice  $G$  — “rez” kad dijagonala u  $R_0$  “padne”.

**Teorem.** Neka je  $G \in \mathbb{R}^{m \times n}$  matrica ranga  $r$ . Tada postoje  $n \times n$  matrica permutacije  $P$ , ortogonalna matrica  $Q$  reda  $m$ , te gornja trokutasta matrica  $R_0$  ranga  $r$ , tipa  $\min\{m, n\} \times n$ , tako da vrijedi

$$GP = QR = Q \begin{bmatrix} R_0 \\ 0 \end{bmatrix}$$

i

$$r_{kk}^2 \geq \sum_{i=k}^j r_{ij}^2 \geq r_{jj}^2, \quad j = k + 1, \dots, n, \quad k = 1, \dots, \min\{m, n\}.$$

# Veza QR faktorizacije i faktorizacije Choleskog

Neka je  $G$  pravokutna matrica tipa  $(m, n)$ , koja ima puni stupčani rang, tj.  $\text{rang}(G) = n \leq m$ .

Matrica  $G$  ima jedinstvenu skraćenu QR faktorizaciju, pa je puni QR oblika

$$G = Q \begin{bmatrix} R_0 \\ 0 \end{bmatrix},$$

gdje je  $R_0$  jedinstvena gornja trokutasta matrica reda  $n$ , s pozitivnim dijagonalnim elementima, a  $Q$  je unitarna matrica.

S druge strane, neka je  $H := G^* G$  Gramova matrica skalarnih produkata stupaca matrice  $G$ .

Znamo da je onda  $H$  pozitivno definitna matrica. Zato  $H$  ima jedinstvenu faktorizaciju Choleskog ...

# Veza QR faktorizacije i faktorizacije Choleskog

$$H = R^*R,$$

gdje je  $R$  gornja trokutasta s pozitivnom dijagonalom.

**Tvrđnja.** Ovi trokutasti faktori su jednaki, tj. vrijedi  $R = R_0$ .

**Dokaz.** U  $H = G^*G$  uvrstimo QR faktorizaciju od  $G$  i “skratimo”  $Q^*Q = I$ . Jedinственost faktora  $R$  daje tvrdnju.



Ista veza (jednakost) vrijedi i za faktorizacije s pivotiranjem:

- ▶ pivotiranje stupaca po normi u QR faktorizaciji, i
- ▶ dijagonalno pivotiranje u faktorizaciji Choleskog.

**Korist:** ako znamo “faktor”  $G$  matrice  $H$ , i tražimo  $R$ ,

- ▶ ne treba računati  $H$ , pa Choleskog, već samo QR od  $G$ .