

## Nelinearne jednadžbe:

- Uvod
- Jednodimenzionalna minimizacija
- Metoda zlatnog reza
- Višedimenzionalna minimizacija
- Gradijentna metoda
- Modificirana Newtonova metoda
- Kvazi-Newtonove metode
- Konvergencija
- Primjer

# Optimizacija

## Traženje minimuma funkcije

Zadana funkcija

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

**Cilj:** Naći  $x^*$ , točku minimuma funkcije  $f$ :

$$x^* = \arg \min_{x \in \mathbb{R}^n} f(x).$$

- Problem je jednostavno opisati
- Rješavanje je jedno od najtežih područja numeričke analize.
- Cilj optimizacije je definirati prikladne, tj. što brže postupke, za rješavanje ovog tipa problema.

Nužan uvjet minimuma:

$$\nabla f(\alpha) = 0.$$

Umjesto minimizacije možemo tražiti nultočku gradijenta?

Nemamo garanciju konvergencije prema minimumu. (maksimum, infleksija)

Nekada je bolje umjesto

$$f(x) = 0$$

rješavati ekvivalentni problem

$$f^2(x) \rightarrow \min \quad \text{ili} \quad \sum_{i=1}^n f_i^2(x) \rightarrow \min$$

- Neke poteškoće:

- nepoznata analitička svojstva funkcije  $f$
- globalni minimum

Traženje minimuma

$$x^* = \arg \min_{x \in \mathbb{R}^n} f(x).$$

je potuno analogan problem nalaženju maksimuma funkcije  $f$ .

Traženje maksimuma od  $f$  ekvivalentno je traženju minimuma funkcije  $-f$ :

$$\max_{x \in \mathbb{R}^n} f(x) = \min_{x \in \mathbb{R}^n} -f(x).$$

→ Termin optimizacija ravnopravno se koristi s terminom **minimizacija funkcija**.

Često se minimum funkcije  $f$  ne traži na cijelom području  $\mathbb{R}^n$ , već na nekom podskupu  $D \subset \mathbb{R}^n$ :

$$\min_{x \in D} f(x).$$

→ Problem **minimizacije s ograničenjima**.

- Problem izgleda jednostavniji (zbog manjeg područja minimizacije), ali metode za njegovo rješavanje su složenije nego za polazni problem.

- Uz funkciju  $f$  moramo voditi računa i o rubu područja  $D$  (često definiranog pomoću skupa funkcija).

Primjer: Funkcija  $f(x) = x^2$  ima globalni minimum u 0.

Ako tražimo minimum na intervalu  $[a, b]$ :

minimum funkcije  $f$  jednak 0 ako je  $0 \in [a, b]$  ili

$\min\{f(a), f(b)\}$  ako  $0 \notin [a, b]$ .

- u razmatranje smo trebali uzeti i rubove intervala.

U praksi se često javlja problem optimizacije s posebnim oblikom funkcije  $f$  i skupa  $D$ . Npr.,

-  $D$  presjek poluravnina u  $\mathbb{R}^n$

-  $f$  je linearna funkcija

→ **problem linearnog programiranja.**

-  $f$  kvadratična funkcija (polinom)

→ **problem kvadratičnog programiranja.**

# Jednodimenzionalna minimizacija.

## Metoda zlatnog reza

$$f : \mathbb{R} \rightarrow \mathbb{R}$$

Zadane su tri točke  $a < b < c$

Poznate su vrijednosti funkcije  $f$  u njima:  $f(a)$ ,  $f(b)$  i  $f(c)$

Vrijedi:  $f(b) \leq f(a)$  i  $f(b) \leq f(c)$

- vrijednost funkcije  $f$  je najmanja u srednjoj točki  $b$ .
- točka lokalnog minimuma nalazi u intervalu  $[a, c]$

- Izaberimo novu točku  $x$  iz intervala  $[b, c]$ .
- Pretpostavit ćemo da je  $x \in (b, c)$ .
- Dvije mogućnosti:  $f(x) \geq f(b)$  ili  $f(x) < f(b)$ .
- Ako je  $f(x) \geq f(b)$ 
  - minimum nalazi u  $[a, x]$  (jer je  $f(b) \leq f(a)$  i  $f(b) \leq f(x)$ )
  - novu točku biramo iz trojke  $(a, b, x)$ .
- Ako je  $f(x) < f(b)$ 
  - minimum se nalazi u intervalu  $[b, c]$
  - novu točku biramo iz trojke  $(b, x, c)$ .

Opisani postupak je osnova metode zlatnog reza.

Preostalo je još za razmotriti način izbora nove točke  $x$ .



Neka je  $w$  omjer u kojem  $b$  dijeli interval  $[a, c]$ :

$$w = \frac{b-a}{c-a} \quad \text{i} \quad \frac{c-b}{c-a} = 1 - w.$$

Izaberemo točku  $x \in (b, c)$ . Označimo

$$z = \frac{x-b}{c-a}.$$

- Za  $f(x) \geq f(b)$  minimum je lociran na intervalu širine  $x - a$
- Za  $f(x) < f(b)$  minimum je lociran na intervalu širine  $c - b$ .

**1. zahtjev.** I u jednom i u drugom slučaju širina intervala je jednaka:

$$\begin{aligned} x - a &= c - b, \\ \Rightarrow z + w &= \frac{x - b + b - a}{c - a} = \frac{x - a}{c - a} = \frac{c - b}{c - a} = 1 - w. \\ &\Rightarrow z = 1 - 2w \end{aligned}$$

- točke  $x$  i  $b$  smještene su simetrično s obzirom na središte intervala  $[a, c]$ .

Povoljnim izborom početne točke  $b$  možemo postići da vrijedi

**2. zahtjev.**  $x$  dijeli interval  $[b, c]$  u istom omjeru kao što  $b$  dijeli interval  $[a, c]$ .

$$\Rightarrow \frac{c-b}{c-a} = \frac{c-x}{c-b},$$

$$\Rightarrow 1-w = 1 - \frac{z}{1-w}.$$

$$z = 1 - 2w \Rightarrow w^2 - 3w + 1 = 0.$$

- dva rješenja  $\rightarrow$  zanima nas ono koje je manje od 1:

$$w = \frac{3 - \sqrt{5}}{2} \approx 0.38197.$$

Gornji je broj poznat kao **zlatni broj** pa se metoda s ovakvim izborom nove točke  $x$  naziva metodom **zlatnog reza**.

Uočimo da vrijedi

$$|c^{(i+1)} - a^{(i+1)}| = (1 - w)|c^{(i)} - a^{(i)}| \approx 0.61803|c^{(i)} - a^{(i)}|$$

- metoda konvergira linearno prema točki minimuma  $x^*$ .

Za inicijalno određivanje trojke  $(a^{(0)}, b^{(0)}, c^{(0)})$  krenemo od bilo kojeg para točaka  $a$  i  $b$ . Bez smanjenja općenitosti pretpostavimo da je  $f(a) \geq f(b)$ . Točku  $c$  odredimo tako da  $b$  dijeli interval  $[a, c]$  u zlatnom omjeru. Ukoliko je  $f(b) \leq f(c)$  našli smo traženu trojku. U suprotnom slučaju ponovimo postupak s točkama  $a$  i  $c$  (ili  $b$  i  $c$ ).

Oprez. Općenito nema garancije da ćemo naći početnu trojku.

# Brentova metoda

- Metoda inverzne parabole.
- U blizini minimuma očekujemo da parabola dobro aproksimira funkcijau.
- ista ideja kao kod traženja nultočke.
- U  $n$ -toj iteraciji tri točke:  $a_n, b_n, c_n$ .
- U srednjoj točki je vrijednost funkcije najmanja.
- Nova točka je tjeme interpoliraju 'ce parabole.
- Zadržimo tri točke koje garantiraju postojanje minimuma.
- Konvergira brže nego metoda zlatnog reza.
- Može se kombinirati ove dvije metode: prvo metoda zlatnog reza a zatim Brentova metoda.

# Višedimenzionalna minimizacija

Zadana je funkcija  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Cilj je odrediti

$$\min_{x \in \mathbb{R}^n} f(x).$$

Ideja:

Za neku zadanu točku

$$x_0 \in \mathbb{R}^n$$

odredi točku

$$x_1 \in \mathbb{R}^n$$

takva da je

$$f(x_1) < f(x_0).$$

- postupak ponovimo.

Za točku  $x_i \in \mathbb{R}^n$ , tražimo točku  $x_{i+1} \in \mathbb{R}^n$  za koju je

$$f(x_{i+1}) < f(x_i).$$

Generiramo niz točaka  $x_0, x_1, x_2, \dots$  za koje je

$$f(x_0) > f(x_1) > f(x_2) > \dots$$

Ako je niz  $(f(x_i))_i$  odozdo ograničen, tada postoji  $\lim_i f(x_i)$ .

-  $\lim_i x_i$  ne treba nužno postojati.

Npr., za

$$f(x) = e^{-x}, \quad x_i = i$$

je  $\lim_i f(x_i) = 0$ , no  $\lim_i x_i$  ne postoji.

Za egzistenciju  $\lim_i x_i$  nužno je da postoji  $x_0 \in \mathbb{R}^n$  takav da je skup

$$\{x \mid f(x) \leq f(x_0)\}$$

kompaktan.

Osnovno je pitanje kako izabrati  $x_{i+1}$ .

$s$  - smjer u kojem funkcija  $f$  lokalno pada u okolini točke  $x$ :

$$f(x + \lambda s) < f(x), \quad \text{za mali } \lambda, \quad \lambda \in \mathbb{R}, \quad \lambda > 0.$$

Promatramo funkciju  $g : \mathbb{R} \rightarrow \mathbb{R}$  definiranu s

$$g(\lambda) = f(x + \lambda s).$$

Vrijedi:  $g(0) = f(x)$ .

$f$  glatka funkcija ( $f \in C^1$ )  $\Rightarrow g \in C^1$ .

$f$  pada u smjeru  $s$  oko točke  $x$   $\Leftrightarrow g$  pada u  $0$ , tj.  $g'(0) < 0$ .

Jer

$$g'(\lambda) = \langle \nabla f(x + \lambda s), s \rangle, \quad \Rightarrow \quad g'(0) = \langle \nabla f(x), s \rangle < 0.$$

Definiramo skup

$$D(x) = \{s \mid \langle \nabla f(x), s \rangle < 0\}.$$

Ovaj skup nazivamo **skup smjerova silaska** a njegove elemente **smjerovi silaska**.



Osnova niza minimizacijskih metoda.

Za zadani  $x_i \in \mathbb{R}^n$  definiramo

$$x_{i+1} = x_i + \lambda_i s_i$$

gdje je  $s_i \in D(x_i)$ .

Konstantu  $\lambda_i$  nazivamo **korakom** minimizacije.

Odabiremo je tako da bude zadovoljeno  $f(x_{i+1}) < f(x_i)$ .

To je moguće jer je  $s_i$  smjer silaska.

Izbor smjera silaska ovisi o izboru metode minimizacije.

Različite metode na različite načine određuju izbor smjera silaska.

Veličina koraka minimizacije je bitna za konvergenciju metode.

Nije dovoljno odrediti točku  $x_{i+1}$  koja zadovoljava  $f(x_{i+1}) < f(x_i)$ .

Primjer. Minimizacija funkcije  $f(x) = x^2$ . Izborom

$$x_0 = 2, \quad x_1 = 1.5, \quad \dots, \quad x_i = 1 + \frac{1}{i+1},$$

- niz točaka  $(x_i)_i$  konvergira
- niz padajućih vrijednosti  $(f(x_i))_i$  također konvergira.
- ovi nizovi ne konvergiraju prema točki minimuma, odnosno minimumu funkcije  $f$ .

Jedan od načina izbora koraka  $\lambda_i$  je **maksimalno spuštanje** u smjeru  $s_i$ . Tada je

$$\lambda_i = \arg \min_{\lambda > 0} f(x_i + \lambda s_i).$$

- Ovakav pristup zahtijeva primjenu analitičkih metoda.
- nije jednostavno pri upotrebi računala, naročito ako je funkcija  $f$  složenijeg oblika.

Drugi način je **približno** određivanje  $\lambda_i$  nekom minimizacijskom metodom.

- koristimo metode za jednodimenzionalnu minimizaciju (npr. metodu zlatnog reza ili Brentovu metodu).

Točka  $x_{i+1}$  nije nužno točka (globalnog ili lokalnog) minimuma

u njoj ponavljamo cijeli postupak: izabiremo novi smjer silaska i korak minimizacije.

- korak minimizacije nije nužno izračunati egzaktno ili s prevelikom točnošću
- utrošeno vrijeme ne rezultira s odgovarajućim rezultatom.

Jedan od alternativnih pristupa je **neegzaktno pretraživanje po pravcu**.

- u konačnom broju koraka određuje se  $\lambda_i$
- ne minimizira se  $f(x_i + \lambda s_i)$
- dovoljno se smanjuje vrijednost  $f(x_{i+1})$  u odnosu na  $f(x_i)$  tako da minimizacijska metoda konvergira, tj. da niz  $(x_i)_i$  konvergira točki minimuma funkcije  $f$ .

# Gradijentna metoda

Smjer silaska je:

$$s = -\nabla f(x)$$

$s$  je smjer silaska u točki  $x$ :

$$\langle s, \nabla f(x) \rangle = \langle -\nabla f(x), \nabla f(x) \rangle = -\|\nabla f(x)\|^2 < 0$$

za  $\nabla f(x) \neq 0$ .

$\nabla f(x) = 0$  - zadovoljen kriterij konvergencije (skup smjerova silaska je prazan skup).

- To ne treba značiti da smo došli do točke minimuma.

- ova metoda lokalno bira smjer najbržeg silaska (**metoda najbržeg silaska**, m. najstrmijeg silaska - 'steepest descent method')
- nije najbrža u traženju globalnog minimuma.
- za primjenu metode funkcija  $f$  treba biti glatka ( $f \in C^1$ )

# Modificirana Newtonova metoda

Metoda se zasniva na Newton–Raphsonovoj metodi za rješavanje nelinearne jednadžbe

$$h(x) = 0.$$

Newton–Raphsonova metoda za  $h : \mathbb{R}^n \rightarrow \mathbb{R}^n$ :

$$x_{i+1} = x_i - [H_h(x_i)]^{-1} h(x_i).$$

$H_h$  - Jacobijeva matrica -  $\left( \frac{\partial h_i}{\partial y_j} \right)_{ij}$

Umjesto

$$f(x) \rightarrow \min$$

rješavamo

$$\nabla f(x) = 0.$$

- nužan uvjet minimuma.

- ako je  $f$  konveksna funkcija, tada je taj uvjet i dovoljan.

Newton-Raphsonova metoda generira niz točaka:

$$x_{i+1} = x_i - [\nabla^2 f(x_i)]^{-1} \nabla f(x_i), \quad (1)$$

$\nabla^2 f$  - Hessijan (ili Hessova matrica) funkcije  $f$ :

$$[\nabla^2 f]_{ij} = \frac{\partial^2 f}{\partial y_i \partial y_j}.$$



Da li vrijedi  $f(x_{i+1}) < f(x_i)$ ?

Je li

$$-[\nabla^2 f(x_i)]^{-1} \nabla f(x_i) \in D(x_i)?$$

Neka je  $H$  pozitivno definitna matrica.

$(Hx, x) > 0$  za sve  $x \in \mathbb{R}^n$  i  $x \neq 0$ .

$$\Rightarrow \langle -H\nabla f(x), \nabla f(x) \rangle = -\langle H\nabla f(x), \nabla f(x) \rangle < 0$$

za  $\nabla f(x) \neq 0$ .

$$\Rightarrow -H\nabla f(x) \in D(x).$$

$x^*$  točka minimuma funkcije  $f \Rightarrow \nabla^2 f(x^*)$  je pozitivno definitna.

$\Rightarrow \nabla^2 f(x)$  pozitivno definitna za  $x$  iz neke okoline točke minimuma  $x^*$

$\Rightarrow [\nabla^2 f(x)]^{-1}$  pozitivno definitna

$$\Rightarrow -[\nabla^2 f(x)]^{-1} \nabla f(x) \in D(x)$$

za  $x$  u okolini točke minimuma.

Ovo ne garantira da generirani niz zadovoljava  $f(x_{i+1}) < f(x_i)$ .

**Modificirana Newtonova metoda:**

$$s_i = -[\nabla^2 f(x_i)]^{-1} \nabla f(x_i)$$

$$x_{i+1} = x_i - \lambda_i [\nabla^2 f(x_i)]^{-1} \nabla f(x_i).$$

- korak minimizacije  $\lambda_i$  birmo na jedan od prije opisanih načina.
- modifikacija je uvođenje koraka minimizacije  $\lambda_i$  u Newtonovu metodu.
- nužno je da je funkcija  $f \in C^2$ .

- metoda je primjenjiva samo na području gdje je  $\nabla^2 f$  pozitivno definitna.
- ako  $f$  nije konveksna funkcija, tada je metoda primjenjiva samo u okolini točke minimuma, a ne na cijelom području minimizacije.
- u svakom je koraku minimizacije nužno izračunati Hessijan, te riješiti sustav

$$\nabla^2 f(x_i)(x_{i+1} - x_i) = -\nabla f(x_i)$$

(ovdje nema potrebe za invertiranjem Hessijana).

- radi ubrzanja metode, često se Hessijan ne računa u svakoj iteraciji.
- prednost metode je brža konvergencija generiranog niza  $(x_i)_i$  k točki minimuma.

## Usporedba na kvadratnoj formi

Prednosti modificirane Newtonove metode u odnosu na gradijentnu metodu ilustrirat ćemo na minimizaciji kvadratne forme.

A pozitivno definitna matrica.

Minimizirat ćemo kvadratnu formu

$$f(y) = \frac{1}{2} \langle Ay, y \rangle + \langle b, y \rangle + c.$$

Gradijent funkcije  $f$  je dan s

$$\nabla f(y) = Ay + b,$$

Točka minimuma je:

$$\nabla f(y) = 0 \quad \Rightarrow \quad x^* = -A^{-1}b.$$

Modificirana Newtonova metoda:

$$x_{i+1} = x_i - \lambda_i [\nabla^2 f(x_i)]^{-1} \nabla f(x_i),$$

uz egzakti izbor koraka

$$\lambda_i = \arg \min_{\lambda > 0} f(x_i - \lambda [\nabla^2 f(x_i)]^{-1} \nabla f(x_i))$$

definira iteracije ( $\nabla^2 f(x_i) = A$ )

$$x_{i+1} = x_i - \lambda_i A^{-1} (Ax_i + b) = (1 - \lambda_i)x_i - \lambda_i A^{-1} b.$$

Egzakti izbor koraka daje  $\lambda_0 = 1$ .

Za bilo koji izbor  $x_0$  modificirana Newtonova metoda daje egzaktno rješenje u jednom koraku.

Gradijentna metoda na kvadratnoj formi općenito ne dolazi do minimuma u konačnom broju koraka.

Izaberimo matricu  $A$  oblika

$$A = \begin{bmatrix} \alpha_1 & 0 \\ 0 & \alpha_2 \end{bmatrix},$$

gdje je  $0 < \alpha_1 < \alpha_2$ . Stavimo  $b = 0$  i  $c = 0$ .

Kvadratna forma je

$$f(y) = \frac{1}{2} \langle Ay, y \rangle = \frac{1}{2} (\alpha_1 y_1^2 + \alpha_2 y_2^2),$$

Za  $\alpha_1 = \alpha_2 > 0$  gradijentna metoda u jednom koraku dolazi do točke minimuma

$$x^* = \begin{bmatrix} 0 \\ 0 \end{bmatrix}.$$

Neka je početni vektor

$$x_0 = \begin{bmatrix} x_{0,1} \\ x_{0,2} \end{bmatrix}$$

$x_{0,1} \neq 0$  i  $x_{0,2} \neq 0$ .

(Ako bi jedna komponenta bila 0, tada gradijentna metoda u jednom koraku došli do minimuma.)

Za

$$x_i = \begin{bmatrix} x_{i,1} \\ x_{i,2} \end{bmatrix}$$

egzaktni izbor koraka  $\lambda_i$  daje

$$x_{i+1,1} = \frac{\alpha_2^2(\alpha_2 - \alpha_1)x_{i,1}x_{i,2}^2}{\alpha_1^3x_{i,1}^2 + \alpha_2^3x_{i,2}^2}, \quad x_{i+1,2} = \frac{\alpha_1^2(\alpha_1 - \alpha_2)x_{i,2}x_{i,1}^2}{\alpha_1^3x_{i,1}^2 + \alpha_2^3x_{i,2}^2}.$$

$$(x_{i,1} \neq 0 \text{ i } x_{i,2} \neq 0) \text{ i } (\alpha_1 > \alpha_2 > 0) \Rightarrow x_{i+1,1} \neq 0 \text{ i } x_{i+1,2} \neq 0$$

- indukcijom zaključujemo da niti u jednom koraku ne dolazimo do  
točke minimuma.



# Kvazi-Newtonove metode

## ● Gradijentna metoda

- potrebno samo računanje derivacija (gradijenta)
- ne zahtjeva konveksnost
- do minimuma kvadratne forme ne dolazi u konačnom broju koraka

## ● Newtonova metoda

- potrebno računanje prvih derivacija (gradijenta) i drugih derivacija (Hesijan)
- zahtjeva konveksnost
- do minimuma kvadratne forme ne dolazi u jednom koraku

## ● Kvazi-Newtonove metode

- potrebno samo računanje prvih derivacija (gradijenta)
- ne zahtjeva konveksnost
- do minimuma kvadratne forme dolaze u ? koraka

Pokazali smo:

$H$  pozitivno definitna matrica

$\Rightarrow -H\nabla f(x)$  je smjer silaska.

Promatramo metode za koje je smjer silaska definiran s

$$s_j = -H_j \nabla f(x_j),$$

gdje je  $H_j$  pozitivno definitna matrica.

Ako je

$$H_j = [\nabla^2 f(x_j)]^{-1}$$

to je modificirana Newtonova metoda.

Ideja: matricu  $H_{j+1}$  relativno jednostavno izračunati iz prethodne matrice  $H_j$ .

Nećemo u svakom koraku rješavati sustav

$$\nabla^2 f(x_i) s_i = -\nabla f(x_i),$$

već u svakom koraku množimo

$$H_i \nabla f(x_i),$$

što je daleko brže.

U svakom koraku matricu  $H_{i+1}$  generirat ćemo tako da bude zadovoljeno

$$H_{i+1}(\nabla f(x_{i+1}) - \nabla f(x_i)) = x_{i+1} - x_i.$$

Ovaj uvjet je sličan uvjetu koji zadovoljava Hessijan (iz modificirane Newtonovove metode):

$$\nabla f(x_{i+1}) - \nabla f(x_i) \approx \nabla^2 f(x_{i+1})(x_{i+1} - x_i).$$

Metode koje za izbor smjera silaska koriste

$$s_i = -H_i \nabla f(x_i),$$

pri čemu je

$$H_{i+1}(\nabla f(x_{i+1}) - \nabla f(x_i)) = x_{i+1} - x_i.$$

**kvazi-Newtonove metode.**

(Koristi i naziv **metode promjenjive metrike**).

Za niz matrica koje zadovoljavaju gornji uvjet može se pokazati da vrijedi

$$\lim_{i \rightarrow \infty} H_i = [\nabla^2 f(x^*)]^{-1},$$

gdje je  $x^*$  točka minimuma.

Ovo dodatno opravdava naziv metode.

Sada ćemo vidjeti kako računati  $H_i$  da bi vrijedio uvjet.

Označimo

$$q_i = \nabla f(x_{i+1}) - \nabla f(x_i) \quad \text{i} \quad p_i = x_{i+1} - x_i.$$

Tražimo pozitivno definitnu matricu  $H_{i+1}$  koja zadovoljava

$$H_{i+1}q_i = p_i.$$

$H_{i+1}$  bi trebala biti 'lako izračunljiva' iz matrice  $H_i$ .

Radi jednostavnosti, izbacimo indekse:

$$H = H_i, \quad p = p_i, \quad q = q_i, \quad H' = H_{i+1}.$$

Uvjet sada glasi

$$H'q = p.$$

'Lako izračunljiva':

$$H' = H + E.$$

gdje je  $E$  relativno jednostavna matrica.

Sada smo problem sveli na određivanje matrice  $E$  koja zadovoljava

$$(H + E)q = p,$$

odnosno

$$Eq = p - Hq.$$

$H$  i  $H'$  su simetrične  $\rightarrow E$  simetrična.

Najjednostavnija simetrična matrica  $M$  koja zadovoljava

$$Mx = y$$

za zadane  $x$  i  $y$  ima oblik

$$M = \frac{yy^T}{y^T x} = \frac{yy^T}{\langle y, x \rangle}.$$

$M$  zadovoljava:

$$Mx = \frac{yy^T}{\langle y, x \rangle} x = \frac{1}{\langle y, x \rangle} y(y^T x) = \frac{1}{\langle y, x \rangle} y \langle y, x \rangle = y.$$

Za

$$A = \frac{pp^T}{p^T q}$$

vrijedi  $Aq = p$ , a za

$$B = \frac{Hq(Hq)^T}{(Hq)^T q} = \frac{Hqq^T H}{q^T Hq}$$

vrijedi

$$Bq = \frac{Hq(Hq)^T q}{(Hq)^T q} = Hq.$$

Matrica  $E$  definirana s  $A - B$ :

Matrica  $E$  definirana s:

$$E = A - B = \frac{pp^T}{p^T q} - \frac{Hqq^T H}{q^T Hq}$$

zadovoljava  $Eq = p - Hq$ .

Dakle,  $H_{i+1}$  definirana s

$$H_{i+1} = H_i + \frac{p_i p_i^T}{p_i^T q_i} - \frac{H_i q_i q_i^T H_i}{q_i^T H_i q_i},$$

gdje je

$$q_i = \nabla f(x_{i+1}) - \nabla f(x_i),$$

a

$$p_i = x_{i+1} - x_i,$$

zadovoljava kvazi-Newtonovu jednadžbu.

Ova metoda poznata je pod nazivom '**DFP metoda**' (Davidon, Fletcher, Powell).



## $H_{i+1}$ je dobro definirana.

Nazivnici u definiciji  $H_{i+1}$  su različiti od 0:

$$p_i^T q_i > 0 \quad \text{i} \quad q_i^T H_i q_i > 0$$

ako je  $\nabla f(x_i) \neq 0$ .

Za egzaktan izbor koraka

$$f(x_i + \lambda_i s_i) = \min_{\lambda \geq 0} f(x_i + \lambda s_i)$$

vektori  $s_i$  i  $\nabla f(x_{i+1})$  okomiti.

Jer je  $\lambda_i$  točka minimuma:

$$0 = \frac{d}{d\lambda} f(x_i + \lambda s_i) \Big|_{\lambda=\lambda_i} = \langle \nabla f(x_i + \lambda_i s_i), s_i \rangle = \langle \nabla f(x_{i+1}), s_i \rangle.$$

Ako korak ne biramo egzaktno, već nekom numeričkom metodom, gornja jednakost neće vrijediti.

U tom slučaju je jednoznačno određen  $\mu_i \neq 0$  za koji je

$$\langle \nabla f(\mathbf{x}_{i+1}), \mathbf{s}_i \rangle = \mu_i \langle \nabla f(\mathbf{x}_i), \mathbf{s}_i \rangle.$$

Za egzaktn izbor koraka je  $\mu_i = 0$ , dok za neegzaktn izbor očekujemo da je  $\mu_i \approx 0$ .

Primjenom gornjih oznaka dobivamo

$$\begin{aligned} p_i^T q_i &= \langle \nabla f(x_{i+1}) - \nabla f(x_i), x_{i+1} - x_i \rangle \\ &= \langle \nabla f(x_{i+1}) - \nabla f(x_i), \lambda_i s_i \rangle \\ &\quad \vdots \\ &= -\lambda_i(\mu_i - 1) \langle \nabla f(x_i), H_i \nabla f(x_i) \rangle. \end{aligned}$$

$H_i$  pozitivno definitna i  $\nabla f(x_i) \neq 0 \rightarrow p_i^T q_i > 0$

Uz uvjet da je  $\mu_i < 1$ .

Ovo nije veliko ograničenje jer kod neegzaktog izbora koraka je  $\mu_i \approx 0$ .

$H_i$  pozitivno definitna  $\rightarrow$

$$q_i^T H_i q_i \geq 0.$$

= 0 samo ako je  $q_i = 0$  odnosno

$$\nabla f(x_{i+1}) = \nabla f(x_i).$$

Tada je

$$\langle \nabla f(x_{i+1}), s_i \rangle = \langle \nabla f(x_i), s_i \rangle$$

te je  $\mu_i = 1$ .

Znači,  $\mu_i < 1$  garantira da je

$$q_i^T H_i q_i > 0.$$

Ovime smo pokazali da je matrica  $H_{i+1}$  dobro definirana.

$H_i$  je pozitivno definitna  $\rightarrow$  simetrična.

Iz definicije matrice  $H_{i+1}$  jasno je da je i ona simetrična, no pozitivna definitnost nije tako očita.

Uzmimo proizvoljan vektor  $y \in \mathbb{R}^n$ ,  $y \neq 0$ .

$H_i$  pozitivno definitna  $\rightarrow$

$$H = LL^T,$$

gdje je  $L$  regularna donjetrokutasta matrica.

Uz oznake  $u = L^T y$  i  $v = L^T q_i$ , izlazi

$$\langle H_{i+1} y, y \rangle = u^T u + \frac{(p^T y)^2}{p^T q} - \frac{(v^T u)^2}{v^T v}.$$

Kako je  $p^T q > 0$ , vrijedi

$$\frac{(p^T y)^2}{p^T q} \geq 0.$$

S druge strane vrijedi

$$u^T u - \frac{(v^T u)^2}{v^T v} = \|u\|^2 - \frac{\langle u, v \rangle^2}{\|v\|^2} = \frac{\|u\|^2 \|v\|^2 - \langle u, v \rangle^2}{\|v\|^2} \geq 0.$$

Posljedica Schwartzove nejednakosti.

Ovime smo pokazali da je

$$\langle H_{i+1} y, y \rangle \geq 0.$$

Sada ćemo pokazati da je

$$\langle H_{i+1} y, y \rangle \neq 0.$$

Kad bi bilo  $\langle H_{i+1} y, y \rangle = 0$ , onda bi moralo vrijediti i

$$\|u\|^2 \|v\|^2 - \langle u, v \rangle^2 = 0,$$

$\Rightarrow$   $u$  i  $v$  kolinearni:  $u = \alpha v$ .

No, tada je  $y = \alpha q$ , a  $\alpha \neq 0$  jer je  $y \neq 0$ .

Nadalje, zbog  $\langle H_{i+1}y, y \rangle = 0$  treba vrijediti i

$$0 = \frac{(p^T y)^2}{p^T q} = \frac{\langle p, \alpha q \rangle^2}{\langle p, q \rangle} = \alpha^2 \langle p, q \rangle.$$

U kontradikciji s prije dokazanim:

$$0 < p^T q = \langle p, q \rangle.$$

Ovime smo dokazali sljedeći teorem.

### Teorem

*Neka je  $H_i$  pozitivno definitna matrica i  $\nabla f(x_i) \neq 0$ , te neka je korak minimizacije određen tako da je  $\mu_i < 1$ . Tada je matrica  $H_{i+1}$  dobro definirana i pozitivno definitna te zadovoljava kvazi-Newtonovu jednadžbu.*

# Generalizacija

DFP metoda može se generalizirati složenijim izborom matrice  $H_{i+1}$ .

Neka je

$$q_i = \nabla f(x_{i+1}) - \nabla f(x_i) \quad \text{i} \quad p_i = x_{i+1} - x_i.$$

Za parametre

$$\gamma_i > 0, \quad \theta_i \geq 0$$

definiramo rekurziju oblika

$$H_{i+1} = \Psi(\gamma_i, \theta_i, H_i, p_i, q_i),$$



gdje je funkcija  $\Psi$  zadana s

$$\begin{aligned} \Psi(\gamma, \theta, H, p, q) = & \gamma H + \left(1 + \gamma \theta \frac{q^T H q}{p^T q}\right) \frac{p p^T}{p^T q} \\ & - \gamma \frac{(1 - \theta)}{q^T H q} H q \cdot q^T H \\ & - \frac{\gamma \theta}{p^T q} (p q^T H + H q p^T). \end{aligned}$$

$\Psi$  je definirana jedino ako je  $p^T q \neq 0$  i  $q^T H q \neq 0$ .

$H_{i+1}$  je dobivena iz  $H_i$  dodavanjem korekcije reda ne većeg od 2 matrici  $\gamma_i H_i$ :

$$\text{rang}(H_{i+1} - H_i) \leq 2.$$

Stoga se kaže da se radi o metodi reda dva.

Metoda obuhvaća nekoliko poznatih metoda kao specijalne slučajeve:

- (a)  $\gamma_i = 1, \theta_i = 0$ ; prije opisana 'DFP metoda';
- (b)  $\gamma_i = 1, \theta_i = 1$ ; Broyden, Fletcher, Goldfarb  
i Shannova metoda reda 2 ('BFGS metoda');
- (c)  $\gamma_i = 1, \theta_i = p_i^T q_i / (p_i^T q_i - q_i^T H_i q_i)$ ; Broydenova simetrična metoda  
reda jedan.

Za ove metode vrijedi teorem analogan teoremu za DFP metodu.

### Teorem

*Ako postoji  $i \geq 0$  za koji je  $H_i$  pozitivno definitna matrica,*

$$\nabla f(x_i) \neq 0$$

*i ako je korak minimizacije određen tako da je  $\mu_i < 1$ , tada je za sve  $\gamma_i > 0$  i  $\theta_i \geq 0$  matrica  $H_{i+1} = \Psi(\gamma_i, \theta_i, H_i, p_i, q_i)$  dobro definirana i pozitivno definitna te zadovoljava kvazi-Newtonovu jednadžbu.*

# Kvazi-Newtonove metode i kvadratna forma

Kvazi-Newtonove metode dolaze do točke minimuma kvadratne funkcije u najviše  $n$  koraka.

Uz uvjet da je korištena egzaktna minimizacija pri izboru koraka minimizacije.

## Teorem

*Neka je*

$$f(x) = \frac{1}{2} \langle Ax, x \rangle + \langle b, x \rangle + c$$

*kvadratna forma gdje je  $A$   $n \times n$  pozitivno definitna matrica.*

*Nadalje, neka je  $x_0 \in \mathbb{R}^n$  i  $H_0$   $n \times n$  pozitivno definitna matrica.*

*Ako je za minimizaciju  $f(x)$  korištena kvazi-Newtonova metoda definirana uz egzaktan izbor koraka s početnim vrijednostima  $x_0$  i  $H_0$ ,*

tada generirani nizovi

$$(x_i)_i, (H_i)_i, (\nabla f(x_i))_i, (p_i)_i = (x_{i+1} - x_i)_i \text{ i } (q_i)_i = (\nabla f(x_{i+1}) - \nabla f(x_i))_i$$

imaju sljedeća svojstva:

- (a) Postoji najmanji indeks  $m \leq n$  za koji je  $x_m = x^* = -A^{-1}b$  minimum od  $f$  i  $\nabla f(x_m) = 0$ .
- (b)  $\langle p_i, q_k \rangle = \langle p_i, Ap_k \rangle = 0$  za  $0 \leq i \neq k \leq m-1$ ,  $\langle p_i, q_i \rangle > 0$  za  $0 \leq i \leq m-1$ . (Vektori  $p_i$  su  $A$ -konjugirani.)
- (c)  $\langle p_i, \nabla f(x_k) \rangle = 0$  za sve  $0 \leq i < k \leq m$ .
- (d)  $H_k q_i = \gamma_{i,k} p_i$  za  $0 \leq i < k \leq m$ , gdje je

$$\gamma_{i,k} = \begin{cases} \gamma_{i+1} \gamma_{i+2} \cdots \gamma_{k-1}, & \text{za } i < k-1, \\ 1 & \text{za } i = k-1 \end{cases}$$

(e) Ako je  $m = n$  tada dodatno vrijedi

$$H_m = H_n = PDP^{-1}A^{-1},$$

gdje je  $D = \text{diag}(\gamma_{0,n}, \gamma_{1,n}, \dots, \gamma_{n-1,n})$ ,  $P = (p_0, p_1, \dots, p_{n-1})$ .

Ako je  $i \gamma_i = 1$  tada je  $H_n = A^{-1}$ .

**Dokaz.** Promatrajmo sljedeće uvjete za proizvoljan indeks  $l \geq 0$ :

$$\langle p_i, q_k \rangle = \langle p_i, Ap_k \rangle = 0 \quad \text{za} \quad 0 \leq i \neq k \leq l-1,$$

$$\langle p_i, q_i \rangle > 0 \quad \text{za} \quad 0 \leq i \leq l-1,$$

$H_l$  je pozitivno definitna,

$$\langle p_i, q_k \rangle = 0 \quad \text{za sve} \quad 0 \leq i < k \leq l,$$

$$H_k q_i = \gamma_{i,k} p_i \quad \text{za} \quad 0 \leq i < k \leq l.$$

Ako su ovi uvjeti zadovoljeni za  $l$  te ako je  $\nabla f(x_l) \neq 0$  tada ćemo pokazati da su uvjeti zadovoljeni i za  $l+1$ .

⋮



# Konvergencija minimizacijskih metoda

Skup smjerova silaska

$$D(x) = \{s \mid \langle \nabla f(x), s \rangle < 0\}.$$

$s \in D(x)$  - vrijednost funkcije  $f$  smanjuje u smjeru  $s$  u nekoj okolini točke  $x$ .

Neka je  $\| \cdot \|$  standardna Euklidska norma ( $\| \cdot \| = \| \cdot \|_2$ ).

Za  $\gamma \in \mathbb{R}$ ,  $0 < \gamma \leq 1$ , promatrajmo skup

$$D(\gamma, x) = \{s \in \mathbb{R}^n \mid \|s\| = 1, \langle \nabla f(x), s \rangle \leq -\gamma \|\nabla f(x)\|\}.$$

Uvjet

$$\langle \nabla f(x), s \rangle \leq -\gamma \|\nabla f(x)\|,$$

zbog  $\|s\| = 1$ , možemo zapisati kao

$$\frac{\langle \nabla f(x), -s \rangle}{\|\nabla f(x)\| \|s\|} \geq \gamma$$

ako je  $\|\nabla f(x)\| \neq 0$ .

Ako je  $\|\nabla f(x)\| = 0$ , uvjet je uvijek zadovoljen.

Označimo s  $\Theta$  kut između vektora  $\nabla f(x)$  i  $-s$ :

$$\langle \nabla f(x), -s \rangle = \cos \Theta \|\nabla f(x)\| \|s\|.$$

Uvjet glasi  $\cos \Theta \geq \gamma$ .

→ promatramo samo one smjerove silaska koji zatvaraju dovoljno mali kut s vektorom  $-\nabla f(x)$ .



Koliko je taj kut malen, definira koeficijent  $\gamma$ .

Sljedeća lema pokazuje pod kojim uvjetima postoji skalar  $\lambda$  i (smjer silaska)  $s \in \mathbb{R}^n$  za koje je  $f(x + \lambda s) < f(x)$ .

### Lema

*Neka je  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  funkcija čiji je gradijent  $\nabla f(x)$  definiran i neprekidan za sve  $x \in V(\bar{x})$  u okolini  $V(\bar{x})$  točke  $\bar{x}$ . Nadalje, pretpostavimo da je  $\nabla f(\bar{x}) \neq 0$  i neka je  $1 \geq \gamma > 0$ . Tada postoji okolina  $U(\bar{x}) \subseteq V(\bar{x})$  od  $\bar{x}$  i broj  $\mu > 0$  takav da je*

$$f(x + \lambda s) \leq f(x) - \frac{\lambda \gamma}{4} \|\nabla f(\bar{x})\|$$

za sve  $\lambda \in [0, \mu]$ .

Promatrimo sljedeću metodu za minimizaciju diferencijabilne funkcije  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ .

### Metoda 1.

(a) Izaberi brojeve  $\gamma_i, \sigma_i, i = 0, 1, 2, \dots$  koji zadovoljavaju

$$\sup_i \gamma_i \leq 1, \quad \inf_i \gamma_i > 0, \quad \inf_i \sigma_i > 0,$$

i izaberi početnu točku  $x_0 \in \mathbb{R}^n$ .

(b) Za  $i = 0, 1, 2, \dots$  izaberi (proizvoljan)  $s_i \in D(\gamma_i, x_i)$  i postavi

$$x_{i+1} := x_i + \lambda_i s_i,$$

gdje je  $\lambda_i \in [0, \sigma_i \|\nabla f(x_i)\|]$  takav da je

$$f(x_{i+1}) = \min_{0 \leq \lambda \leq \sigma_i \|\nabla f(x_i)\|} f(x_i + \lambda s_i).$$

Metoda 1 poopćava velik broj metoda.

Npr., kod gradijentne metode je

$$s_i = -\frac{\nabla f(x_i)}{\|\nabla f(x_i)\|}.$$

Budući da je je

$$\langle \nabla f(x_i), s_i \rangle = \left\langle \nabla f(x_i), -\frac{\nabla f(x_i)}{\|\nabla f(x_i)\|} \right\rangle = -\|\nabla f(x_i)\|,$$

uvijek je zadovoljen uvjet

$$\langle \nabla f(x_i), -s_i \rangle \geq 1 \cdot \|\nabla f(x_i)\|.$$

Možemo uzeti  $\gamma_i = 1$ .

Parametar  $\sigma_i$  kontrolira interval po kojem minimiziramo funkciju

$$g_i(\lambda) := f(x_i + \lambda s_i).$$

- Traženje minimuma po neograničenom intervalu ( $\lambda \in [0, \infty)$ ) je često zahtjevno, ponekad i nemoguće.
- Jednostavnije: na segmentu  $[0, \sigma_i \|\nabla f(x_i)\|]$
- $\sigma_i$  definiramo proizvoljno.
- Međi  $\sigma_i$  - manja (bolja) vrijednost funkcije  $f(x_i + \lambda s_i)$  ali i veći interval (dulji postupak - bilo analitički, bilo numerički).
- Manji  $\sigma_i$  - manji interval i brža jednodimenzionalnu minimizaciju u  $i$ -tom koraku, ali veća vrijednost funkcije  $f$  u novoj točki  $x_{i+1}$ .

Konvergenciju niza  $(x_i)_i$  dobivenovog metodom 1 opisuje sljedeći teorem.

### Teorem

*Neka je  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  i neka je  $x_0 \in \mathbb{R}^n$  izabran da vrijedi*

- (a)  $K := \{x \mid f(x) \leq f(x_0)\}$  je kompaktan,*
- (b)  $f$  je neprekidno diferencijabilna na nekom otvorenom skupu koji sadrži  $K$ .*

*Tada za svaki niz  $(x_i)_i$  definiran Metodom 1 vrijedi*

- (a)  $x_i \in K$  za sve  $i = 0, 1, 2, \dots$   
 $(x_i)_i$  ima barem jedno gomilište  $\bar{x}$  u  $K$ .*
- (b) Svako gomilište niza  $(x_i)_i$  je stacionarna točka od  $f$ ;  $\nabla f(\bar{x}) = 0$ .*

## Dokaz.

**1. Gomilište.** Iz definicije niza  $(x_i)_i$  direktno slijedi da je niz  $(f(x_i))_i$  monoton:

$$\cdots \leq f(x_{i+1}) \leq f(x_i) \leq \cdots \leq f(x_1) \leq f(x_0),$$

te posebno vrijedi  $f(x_i) \leq f(x_0)$ , tj.  $x_i \in K$ .

$K$  kompaktan  $\Rightarrow (x_i)_i$  ima barem jedno gomilište u  $K$ .

Prva tvrdnja dokazana.

**2. Stacionarna točka.** Neka je  $(x_i)_i$  niz u  $K$  i  $\bar{x}$  njegovo gomilište.

BSO  $\bar{x} = \lim_i x_i$  (tj. uzimamo konvergentan podniz).

Pretpostavit ćemo suprotno:

$$\nabla f(\bar{x}) \neq 0.$$

**Skica.** Neka je

$$\gamma := \inf_i \gamma_i > 0 \quad \text{i} \quad \sigma := \inf_i \sigma_i > 0.$$

Prema Lemi, postoji okolina  $U(\bar{x})$  od  $\bar{x}$  u kojoj je

$$f(x + \lambda s) \leq f(x) - \lambda \frac{\gamma}{4} \|\nabla f(x)\|$$

(lema) i

$$\|\nabla f(x_i)\| \geq \frac{1}{2} \|\nabla f(\bar{x})\| > 0.$$

(neprekidnost gradijenta) za dovoljno veliki  $i$ .

Definira se  $M$

$$M := \min \left\{ \mu, \frac{1}{2} \sigma \|\nabla f(\bar{x})\| \right\}.$$

Sada je

$$\begin{aligned}
 f(x_{i+1}) &= \min_{0 \leq \lambda \leq \mu_i} f(x_i + \lambda s_i) \\
 &\leq \min_{0 \leq \lambda \leq M} f(x_i + \lambda s_i) \\
 &\leq f(x_i + M s_i) \\
 &\leq f(x_i) - M \frac{\gamma}{4} \|\nabla f(x_i)\| \\
 &\leq f(x_i) - M \frac{\gamma}{8} \|\nabla f(\bar{x})\|.
 \end{aligned}$$

Ako označimo

$$\varepsilon := M \frac{\gamma}{8} \|\nabla f(\bar{x})\| > 0.$$

vrijedi  $f(x_{i+1}) \leq f(x_i) - \varepsilon$  za sve dovoljno velike  $k$ .

$$\Rightarrow \lim_i f(x_i) = -\infty.$$

Kontradikcija s činjenicom da je  $(f(x_i))_i$  odozdo ograničen s  $f(\bar{x})$ .



- Korak (b) u Metodi 1 je minimizacija funkcije

$$g(\lambda) := f(x_i + \lambda s_i)$$

na segmentu  $[0, \sigma_i \|\nabla f(x_i)\|]$ .

- **pretraživanje po pravcu** (engl. 'line search').
- Uvjeti Teorema zahtijevaju pronalaženje egzaktnog minimuma.
- Težak a (često nemoguć) zadatak.
- Numerička jednodimenzionalna minimizacija (npr. metoda zlatnog reza, Brentova metoda) može dati dosta točnu aproksimaciju minimuma.
- Značajnu količina računanja.
- Drugi pristup: 'neegzaktno pretraživanje po pravcu' - konačni postupak minimizacije.

## Metoda 2.

(a) Izaberu se brojevi  $\gamma_i, \sigma_i, i = 0, 1, 2, \dots$  koji zadovoljavaju

$$\sup_i \gamma_i \leq 1, \quad \inf_i \gamma_i > 0, \quad \inf_i \sigma_i > 0,$$

i početna točka  $x_0 \in \mathbb{R}^n$ .

(b) Za  $i = 0, 1, 2, \dots$  izračuna se  $x_{i+1}$  iz  $x_i$  na sljedeći način:

( $\alpha$ ) Izabere se proizvoljan  $s_i \in D(\gamma_i, x_i)$ , definira

$$\rho_i := \sigma_i \|\nabla f(x_i)\|, \quad \phi_i(\lambda) := f(x_i + \lambda s_i),$$

i odredi najmanji cijeli broj  $j \geq 0$  takav da je

$$\phi_i(\rho_i 2^{-j}) \leq \phi_i(0) - \rho_i 2^{-j} \frac{\gamma_i}{4} \|\nabla f(x_i)\|.$$

( $\beta$ ) Odredi se  $\bar{i} \in \{0, 1, \dots, j\}$  takav da je  $\phi_i(\rho_i 2^{-\bar{i}})$  minimalan i definira

$$x_{i+1} := x_i + \lambda_i s_i$$

gdje je  $\lambda_i = \rho_i 2^{-\bar{i}}$ .

- Uočimo da  $j$  iz Metode 2 postoji.
- Metoda 2 je konvergentna kao i Metoda 1:

## Teorem

*Pod pretpostavkom Teorema za Metodu 1, svaki niz  $(x_i)_i$  dobiven Metodom 2 zadovoljava tvrdnje Teorema za Metodu 1.*

# Konvergencija modificirane Newtonove metode

U modificiranoj Newtonovoj metodi smjer silaska  $s_i$  zadan je s

$$\bar{s}_i = -[\nabla^2 f(x_i)]^{-1} \nabla f(x_i), \quad s_i := \frac{\bar{s}_i}{\|\bar{s}_i\|}.$$

Radi jednostavnosti, označimo

$$H := [\nabla^2 f(x_i)]^{-1} \quad \text{i} \quad g := \nabla f(x_i),$$

pa je

$$s_i = -\frac{Hg}{\|Hg\|}.$$

Pokušajmo odrediti  $\gamma_i$  za koji je

$$\langle \nabla f(x_i), s_i \rangle \geq \gamma_i \|\nabla f(x_i)\|,$$

tj.

$$\langle g, Hg \rangle \geq \gamma_i \|g\| \|Hg\|.$$

Ako je  $f \in C^2$  tada je  $\nabla^2 f(x_i)$  simetrična matrica, te vrijedi

$$\lambda_{\max} \|x\|^2 \geq \langle \nabla^2 f(x_i) x, x \rangle \geq \lambda_{\min} \|x\|^2, \quad \forall x \in \mathbb{R}^n,$$

$\lambda_{\max}$  - najveća

$\lambda_{\min}$  - najmanja svojstvena vrijednost.

Za euklidsku normu  $\| \cdot \|$  vrijedi:

$$\|\nabla^2 f(x_i)\| = \max\{|\lambda_{\max}|, |\lambda_{\min}|\}.$$

Ako je matrica  $\nabla^2 f(x_i)$  **pozitivno definitna**, onda je

$$\lambda_{\max} > \lambda_{\min} > 0,$$

te je

$$\|\nabla^2 f(x_i)\| = \lambda_{\max}.$$

U okolini minimuma je  $\nabla^2 f(x_i)$  **pozitivno definitna**.

$\lambda$  svojstvena vrijednost od  $\nabla^2 f(x_i)$   
 $\Rightarrow 1/\lambda$  svojstvena vrijednost od  $[\nabla^2 f(x_i)]^{-1}$ .

Sada je

$$\|[\nabla^2 f(x_i)]^{-1}\| = \frac{1}{\lambda_{\min}}.$$

$\rightarrow H = [\nabla^2 f(x_i)]^{-1}$  zadovoljava:

$$\frac{1}{\lambda_{\min}} \|x\|^2 \geq \langle Hx, x \rangle \geq \frac{1}{\lambda_{\max}} \|x\|^2, \quad \forall x \in \mathbb{R}^n.$$

Nadalje vrijedi

$$\|Hx\| \leq \|H\| \|x\|.$$

Iskoristivši ove nejednakosti, dobivamo

$$\langle g, Hg \rangle \geq \frac{1}{\lambda_{\max}} \|g\|^2 \quad \text{i} \quad \gamma_i \|g\| \|Hg\| \leq \gamma_i \frac{1}{\lambda_{\min}} \|g\|^2.$$

Ukoliko je zadovoljeno

$$\frac{1}{\lambda_{\max}} \geq \gamma_i \frac{1}{\lambda_{\min}},$$

tada je

$$\langle g, Hg \rangle \geq \frac{1}{\lambda_{\max}} \|g\|^2 \geq \gamma_i \frac{1}{\lambda_{\min}} \|g\|^2 \geq \gamma_i \|g\| \|Hg\|.$$

Prvi uvjet možemo zapisati u obliku

$$\gamma_i \leq \frac{\lambda_{\min}}{\lambda_{\max}} = \frac{1}{\|\nabla^2 f(x_i)\| \|\left[\nabla^2 f(x_i)\right]^{-1}\|} = \frac{1}{\text{cond}(\nabla^2 f(x_i))}.$$

Ako je matrica singularna, tada je

$$\text{cond}(\nabla^2 f(x_i)) = \infty \quad \text{i} \quad \gamma_i = 0$$

te nemamo zadovoljen uvjet konvergencije.

Ako je  $\nabla^2 f$  regularna u minimumu  $\bar{x}$   
- (onda je automatski i pozitivno definitna),  
tada možemo staviti

$$\gamma_i = \frac{1}{\text{cond}(\nabla^2 f(x_i))}$$

te je zbog regularnosti

$$\inf_i \gamma_i = \frac{1}{\sup_i \text{cond}(\nabla^2 f(x_i))} > 0.$$

- Modificirana Newtonova metoda je konvergentna ako je  $f$  konveksna ( $\nabla^2 f$  pozitivno definitna).
- Jači uvjet od npr. uvjeta konvergencije gradijentne metode.
- Metoda brže konvergira ukoliko su ispunjeni uvjeti konvergencije.



## Primjer.

Ilustracija DFP metode, BFGS metode i gradijentne metode.  
minimiziramo

$$f(x, y) = 100 \left[ y^3(3 - x) - x^2(3 + x) \right]^2 + \frac{(2 + x)^2}{1 + (2 + x)^2}.$$

Minimum se postiže u

$$\bar{x} = 2 \quad \text{i} \quad \bar{y} = 0.8942719099\dots, \quad f(\bar{x}, \bar{y}) = 0,$$

Startne vrijednosti:

$$x_0 = 0.1, \quad y_0 = 4.2$$

i

$$H_0 = I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

Za DFP i BFGS metodu.

Korištena je ista metoda za pretraživanje po pravcu i isti kriterij zaustavljanja  $\epsilon = 10^{-11}$ .

	BFGS	DFP	Gradijentna m.
$N$	54	47	201
$F$	374	568	1248
$\epsilon$	$\leq 10^{-11}$	$\leq 10^{-11}$	0.7

$N$  - broj iteracija

$F$  - broj poziva funkcije  $f$ .

$$\epsilon = \|\nabla f(x_N), y_N\|$$