

# *Numerička matematika*

## *7. predavanje*

Saša Singer

`singer@math.hr`

`web.math.pmf.unizg.hr/~singer`

PMF – Matematički odsjek, Zagreb

# Sadržaj predavanja

- Metoda najmanjih kvadrata:
  - Diskretni problem najmanjih kvadrata.
  - Normalne jednačbe.
  - Linearizacija.
  - Primjer za najmanje kvadrate — etil.
  - Matrična formulacija linearnog problema najmanjih kvadrata.

# *Informacije*

Trenutno nema bitnih informacija.

# Diskretni problem najmanjih kvadrata

# 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 mnogo 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 jednadžbi

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 jednadžbi.

# 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 **regularna**, uz **uvjet** da imamo **barem dvije različite** točke  $x_k$ . To je ekvivalentno (Gramova matrica) linearnoj **nezavisnosti** vektora

$$(1, 1, \dots, 1)^T \quad \text{i} \quad (x_0, x_1, \dots, x_n)^T.$$

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** jedinoj 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  $y = a_0 + a_1x$ .

## 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.

**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 **logaritmiramo** relaciju

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

dobivamo

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

## Primjer nelinearnih najmanjih kvadrata

Moramo **logaritmirati** 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)

$$\psi(x) = \log \varphi(x) = \log(a_0) + a_1 \log x,$$

$$h_k = \log f_k, \quad k = 0, \dots, n.$$

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:

$$\psi(x) = \frac{x}{\varphi(x)} = a_0 + a_1x,$$

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

Pripadni **linearni** problem najmanjih kvadrata je

$$\tilde{S} = \tilde{S}(a_0, a_1) = \sum_{k=0}^n (h_k - a_0 - a_1x_k)^2 \rightarrow \min.$$



## 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  $10^6 \text{ km}$ ),
- a  $x$  je **kut** između **spojnice** Zemlja–Sunce i **glavne osi** elipse (u **stupnjevima**). [radijani =  $\pi \cdot \text{stupnjevi}/180$ ]!

## Primjer (nastavak)

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

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

gdje je  $\varepsilon$  **ekscentricitet** elipse, a  $\rho$  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**

$i$	$v_i = r_i$	$u_i = r_i \cos x_i$	$u_i^2$	$u_i v_i$
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** uklanja **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 uniformna** funkcija između  $-1$  i  $1$ , što znači da smo **uklonili** slučajnu grešku.

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

## Demo primjeri

GnuPlot demo za prethodni problem.

- Num\_Pas\Mls\GnuPlot\Pravac.plt

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).

- Num\_Pas\Mls\GnuPlot\Etil.plt

# Primjer izbora funkcije — etil

# 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



# Matrična formulacija linearnog problema najmanjih kvadrata



# Matrična formulacija

Diskretni **linearni** problem najmanjih kvadrata najčešće se rješava 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 ( $n \gg m$ ).

# Matrična formulacija — preodređeni sustav

Uz oznake

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

prethodne jednadžbe možemo napisati u **matričnom obliku**

$$Ax = b.$$

**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 jednadžbi.

Taj sustav **ne mora** uvijek **imati** rješenje, tj. može se dogoditi da je

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

Upravo to se, gotovo uvijek, i događa u praksi.

# Matrična formulacija — min norme reziduala

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

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

Problem “najmanjih kvadrata”: minimizacija norme  $\|Ax - b\|_2$  ekvivalentna je minimizaciji kvadrata norme  $\|Ax - b\|_2^2$ .

## 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 jednažbi i pišemo u obliku

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

**Napomena.** Raniji pristup — minimizacijom norme vektora greške, daje baš ovaj sustav normalnih jednažbi. Provjerite!

$A^T A$  je Gramova matrica skalarnih produkata stupaca od  $A$ .

## 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, odnosno, da za rezidual  $r = b - Ax$  vrijedi  $A^T r = 0$ .

Pretpostavimo **suprotno** — da za rezidual  $r$  vrijedi

$$A^T r = z \neq 0.$$

Za  $\varepsilon \in \mathbb{R}$ , promatramo vektor  $\hat{x} = x + \varepsilon z$ . Njegov rezidual je

$$\hat{r} = b - A\hat{x} = b - Ax - \varepsilon Az = r - \varepsilon Az,$$

pa je

$$\begin{aligned} \|\hat{r}\|_2^2 &= \hat{r}^T \hat{r} = r^T r - \varepsilon r^T Az - \varepsilon (Az)^T r + \varepsilon^2 (Az)^T (Az) \\ &= \{A^T r = z\} = r^T r - 2\varepsilon z^T z + \varepsilon^2 (Az)^T (Az) \\ &= \|r\|_2^2 - 2\varepsilon \|z\|_2^2 + \varepsilon^2 \|Az\|_2^2. \end{aligned}$$

## Rješenje problema najmanjih kvadrata

No, zbog  $\|z\| > 0$ , za dovoljno mali  $\varepsilon > 0$  dobivamo da je

$$\|\hat{r}\|_2^2 = \|r\|_2^2 - 2\varepsilon\|z\|_2^2 + \varepsilon^2\|Az\|_2^2 < \|r\|_2^2,$$

što je **kontradikcija** s pretpostavkom da  $x$  **minimizira** rezidual.

Zaključujemo da **mora** biti  $z = 0$ , tj. da  $x$  **zadovoljava** sustav **normalnih** jednažbi.

**Obrat.** Pretpostavimo da  $x$  **zadovoljava** **normalne** jednažbe

$$A^T r = 0, \quad r = b - Ax.$$

Za bilo koji vektor  $\hat{x} \in \mathbb{R}^m$ , njegov rezidual  $\hat{r}$  ima oblik

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



## Rješenje problema najmanjih kvadrata

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  $x \in \mathcal{S}$ . ■

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

# Struktura skupa svih rješenja

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  $\mathbb{R}^m$ .

**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

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

Odavde odmah slijedi egzistencija rješenja, tj.  $\mathcal{S} \neq \emptyset$ .

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

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

- 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). ■

# 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 matrice  $A$  su **linearno nezavisni**, ako i samo ako za svaki  $x \neq 0$  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

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

# 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 jednažbi odmah vidimo da je

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

što znači da je  $r \in \mathcal{N}(A^T)$ . Na kraju, prisjetimo se da je


$$\mathcal{R}(A) \oplus \mathcal{N}(A^T) = \mathbb{R}^n,$$

pa vektor  $r$  mora biti **okomit** 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.

Sjetite se uvodnih komentara o izboru “baznih” funkcija  $\varphi_j$ .

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:

- To rješenje je ortogonalna projekcija ishodišta, odnosno, nul-vektora na linearnu mnogostrukost  $\mathcal{S} = x_0 + \mathcal{N}(A)$  (očito je jedinstveno).

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 jednadžbi 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 **tačno**.

Može se koristiti za **mali** broj parametara  $m$ , ako **ne tražimo** **jako tačno** 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  $A = QR$ !