

# *Znanstveno računanje 2*

## *11. i 12. predavanje*

Saša Singer

[singer@math.hr](mailto:singer@math.hr)

[web.math.hr/~singer](http://web.math.hr/~singer)

PMF – Matematički odjel, Zagreb

# Sadržaj predavanja

- Izgladivanje podataka i metoda najmanjih kvadrata:
  - Veza izgladivanja i najmanjih kvadrata.
  - Globalno i lokalno izgladivanje.
  - Diskretni ortogonalni polonomi i Forsytheov algoritam.
  - Lokalno izgladivanje — najmanji kvadrati, integral.
  - Diskretna ortogonalnost trigonometrijskih funkcija.
  - Najmanji kvadrati i splajn funkcije.
  - Dierckx.

# Informacije

Konzultacije (trajno, nažalost):

- utorak, 16–17 sati, petak, 19–20 sati.

Sljedeća dva tjedna — 9. 6. i 16. 6.

- nemamo nastavu,

- tu sam — možete me iskoristiti za konzultacije.

Završni projektni zadaci će biti spremni

- do kraja ovog vikenda — 7. 6., na mom webu,

- preuzimanje ide preko foruma (kao prije),

- rok za predaju je petak, 17. 7., u 14 sati.

# Izглаđivanje podataka i diskretni najmanji kvadrati

# Uvod u izgladivanje podataka

Zadan je skup podataka (ili točaka u ravnini)

$$(x_i, f_i), \quad i = 0, \dots, n,$$

pri čemu

- vrijednosti  $x_i$  smatramo **točnim** — bez grešaka,
- a vrijednosti  $f_i$  su “**izmjerene**” vrijednosti i nose u sebi neku **grešku**, označimo ju s  $\varepsilon_i$ .

Na primjer,  $f_i$  možemo interpretirati kao

- **približne** vrijednosti neke **funkcije**  $f$  u točkama  $x_i$ .

**Prave** vrijednosti  $f(x_i)$ , naravno, **ne znamo!**

Točke  $x_i$ , bar zasad, **ne moraju** biti međusobno **različite**, isto kao i kod diskretnih najmanjih kvadrata.

Međutim, pretpostavimo da **jesu** međusobno **različite**

# Uvod u izgladivanje podataka

Dakle, imamo **izmjereni** uzorak funkcijskih vrijednosti funkcije  $f$  na **diskretnom** skupu točaka  $x_0, \dots, x_n$ , za koji vrijedi

$$f_i = f(x_i) + \varepsilon_i, \quad i = 0, \dots, n.$$

**Ideja:** uz određene **statističke** pretpostavke na “**slučajnost**” grešaka  $\varepsilon_i$ ,

- zamijeniti  $f_i$  vrijednošću neke **aproksimacijske** funkcije  $\varphi$  u točki  $x_i$ ,
- tako da **očekivane** greške u  $\varphi_i := \varphi(x_i)$  budu “**manje**”.

Drugim riječima, cilj je

- **ukloniti slučajne** greške u  $f_i$ , ili
- “**izgladiti**” ove izmjerene podatke!

# Statističke pretpostavke na model

Za **izglađivanje** trebamo **dvije** statističke **pretpostavke** na greške.

**Prva** i ključna pretpostavka:

- U mjerenjima **nema sistematskih** grešaka, tj. imamo dobro “kalibrirane” instrumente, ili,
- **srednja vrijednost** ili **očekivanje** greške je **nula**

$$E(\varepsilon_i) = 0, \quad i = 0, \dots, n.$$

Pisano vektorski u prostoru  $\mathbb{R}^{n+1}$ , uz oznaku  $\varepsilon = (\varepsilon_0, \dots, \varepsilon_n)^T$ ,

$$E(\varepsilon) = 0.$$

Uz tu pretpostavku, **nepoznata** vrijednost  $f(x_i)$  je **ista** kao i **očekivanje izmjerene** vrijednosti  $f_i$ , za  $i = 0, \dots, n$ .

# Statističke pretpostavke na model

Druga pretpostavka, koja bitno olakšava računanje:

- Greške u različitim mjerenjima (od točke do točke) su statistički nezavisne,
- tj., kovarijacijska matrica  $V := V(\varepsilon)$  je dijagonalna

$$V(\varepsilon) = \text{diag}(\sigma_0^2, \dots, \sigma_n^2),$$

a  $\sigma_0, \dots, \sigma_n$  su standardne devijacije u pojedinim mjerenjima (kvadrati su varijance).

Sasvim općenito, kovarijacijska matrica  $V$  može biti

- bilo koja (simetrična) pozitivno definitna matrica.

No, dijagonalnost bitno ubrzava računanje, a često je istinita u praksi.



## Skalarni produkt generiran s $W = V^{-1}$

Na vektorskom prostoru  $\mathbb{R}^{n+1}$  definiramo **skalarni produkt generiran** matricom  $W := V^{-1}$  na sljedeći način

$$\langle u, v \rangle_W := v^T W u = \langle W u, v \rangle, \quad u, v \in \mathbb{R}^{n+1}.$$

Iz **pozitivne definitnosti** matrice  $V^{-1}$  lako slijedi da je ovo zaista **skalarni produkt**.

Pripadnu **W-normu** vektora definiramo na standardni način

$$\|v\|_W := \sqrt{\langle v, v \rangle_W} = \sqrt{\langle W v, v \rangle}, \quad v \in \mathbb{R}^{n+1}.$$

Obično ćemo koristiti **kvadrat** norme

$$\|v\|_W^2 = \langle v, v \rangle_W = \langle W v, v \rangle, \quad v \in \mathbb{R}^{n+1}.$$

# Linearna aproksimacija

Aproksimacijsku funkciju  $\varphi$  prikazujemo kao

- nepoznatu linearnu kombinaciju
- poznatih (izabranih) funkcija — tzv. funkcija “baze” u izabranom modelu.

Neka su  $\varphi_0, \dots, \varphi_m$  izabrane funkcije “baze” u modelu.

Aproksimacijska funkcija  $\varphi$  ima oblik

$$\varphi(x) = c_0\varphi_0(x) + \dots + c_m\varphi_m(x) = \sum_{j=0}^m c_j\varphi_j(x),$$

Koeficijenti  $c_0, \dots, c_m$  u ovoj linearnoj kombinaciji su nepoznati parametri koje treba odrediti.

Dovoljno je uzeti  $m \leq n$ . U praksi, točaka  $x_0, \dots, x_n$  ima mnogo više nego nepoznatih parametara  $c_0, \dots, c_m$ , tj.  $n \gg m$ .

# Linearna aproksimacija

Iz vrijednosti funkcija baze  $\varphi_j$  u točkama  $x_i$  formiramo

• (općenito, pravokutnu) matricu  $A \in \mathbb{R}^{(n+1) \times (m+1)}$  na sljedeći način

$$a_{ij} := \varphi_j(x_i), \quad i = 0, \dots, n, \quad j = 0, \dots, m.$$

Ako su funkcije baze “dobro” izabrane, onda su

• stupci matrice  $A$  su linearno nezavisni, tako da  $A$  ima puni stupčani rang (zato nam treba  $m \leq n$ ).

Uz ove oznake, imamo

$$\varphi(x_i) = \sum_{j=0}^m c_j \varphi_j(x_i) = \sum_{j=0}^m a_{ij} c_j, \quad i = 0, \dots, n.$$

# Linearni model i procjena parametara

Nepoznate parametre  $c_0, \dots, c_m$  određujemo iz “modela”

$$f_i = \varphi(x_i) + \varepsilon_i, \quad i = 0, \dots, n,$$

Označimo s

- $\tilde{f} := (f_0, \dots, f_n)^T \in \mathbb{R}^{n+1}$  vektor izmjerenih vrijednosti,
- $c := (c_0, \dots, c_m)^T \in \mathbb{R}^{m+1}$  vektor nepoznatih parametara.

Onda dobivamo tzv. **linearni** model za procjenu parametara  $c$  u obliku

$$\tilde{f} = Ac + \varepsilon.$$

Uz sve navedene pretpostavke, **najbolju** procjenu parametara dobivamo iz **Gauss–Markov** teorema:

- to je ona s **najmanjom varijancom!**

# Veza izgladivanja i najmanjih kvadrata

To direktno vodi u metodu najmanjih kvadrata:

- minimiziraj varijancu.

Preciznije, najbolji izbor parametara (za fiksni  $m$ ) je rješenje  $c$  problema najmanjih kvadrata

$$\|\tilde{f} - Ac\|_W^2 = \langle W(\tilde{f} - Ac), \tilde{f} - Ac \rangle \rightarrow \min,$$

uz  $W = V^{-1}$ . Pripadni sustav normalnih jednažbi je

$$(A^T W A)c = A^T W \tilde{f}.$$

Dodatno, kovarijacijska matrica najbolje procjene  $c$  je

$$V(c) = (A^T W A)^{-1}.$$

# Veza izgladivanja i najmanjih kvadrata

Na kraju, pripadna **minimalna** varijanca je

$$s^2 = \frac{\|\tilde{f} - Ac\|_W^2}{n - m}.$$

Do na faktor u nazivniku,

● **brojnik** je ono što se **minimizira** (najmanji kvadrati)!

Ovaj rezultat vrijedi za **bilo koju** simetričnu pozitivno definitnu kovarijacijsku matricu  $V$ .

# Standardni zapis skalarnog produkta

U praksi je kovarijacijska matrica  $V$  često **dijagonalna**

$$V(\varepsilon) = \text{diag}(\sigma_0^2, \dots, \sigma_n^2),$$

a  $\sigma_0, \dots, \sigma_n$  su **standardne devijacije** u pojedinim mjerenjima (**kvadrati** su **varijance**). Tada se koristi standardna oznaka

$$w_i = \frac{1}{\sigma_i^2}, \quad i = 0, \dots, n,$$

a pripadni **težinski** skalarni produkt ima oblik

$$\langle u, v \rangle_W = \sum_{i=0}^n w_i u_i v_i, \quad u, v \in \mathbb{R}^{n+1}.$$

Složenost pada s  $O(n^2)$  na  $O(n)$ .

# Težinski najmanji kvadrati

Pripadni problem najmanjih kvadrata

$$\|\tilde{f} - Ac\|_W^2 = \langle W(\tilde{f} - Ac), \tilde{f} - Ac \rangle \rightarrow \min,$$

onda ima “**puni**” oblik

$$\|\tilde{f} - Ac\|_W^2 = \sum_{i=0}^n w_i \left( f_i - \sum_{j=0}^m c_j \varphi_j(x_i) \right)^2 \rightarrow \min.$$



# Praktični problemi kod izgladivanja

- Praktična uloga varijanci  $\sigma_i$ , odnosno težina  $w_i$ .
- Skaliranje slično klasičnoj pretpostavci — greške su nezavisne, normalna distribucija  $N(0, 1)$ .
- Izbacivanje **istih** točaka (zbog dimenzije).

U primjeni kod izgladivanja —  $m$  se **traži!**

- Ideja — diži  $m$  (dimenziju prostora), sve dok se varijanca  $s_m^2$  približno ne **stabilizira**.
- Matrica  $A$  varira (raste) s  $m$ .
- To ima smisla koristiti ako uzimamo **ortogonalne** baze, tako da  $A$  ima **ortogonalne** stupce ( $A^T W A = I_m$ ).
- Realizacija za **polinome** = **Forsytheov** algoritam s **detekcijom** stupnja.