

# *Numerička matematika*

## *14. predavanje*

Saša Singer

`singer@math.hr`

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

PMF – Matematički odsjek, Zagreb

# Sadržaj predavanja

- Rješavanje sustava nelinearnih jednadžbi:
  - Newtonova metoda za nelinearne sustave.
  - Metoda sekante za nelinearne sustave.
- Uvod u optimizaciju bez ograničenja:
  - Formulacija problema.
  - Vrste metoda za optimizaciju bez ograničenja.

# Rješavanje sustava nelinearnih jednadžbi

# Formulacija problema

Zadana je funkcija

$$f : \mathbb{R}^n \rightarrow \mathbb{R}^m.$$

Radi jednostavnosti, pretpostavljamo da je  $f$  definirana na cijelom prostoru  $\mathbb{R}^n$ .

Kao i prije, tražimo (jednu ili sve) točke  $x \in \mathbb{R}^n$  za koje je

$$f(x) = 0 \in \mathbb{R}^m.$$

Najjednostavniji primjer je tzv. linearna (ili afina) funkcija  $f$

$$f(x) = Ax - b, \quad x \in \mathbb{R}^n$$

gdje je  $A \in \mathbb{R}^{m \times n}$  zadana pravokutna matrica s  $m$  redaka i  $n$  stupaca, a  $b \in \mathbb{R}^m$  je zadani vektor.

Nultočke ove funkcije su rješenja linearnog sustava  $Ax = b$ .

# Pojednostavljenja — dodatne pretpostavke

Raspisom vektorske jednadžbe  $f(x) = 0$  po **komponentama** u prostoru  $\mathbb{R}^m$ , dobivamo **sustav** s  $m$  jednadžbi i  $n$  nepoznanica

$$f_i(x_1, x_2, \dots, x_n) = 0, \quad i = 1, \dots, m.$$

**Dodatne** pretpostavke u nastavku:

- funkcija  $f$  je, općenito, **nelinearna**,
- broj jednadžbi  $m$  **jednak** je broju nepoznanica  $n$ ,  
tj. funkcija je  $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ .

Osim toga, pretpostavljamo

- da  $f$  ima samo **izolirane** nultočke  $\alpha \in \mathbb{R}^n$ , i
- da je  $f$  dovoljno **glatka** — na cijelom  $\mathbb{R}^n$ , ili barem u nekoj **okolini** nultočke.

# O generalizaciji metoda iz jedne dimenzije

Očita ideja za rješavanje sustava nelinearnih jednačbi je

- generalizacija metoda za rješavanje jedne jednačbe.

**Problem:** U više dimenzija nema uspoređivanja funkcijskih vrijednosti (vektora  $f$ ) — osim po komponentama  $f_i$ .

Zato se “jednostavne” metode — poput bisekcije,

- teško generaliziraju, a i složenost postaje problem (imamo  $2^n$  vrhova “kocke” i  $n$  komponentnih funkcija u svakom vrhu). Probajte zamisliti u  $\mathbb{R}^2$ !

S druge strane, većina “iteracijskih” funkcija se

- relativno jednostavno generalizira — iz “skalarnih”, u “vektorske” ili “matrično–vektorske”.

Ilustracija toga = Newtonova metoda i metoda sekante.

## Newtonova metoda u $\mathbb{R}^n$

Newtonovu metodu dobivamo linearizacijom funkcije  $f$  oko trenutne aproksimacije  $x^{(k)} \in \mathbb{R}^n$  — slično kao za  $n = 1$ , samo su oznake malo drugačije (indeksi služe za komponente).

Izaberemo neku početnu točku  $x^{(0)} \in \mathbb{R}^n$ . Onda, induktivno, generiramo niz aproksimacija  $x^{(k)}$ , za  $k \geq 0$ , na sljedeći način.

Oko trenutne točke  $x^{(k)}$ , svaku komponentnu funkciju  $f_i$

aproximiramo linearnim dijelom Taylorovog razvoja, tj. odbacujemo sve članove nakon linearnih. Dobivamo

$$f_i(x) \approx f_i(x^{(k)}) + \sum_{j=1}^n \frac{\partial f_i}{\partial x_j}(x^{(k)}) (x_j - x_j^{(k)}), \quad i = 1, \dots, n.$$

# Newtonova metoda u $\mathbb{R}^n$

Iskoristimo **Jacobijevu** matricu  $J_f(x)$ , koja sadrži **parcijalne derivacije** svih komponentnih funkcija po svim varijablama

$$[J_f(x)]_{ij} = \frac{\partial f_i}{\partial x_j}, \quad i = 1, \dots, n, \quad j = 1, \dots, n,$$

ili

$$J_f(x) = \frac{\partial f}{\partial x}(x) = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \dots & \frac{\partial f_1}{\partial x_n} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \dots & \frac{\partial f_2}{\partial x_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \dots & \frac{\partial f_n}{\partial x_n} \end{bmatrix} \in \mathbb{R}^{n \times n}.$$



# Newtonova metoda u $\mathbb{R}^n$

**Lineariziranu** aproksimaciju za  $f(x)$  oko točke  $x^{(k)}$  možemo zapisati u **matrično–vektorskom** obliku

$$f(x) \approx f(x^{(k)}) + J_f(x^{(k)}) (x - x^{(k)}).$$

**Novu** aproksimaciju  $x^{(k+1)}$  za nultočku dobivamo iz zahtjeva da je

$$f(x^{(k+1)}) \approx f(x^{(k)}) + J_f(x^{(k)}) (x^{(k+1)} - x^{(k)}) = 0.$$

Ako je  $J_f(x^{(k)})$  **regularna** matrica, onda je pripadna **korekcija**

$$d^{(k)} := x^{(k+1)} - x^{(k)}$$

jedinstveno **rješenje linearnog** sustava jednadžbi

$$J_f(x^{(k)}) d^{(k)} = -f(x^{(k)}).$$

## Newtonova metoda u $\mathbb{R}^n$

Za korekciju  $d^{(k)}$  onda vrijedi (ali se **ne** računa ovako)

$$d^{(k)} = -[J_f(x^{(k)})]^{-1} f(x^{(k)}),$$

pa izlazi standardni zapis za iteracije u **Newtonovoj** metodi

$$x^{(k+1)} = x^{(k)} - [J_f(x^{(k)})]^{-1} f(x^{(k)}), \quad k = 0, 1, \dots$$

U usporedbi sa “**skalarnim**” oblikom Newtonove metode,

$$x^{(k+1)} = x^{(k)} - \frac{f(x^{(k)})}{f'(x^{(k)})},$$

- **množenje inverzom Jacobijeve** matrice  $J_f(x)$ , i to **slijeva**, je “zamjena” za **dijeljenje** derivacijom funkcije  $f'(x)$ .

Za računanje, **Jacobijeva** matrica  $J_f(x^{(k)})$  mora biti **regularna**.

# Lokalna konvergencija Newtonove metode u $\mathbb{R}^n$

Uočite da se rješavanje **jednog nelinearnog** sustava jednažbi svodi na **niz** rješavanja **linearnih** sustava.

Što se **konvergencije** tiče, vrijedi potpuni analogon rezultata o **lokalnoj** konvergenciji i **brzini** konvergencije u jednoj dimenziji.

**Teorem.** Neka je  $\alpha$  nultočka funkcije  $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$  i neka je  $f$  klase  $C^2$  u okolini od  $\alpha$ .

Ako je  $J_f(\alpha)$  **regularna** matrica (to je analogon **jednostruke** nultočke), onda **postoji** okolina nultočke  $\alpha$ , takva da

- za bilo koju **početnu** točku  $x^{(0)}$  iz te okoline,
- niz iteracija generiran **Newtonovom** metodom, **konvergira** prema  $\alpha$ , i konvergencija je (barem) **kvadratna**,

tj. vrijedi 
$$\|\alpha - x^{(k+1)}\| \in O(\|\alpha - x^{(k)}\|^2).$$



## Metoda sekante u $\mathbb{R}^n$

Metodu **sekante** dobivamo iz **Newtonove** metode, slično kao u jednoj dimenziji.

Izaberemo **dvije početne** točke  $x^{(0)}$  i  $x^{(1)}$ .

U točki  $x^{(k)}$ , za  $k \geq 1$ , sve **parcijalne derivacije** u **Jacobijevoj** matrici  $J_f(x^{(k)})$ ,

- aproximiramo pripadnim **podijeljenim razlikama** kroz **zadnje** dvije aproksimacije  $x^{(k)}$  i  $x^{(k-1)}$ .

Dobivamo “**sekantnu**” matricu

$$[S_f(x^{(k)})]_{ij} = \frac{f_i(x^{(k)}) - f_i(x^{(k-1)})}{x_j^{(k)} - x_j^{(k-1)}}, \quad i, j = 1, \dots, n.$$

Dalje postupamo isto kao u **Newtonovoj** metodi.

## Metoda sekante u $\mathbb{R}^n$

Ako je  $S_f(x^{(k)})$  regularna matrica, onda je pripadna korekcija

$$d^{(k)} := x^{(k+1)} - x^{(k)}$$

jedinstveno rješenje linearnog sustava jednadžbi

$$S_f(x^{(k)}) d^{(k)} = -f(x^{(k)}).$$

Oдавде izlazi standardni zapis za iteracije u metodi sekante

$$x^{(k+1)} = x^{(k)} - [S_f(x^{(k)})]^{-1} f(x^{(k)}), \quad k = 1, 2, \dots$$

**Napomena.** Korektnija oznaka za matricu je  $S_f(x^{(k)}, x^{(k-1)})$ , tako da se vidi ovisnost o zadnje dvije aproksimacije.

Za metodu sekante u  $\mathbb{R}^n$  vrijede slični rezultati kao u  $\mathbb{R}$ .

# Uvod u optimizaciju bez ograničenja

# Formulacija problema optimizacije

Zadana je funkcija

$$f : \mathbb{R}^n \rightarrow \mathbb{R}.$$

Opet, radi jednostavnosti, pretpostavljamo da je  $f$  definirana na cijelom prostoru  $\mathbb{R}^n$ .

Tražimo (jednu ili sve) točke  $x^* \in \mathbb{R}^n$  za koje je

$$f(x^*) = \min f(x), \quad \text{ili} \quad x^* = \arg \min f(x).$$

Takve točke  $x^*$  zovu se točke **minimuma** funkcije  $f$ .

Problem **maksimizacije** ili traženja točaka **maksimuma** za funkciju  $f$

• ekvivalentan je **minimizaciji** funkcije  $g = -f$ .

Zato se često kaže: “**optimizacija**” = “**minimizacija**”.

# Vrste problema optimizacije

Ovisno o tome za koje  $x$  vrijedi ranija relacija, razlikujemo

- točke lokalnog minimuma — relacija vrijedi za sve  $x$  iz neke okoline od  $x^*$ ,
- točke globalnog minimuma — relacija vrijedi za sve  $x$  iz domene (kod nas je to cijeli  $\mathbb{R}^n$ ).

Ovaj problem — bez restrikcija u domeni, zove se optimizacija bez ograničenja. Ako minimum tražimo na nekom podskupu  $D \subset \mathbb{R}^n$ , dobivamo problem optimizacije s ograničenjima.

**Napomena.** Većina numeričkih metoda za optimizaciju, nalazi (ili garantira) samo točke lokalnog minimuma.

**Globalnost** ili jedinstvenost se dobiva iz dodatnih svojstava funkcije  $f$  — na primjer, konveksnost od  $f$  (plus još ponešto).



# Metode za optimizaciju bez ograničenja

Uočite da je **kodomena** funkcije  $f$  skup  $\mathbb{R}$ .

- 🔴 Zato ovdje **smijemo uspoređivati** funkcijske vrijednosti.

**Metode** za rješavanje problema optimizacije (bez ograničenja), ugrubo, dijelimo po tome **koje informacije** o funkciji  $f$  koriste (glatkoća).

- 🔴 Metode **direktnog pretraživanja** koriste samo **funkcijske** vrijednosti za  $f$ .
- 🔴 Metode **silaska** koriste i **derivacije** (gradijente) funkcije  $f$ , ili neke aproksimacije za njih.
- 🔴 Metode **Newtonovog** tipa koriste i **druge derivacije** (Hesseovu matricu) od  $f$ , ili neke aproksimacije za njih.