

dr.sc. Rudolf Scitovski, redoviti profesor
Odjel za matematiku, Sveučilište u Osijeku

Metode optimizacije

Pripreme za predavanja iz kolegija *Metode optimizacije*
poslijediplomski studij matematike
Odsjek za matematiku, Univerzitet u Tuzli
Svibnja, 2005.

Sadržaj

1. Konveksne funkcije	1
1.1. Konveksni skupovi	1
1.2. Konveksne funkcije	1
1.3. Lokalni minimum	3
1.4. Primjeri i motivacija	5
2. Metode jednodimenzionalne minimizacije	7
2.1. Metoda zlatnog reza	7
2.2. Metoda parabole	11
2.3. Newtonova metoda tangentni	13
3. Gradijentne metode	14
3.1. Gradijentna metoda i metoda najbržeg spusta	15
4. Metode Newtonovog tipa	20
4.1. Newtonova metoda	20
4.1.1. Svojstva Newtonove metode	21
4.2. Quasi–Newtonove metode	25
4.2.1. Sustavi nelinearnih jednadžbi	25
4.2.2. Minimizacija glatke funkcije	30
4.2.3. Korekcije koje čuvaju pozitivnu definitnost	33
4.3. Inverzne korekcije	36
5. Seminarski radovi	38

1. Konveksne funkcije

1.1. Konveksni skupovi

Definicija 1.1. Kažemo da je skup $K \subseteq \mathbb{R}^n$ **konveksan** ako za bilo koje dvije točke $x_1, x_2 \in K$ sadrži i segment određen tim točkama, tj.

$$x_1, x_2 \in K \Rightarrow \lambda x_1 + (1 - \lambda)x_2 \in K \quad \forall \lambda \in [0, 1].$$

Zadatak 1.1. Pokažite da konveksan skup sadrži svaku konveksnu kombinaciju od konačno svojih točaka, tj.

$$(x_1, \dots, x_n \in K) \quad \wedge \quad \left(\lambda_1, \dots, \lambda_n \geq 0, \quad \sum_{i=1}^n \lambda_i = 1 \right) \Rightarrow \sum_{i=1}^n \lambda_i x_i \in K$$

Definicija 1.2. Kažemo da je skup $K \subseteq \mathbb{R}^n$ **strog konveksan** ako

$$x_1, x_2 \in K, \quad x_1 \neq x_2 \Rightarrow \lambda x_1 + (1 - \lambda)x_2 \in \text{Int } K \quad \forall \lambda \in (0, 1).$$

Definicija 1.3. Kažemo da je skup $K \subseteq \mathbb{R}^n$ **jako konveksan** ako postoji takva konstanta $\gamma > 0$, tako da

$$(x_1, x_2 \in K) \wedge (\|y\| \leq \gamma \|x_2 - x_1\|^2) \Rightarrow \frac{x_1 + x_2}{2} + y \in K.$$

Zadatak 1.2. Pokažite da je svaki jako konveksan skup ujedno i strogo konveksan, ali obrat ne vrijedi.

1.2. Konveksne funkcije

Definicija 1.4. Kažemo da je funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}$ **konveksna** ako vrijedi

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y) \tag{1.1}$$

$$\forall x, y \in \mathbb{R}^n \quad \forall \lambda \in [0, 1].$$

Definicija 1.5. Kažemo da je funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}$ **strog konveksna** ako $\forall x, y \in \mathbb{R}^n$, $x \neq y$ vrijedi

$$f(\lambda x + (1 - \lambda)y) < \lambda f(x) + (1 - \lambda)f(y) \tag{1.2}$$

$$\forall \lambda \in (0, 1).$$

Definicija 1.6. Kažemo da je funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}$ **jako konveksna** ako postoji takav realni broj $\gamma > 0$ da vrijedi

$$f\left(\frac{x+y}{2}\right) \leq \frac{1}{2}(f(x) + f(y)) - \gamma \|x - y\|^2 \tag{1.3}$$

$$\forall x, y \in \mathbb{R}^n.$$

Primjedba 1.1. Može se pokazati da da je funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}$ jako konveksna ako postoji realan broj $\kappa > 0$ tako da bude

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y) - \kappa \lambda(1 - \lambda) \|x - y\|^2 \tag{1.4}$$

$$\forall x, y \in \mathbb{R}^n \quad \forall \lambda \in [0, 1].$$

Naime, ako u (1.4) stavimo $\lambda = \frac{1}{2}$ i $\gamma = \frac{1}{4}\kappa$, dobivamo (1.4).

Primjer 1.1. Neka je $\mathcal{A} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ simetrični linearni operator. Tada je kvadratna forma $f(x) := \frac{1}{2}(\mathcal{A}x, x)$ konveksna funkcija onda i samo onda ako je $\mathcal{A} \geq 0$, tj. ako su sve svijestvene vrijednosti nenegativne – označimo ih s $\lambda_1 \geq \dots \geq \lambda_n \geq 0$. Kako je (vidi primjerice [9], [10])

$$\lambda_n\|x\|^2 \leq (\mathcal{A}x, x) \leq \lambda_1\|x\|^2 \text{ za sve } x \in \mathbb{R}^n,$$

može se pokazati da vrijedi

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y) - \frac{1}{2}\lambda_n\lambda(1 - \lambda)\|x - y\|^2$$

Dakle, ako je \mathcal{A} pozitivno definitan ($\lambda_n > 0$), f je jako konveksna funkcija

Primjer 1.2. Funkcija $f : \mathbb{R}^2 \rightarrow \mathbb{R}^2$, $f(x_1, x_2) = x_1^2 + x_2^2$ je jako konveksna funkcija, a funkcija $g : \mathbb{R}^2 \rightarrow \mathbb{R}^2$, $g(x_1, x_2) = x_1^2$ je konveksna, ali nije jako konveksna ($\lambda_1 = 1, \lambda_2 = 0$). Kako izgledaju plohe ovih funkcija?

Zadatak 1.3. Pokažite da je svaka jako konveksna funkcija ujedno i konveksna, ali da obrat ne vrijedi.

Uvedimo sljedeće oznake. Za neprekidno diferencijabilnu funkciju $f : \mathcal{D} \rightarrow \mathbb{R}^n$, $\mathcal{D} \subset \mathbb{R}^n$ ($f \in C^1(\mathcal{D})$) s

$$f'(x) = \left[\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right]$$

označit ćemo derivaciju funkcije f u točki $x = (x_1, \dots, x_n)^T \in \mathcal{D}$, a s

$$\nabla f(x) := (f'(x))^T$$

gradijent funkcije f u točki x .

Ako je f dvostruko neprekidno diferencijabilna ($f \in C^2(\mathcal{D})$) za $x \in \mathcal{D}$ s

$$\nabla^2 f(x) = (f''(x)) := \left(\frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right)_{i,j=1,\dots,n}$$

označit ćemo Hesseovu matricu (hesijan) funkcije f u točki x . Primijetite da je $\nabla^2 f$ simetrična matrica.

Lema 1.1. Ako je $f \in C^1(K)$ konveksna funkcija na konveksnom skupu K , onda vrijedi

$$(f'(y), x - y) \leq f(x) - f(y) \leq (f'(x), x - y) \quad \forall x, y \in K. \quad (1.5)$$

Dokaz. Oduzimajući $f(y)$ na obje strane nejednakosti (1.1) dobivamo

$$f(y + \lambda(x - y)) - f(y) \leq \lambda(f(x) - f(y)).$$

Primjenjujući na lijevoj strani Lagrangeov teorem o srednjoj vrijednosti

$$f(y + \lambda(x - y)) - f(y) = (f'(y + \vartheta\lambda(x - y)), \lambda(x - y)), \quad \vartheta \in (0, 1),$$

nakon dijeljenja nejednakosti s λ i stavljanja $\lambda \rightarrow +0$, dobivamo lijevu stranu tražene nejednakosti. Pokušajte na sličan način dobiti i desnu stranu nejednakosti.



Lema 1.2. Neka je $K \subseteq \mathbb{R}^n$ konveksan skup. Funkcija $f \in C^1(K)$ je jako konveksna onda i samo onda ako postoji $m > 0$ takav da je

$$(f'(y) - f'(x), y - x) \geq m\|y - x\|^2 \quad \text{za sve } x, y \in K. \quad (1.6)$$

Teorem 1.1. Neka je $K \subseteq \mathbb{R}^n$ konveksan skup takav da je $\text{Int } K \neq \emptyset$. Funkcija $f \in C^2(K)$ je jako konveksna onda i samo onda ako postoji $m > 0$ takav da je

$$(f''(x)y, y) \geq m\|y\|^2 \quad \text{za sve } x \in K \text{ i za sve } y \in R^n. \quad (1.7)$$

1.3. Lokalni minimum

Definicija 1.7. Neka je $f : \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subset \mathbb{R}^n$ proizvoljna funkcija. Kažemo da je $x^* \in \mathcal{D}$ točka lokalnog minimuma funkcije f na skupu \mathcal{D} ako postoji okolina \mathcal{O} točke x^* , tako da je $f(x) \geq f(x^*)$ za sve $x \in \mathcal{O} \cap \mathcal{D}$. Točku x^* zovemo točka strogog lokalnog minimuma ako postoji okolina \mathcal{O} točke x^* , tako da vrijedi $f(x) > f(x^*)$ za sve $x \in \mathcal{O} \cap \mathcal{D} \setminus \{x^*\}$. Točku x^* zovemo točkom globalnog minimuma funkcije f ako je $f(x) \geq f(x^*)$ za sve $x \in \mathcal{D}$.

Teorem 1.2. Ako je $f : K \rightarrow \mathbb{R}$, $K \subseteq \mathbb{R}^n$ jako konveksna neprekidna funkcija na zatvorenom konveksnom skupu K , onda:

(i) funkcija f je ograničena odozdo na K , tj. $f^* := \inf f(x) > -\infty$,

(ii) postoji jedinstvena točka $x^* \in K$, takva da bude $f(x^*) = f^*$,

(iii) skup $M(y) = \{x \in K : f(x) \leq f(y)\}$ je ograničen za svaki $y \in K$.

Lema 1.3. Da bi konveksna funkcija $f \in C^1(K)$ dostigla svoj infimum na konveksnom skupu $K \subseteq \mathbb{R}^n$ u točki $x^* \in K$ nužno je i dovoljno da bude:

$$(f'(x^*), x - x^*) \geq 0 \quad \text{za sve } x \in K. \quad (1.8)$$

Ako je $x^* \in \text{Int } K$, onda je ovaj uvjet ekvivalentan jednakosti $f'(x^*) = 0$.

Lema 1.4. neka je $x_0 \in \mathbb{R}^n$ proizvoljna točka i $f \in C^2(\mathbb{R}^n)$ jako konveksna funkcija. Tada je skup $Y = \{x \in \mathbb{R}^n : f(x) \leq f(x_0)\}$ zatvoren, ograničen i jako konveksan.

Primjer 1.3. Razmotrimo kvadratnu funkciju $f : \mathbb{R}^2 \rightarrow \mathbb{R}$,

$$f(x_1, x_2) = x_1^2 + x_1 x_2 + x_2^2.$$

Ova funkcija je pozitivno definitna kvadratna forma zadana pozitivno definitnim simetričnim linearnim operatorom \mathcal{A} sa svojstvenim vrijednostima $\lambda_1 = 3, \lambda_2 = 1$, kome u bazi (e_1, e_2) pripada simetrična kvadratna matrica $A = \begin{bmatrix} 1 & 1/2 \\ 1/2 & 1 \end{bmatrix}$. Prema Primjeru 1.1. ova funkcija je jako konveksna na čitavom \mathbb{R}^2 , a prema Lemi 1.3. i Teoremu 1.2. postoji jedinstvena točka minimuma x^* , koja se može pronaći tako da riješimo jednadžbu $f'(x) = 0$. Matrica drugih derivacija (Hessijan) u toj točki mora biti pozitivno definitna. Lako s može vidjeti da je točka minimuma ove funkcije $x^* = (0, 0)$.

Ako prepostavimo da je $f : \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subset \mathbb{R}^n$ dovoljno puta diferencijabilna funkcija definirana na otvorenom skupu $\mathcal{D} \subset \mathbb{R}^n$, onda možemo koristiti jednostavne nužne i dovoljne uvjete egzistencije lokalnog minimuma, koji su dobro razrađeni u elementarnoj analizi. Točku $x^* \in \mathcal{D}$ za koju vrijedi $\nabla f(x^*) = 0$ zvat ćemo stacionarna točka funkcije f . Sljedeći teorem daje nužne uvjete lokalnog minimuma.

Teorem 1.3. *Neka je $f \in C^1(\mathcal{D})$ neprekidno diferencijabilna funkcija definirana na otvorenom skupu $\mathcal{D} \subset \mathbb{R}^n$ i neka je x^* točka lokalnog minimuma od f . Tada vrijedi*

- (i) x^* je stacionarna točka funkcije f , tj. $\nabla f(x^*) = 0$,
- (ii) ako je $f \in C^2(\mathcal{D})$, njezin hesijan $\nabla^2 f(x^*)$ u točki x^* je pozitivno semidefinitna matrica.

Dokaz. (i) Prepostavimo da je $f \in C^1(\mathcal{D})$ i da x^* nije stacionarna točka funkcije f , tj. $\nabla f(x^*) \neq 0$ i definirjmo funkciju

$$\varphi(t) := f(x^* - t\nabla f(x^*)), \quad t \in \mathbb{R}.$$

Za maleni $|t|, t \in \mathbb{R}$ funkcija φ je neprekidno diferencijabilna funkcija za koju vrijedi

$$\varphi'(0) = -f'(x^*)\nabla f(x^*) = -\|\nabla f(x^*)\|_2^2$$

Kako je $\nabla f(x^*) \neq 0$, mora biti $\varphi'(0) < 0$. Zato postoji $\epsilon > 0$, takav da bude $\varphi(\epsilon) < \varphi(0)$. To znači da x^* nije točka lokalnog minimuma od f , što je u suprotnosti s polaznom prepostavkom.

(ii) Prepostavimo da je $f \in C^2(\mathcal{D})$ i da $\nabla^2 f(x^*)$ nije pozitivno semidefinitna matrica. To znači da postoji vektor $d \in \mathbb{R}^n$, $d \neq 0$, takav da je $d^T \nabla^2 f(x^*) d < 0$. Prema Taylorovom teoremu, a zbog činjenice da je $\nabla f(x^*) = 0$, za maleni $t > 0$ postoji $\tau \in (0, t)$, takav da bude

$$f(x^* - td) = f(x^*) + \frac{1}{2}t^2 d^T \nabla^2 f(x^* - \tau d) d.$$

Odavde za dovoljno maleni $t > 0$ zbog neprekidnosti od $\nabla^2 f$ vrijedi $f(x^* - td) < f(x^*)$. To bi značilo da x^* nije točka lokalnog minimuma od f , što je u suprotnosti s polaznom prepostavkom. ♣

Sljedeći teorem daje dovoljne uvjete lokalnog minimuma.

Teorem 1.4. *Neka je $f \in C^2(\mathcal{D})$, $\mathcal{D} \subset \mathbb{R}^n$ otvoren skup, a $x^* \in \mathcal{D}$ stacionarna točka od f u kojoj je hesijan $\nabla^2 f(x^*)$ pozitivno definitan. Tada je x^* točka strogog lokalnog minimuma funkcije f .*

Dokaz. Kako je $x^* \in \text{Int } \mathcal{D}$ i $f'(x^*) = 0$, prema Taylorovom teoremu za svaki dovoljno maleni vektor $d \in \mathbb{R}^n$ vrijedi

$$f(x^* + d) = f(x^*) + \frac{1}{2}d^T \nabla^2 f(x^* + \vartheta d)d, \quad \vartheta \in (0, 1).$$

Kako je $\nabla^2 f(x^*)$ pozitivno definitan, postoji $\lambda > 0$, takav da za sve $d \in \mathbb{R}^n$ vrijedi

$$d^T \nabla^2 f(x^*) d \geq \lambda d^T d.$$

Zbog toga je

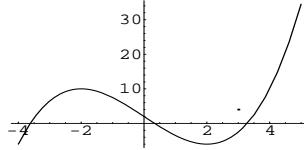
$$\begin{aligned} f(x^* + d) &= f(x^*) + \frac{1}{2}d^T \nabla^2 f(x^*) d - \frac{1}{2}d^T (\nabla^2 f(x^*) - \nabla^2 f(x^* + \vartheta d)) d, \\ &\geq f(x^*) + \frac{1}{2}(\lambda - \|\nabla^2 f(x^*) - \nabla^2 f(x^* + \vartheta d)\|) d^T d \end{aligned}$$

pri čemu je korištena Cauchyjeva nejednakost i svojstvo kompatibilnosti vektorskih i matričnih normi. Zbog $\lambda > 0$ i neprekidnosti od $\nabla^2 f$ slijedi $f(x^* + d) > f(x^*)$ za sve dovoljno malene vektore $d \neq 0$. Po Definiciji 1.7. To znači da je x^* točka strogog lokalnog minimuma funkcije f . ♣

1.4. Primjeri i motivacija

Najprije ćemo navesti nekoliko primjera u kojima se pojavljuje problem minimizacije funkcije jedne ili više varijabli, koji će nam kasnije poslužiti kao test-primjeri kod raznih metoda minimizacije.

Primjer 1.4. Treba izračunati L_2 udaljenost točke $T_0(3, 4)$ do kubne parabole $q(x) = .5x^3 - 6x + 2$ (vidi Sliku 1).



Slika 1. Udaljenost točke do krivlje

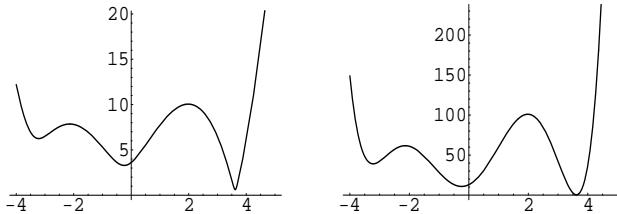
L_2 udaljenost točke $T_0(x_0, y_0)$ do neke točke $T(x, f(x))$ na grafu funkcije q zadana je s

$$d_2(x) = d_2(T_0(x_0, y_0), T(x, q(x))) = \sqrt{(x - x_0)^2 + (q(x) - y_0)^2},$$

pa je određivanje udaljenosti točke $T_0(x_0, y_0)$ do grafa funkcije q zadane na intervalu $[a, b]$ problem određivanja globalnog minimuma funkcije d_2 na segmentu $[a, b]$ (vidi Sliku 2.a).

Budući da je funkcija $x \mapsto \sqrt{x}$ monotono rastuća funkcija, onda se naš problem svodi na određivanje globalnog minimuma funkcije

$$f(x) = (x - x_0)^2 + (q(x) - y_0)^2.$$



Slika 2. a) Funkcija d_2 b) Funkcija f

Dakle, u ovom primjeru radi se o problemu minimizacije "glatke" (višestruko derivabilne) funkcije jedne varijable (polinoma 6. stupnja) – tzv. problem jednodimenzionalne minimizacije. Iz slike se može uočiti da ova funkcija ima tri lokalna minimuma od kojih je jedan ujedno i globalni minimum.

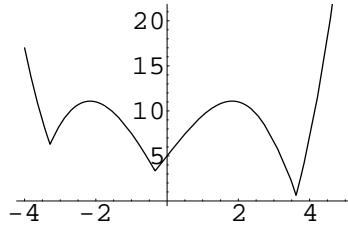
Primjer 1.5. Treba izračunati L_1 udaljenost točke $T_0(3, 4)$ do kubne parabole $q(x) = .5x^3 - 6x + 2$ (vidi Sliku 1).

L_1 udaljenost točke $T_0(x_0, y_0)$ do neke točke $T(x, f(x))$ na grafu funkcije q zadana je s

$$d_1(x) = d_1(T_0(x_0, y_0), T(x, q(x))) = |x - x_0| + |q(x) - y_0|,$$

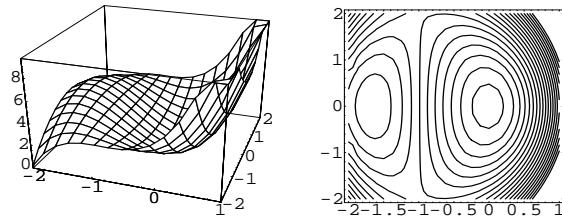
pa je određivanje udaljenosti točke $T_0(x_0, y_0)$ do grafa funkcije q zadane na intervalu $[a, b]$ problem određivanja globalnog minimuma funkcije d_1 na segmentu $[a, b]$ (vidi Sliku 3.). Dakle, i u ovom primjeru

radi se također o problemu jednodimenzionalne minimizacije, ali ovaj puta je minimizirajuća funkcija nediferencijabilna (ima "špineve"). Također iz slike se može uočiti da ova funkcija ima tri lokalna minimuma od kojih je jedan ujedno i globalni minimum.



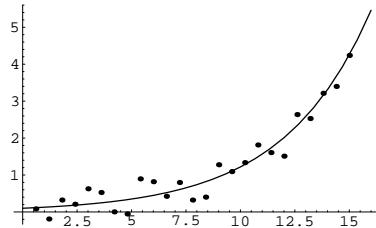
Slika 3 Funkcija d_1

Primjer 1.6. *Funkcija $f(x_1, x_2) = 2x_1^3 + x_1x_2^2 + 5x_1^2 + x_2^2$ ima četiri stacionarne točke: $T_1(0, 0)$, $T_2(-\frac{5}{3}, 0)$, $T_3(-1, 2)$, $T_4(-1, -2)$. Može se pokazati da je T_1 točka minimuma, T_2 točka maksimuma, a da su T_3 i T_4 sedlaste točke. Na Slici 4 prikazana je ploha i contourPlot ove funkcije.*



Slika 4 Ploha i ContourPlot funkcije $f(x_1, x_2) = 2x_1^3 + x_1x_2^2 + 5x_1^2 + x_2^2$

Primjer 1.7. *Zadani su podaci mjeranja (x_i, y_i) $i = 1, \dots, m$. Treba odrediti optimalne parametre b^*, c^* eksponencijalne funkcije-modela $f(t; b, c) = b e^{ct}$, tako da suma kvadrata izmjerениh od teoretskih vrijednosti bude minimalna (vidi Sliku 4).*



Slika 5 Podaci i najbolja L_2 eksponencijalna funkcija-model

Optimalne parametre b^*, c^* eksponencijalne funkcije-modela $f(t; b, c) = b e^{ct}$ odredit ćemo tako da minimiziramo funkcional

$$F(b, c) = \frac{1}{2} \sum_{i=1}^m (b e^{cx_i} - y_i)^2.$$

Primijetite da se u ovom slučaju radi o problemu minimizacije "glatke" (višestruko derivabilne) funkcije dviju varijabli – tzv. problem višedimenzionalne minimizacije.

2. Metode jednodimenzionalne minimizacije

Zadana je funkcija $f : [a, b] \rightarrow \mathbb{R}$, koja općenito nije derivabilna i koja u nepoznatoj točki x^* postiže strogi lokalni minimum. Problem pronalaženja točke x^* ne možemo riješiti primjenom metoda koje se zasnivaju na poznavanju derivacije funkcije f . Razmotrit ćemo dvije jednostavne metode za određivanje minimuma takve funkcije, metodu **zlatnog reza** i metodu **parabole**. Pretpostavimo još da poznajemo graf funkcije f . Od dodatnih svojstava na funkciju $f : [a, b] \rightarrow \mathbb{R}$ zahtijevat ćemo tzv. svojstvo **unimodalnosti** (vidi primjerice [10]).

Definicija 2.1. Za funkciju $f : [a, b] \rightarrow \mathbb{R}$ kažemo da je unimodalna na intervalu $[a, b]$ ako f postiže minimum u nekoj točki $x^* \in [a, b]$ i ako za svake dvije točke $x_1 < x_2$ vrijede svojstva:

- i) ako je $x_1 < x_2 \leq x^*$ tada je $f(x_1) > f(x_2)$ tj. funkcija je padajuća,
- ii) ako je $x^* \leq x_1 < x_2$ tada je $f(x_1) < f(x_2)$ tj. funkcija je rastuća.

Primijetite da poznavanjem grafa funkcije f lako možemo provjeriti svojstvo unimodalnosti funkcije f na intervalu $[a, b]$.

2.1. Metoda zlatnog reza

Neka je $f : [a, b] \rightarrow \mathbb{R}$ zadana funkcija te neka je $[a_{k-1}, b_{k-1}] \subset [a, b]$ interval takav da je $f : [a_{k-1}, b_{k-1}] \rightarrow \mathbb{R}$ unimodalna na $[a_{k-1}, b_{k-1}]$. Pretpostavimo nadalje da je $x^* \in [a_{k-1}, b_{k-1}]$ nepoznata točka u kojoj se postiže lokalni minimum funkcije f na segmentu $[a_{k-1}, b_{k-1}]$. Vrijednost funkcije izračunat ćemo u dvije točke $y_k < z_k$, gdje su $y_k, z_k \in [a_{k-1}, b_{k-1}]$ za koje vrijede sljedeći uvjeti

- I. y_k i z_k jednako su udaljeni od krajeva segmenta $[a_{k-1}, b_{k-1}]$ tj. vrijedi

$$y_k - a_{k-1} = b_{k-1} - z_k,$$

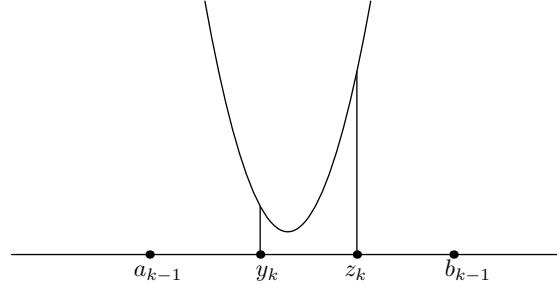
- II. y_k je "bliže" lijevom rubu segmenta $[a_{k-1}, b_{k-1}]$, a z_k je "bliže" desnom rubu segmenta $[a_{k-1}, b_{k-1}]$, tj. za neki $c \in (0, \frac{1}{2})$ (koji ćemo kasnije precizno odrediti) vrijedi

$$y_k = a_{k-1} + c(b_{k-1} - a_{k-1}), \quad (2.1)$$

$$\begin{aligned} z_k &= b_{k-1} - c(b_{k-1} - a_{k-1}) \\ &= a_{k-1} + (1 - c)(b_{k-1} - a_{k-1}) \\ &= a_{k-1} + b_{k-1} - y_k \end{aligned} \quad (2.2)$$

III. Mogu pri tome nastupiti dva slučaja

Slučaj 1. (vidi *Sliku 6.*)



Slika 6. Slučaj kada vrijedi $f(y_k) \leq f(z_k)$

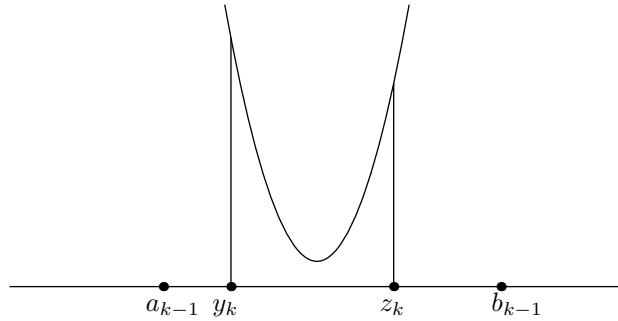
Ako je $f(y_k) \leq f(z_k)$ zbog unimodalnosti funkcije f je $x^* \in [a_{k-1}, z_k]$ pa stavljamo

$$\begin{aligned} a_k &:= a_{k-1} \\ b_k &:= z_k \\ x_k &:= y_k. \end{aligned}$$

Sada je x_k nova aproksimacija točke x^* , koja je bolja od prethodne x_{k-1} .

Slučaj 2. (vidi *Sliku 7.*) Ako je $f(y_k) > f(z_k)$ zbog unimodalnosti funkcije f je $x^* \in [y_k, b_{k-1}]$, pa stavljamo

$$\begin{aligned} a_k &:= y_k \\ b_k &:= b_{k-1} \\ x_k &:= z_k. \end{aligned}$$



Slika 7. Slučaj kada vrijedi $f(y_k) > f(z_k)$

Sada smo došli do segmenta $[a_k, b_k]$ za koji očito vrijedi $[a_k, b_k] \subset [a_{k-1}, b_{k-1}]$. Opisani postupak možemo iterirati sve dok lijevi i desni kraj segmenta u kojem se nalazi točka x^* ne postanu dovoljno blizu. Kako vrijednost funkcije ne bismo u svakom intervalu morali računati u dvije točke proširit ćemo III. i to na sljedeći način. U *slučaju 1.* (kada je $f(y_k) \leq f(z_k)$) stavljamo još

$$z_{k+1} := y_k, \quad (2.3)$$

a y_{k+1} računamo iz formule (2.1) (zamjenom indeksa k s indeksom $k + 1$). Primijetite da smo ovdje pretpostavili još jedan uvjet, a to je da točka y_k leži "bliže" točki z_k nego točka a_{k-1} , što će biti zadovoljeno dobrim izborom broja c . U slučaju 2. (kada je $f(y_k) > f(z_k)$) stavljamo još

$$y_{k+1} := z_k, \quad (2.4)$$

a z_{k+1} računamo iz formule (2.2) (zamjenom indeksa k s indeksom $k + 1$). Ovdje smo još pretpostavili da točka z_k leži "bliže" točki y_k nego točka b_{k-1} . Preostaje još jedino problem kako odrediti odgovarajući $c \in (0, \frac{1}{2})$, ako uopće postoji. Promatrajmo slučaj 1. iz III. Iz relacije (2.2) zamjenom indeksa k s indeksom $k + 1$ slijedi

$$z_{k+1} = a_k + (1 - c)(b_k - a_k). \quad (2.5)$$

Redom iz relacije (2.3) i (2.1) i (2.2) imamo $z_{k+1} = y_k = a_{k-1} + c(b_{k-1} - a_{k-1}) = a_{k-1} + (z_k - a_{k-1})\frac{c}{1-c}$. Kako je u ovom slučaju $a_k = a_{k-1}$ i $b_k = z_k$ slijedi

$$z_{k+1} = a_k + \frac{c}{1-c}(a_k - b_k). \quad (2.6)$$

Uspoređuju relacije (2.5) i (2.6) dobivamo

$$\frac{c}{1-c} = 1 - c,$$

odakle zbog $c \in (0, \frac{1}{2})$ slijedi $c = \frac{3-\sqrt{5}}{2}$.

Provjerimo, zadovoljava li ovakav c uvjet da točka y_k leži "bliže" točki z_k nego točka a_{k-1} . Prema (2.1) i (2.2) imamo $z_k - y_k = a_{k-1} + (1 - c)(b_{k-1} - a_{k-1}) - a_{k-1} - c(b_{k-1} - a_{k-1}) = (1 - 2c)(b_{k-1} - a_{k-1}) = (\sqrt{5} - 2)(b_{k-1} - a_{k-1})$, dok je $y_k - a_{k-1} = a_{k-1} + c(b_{k-1} - a_{k-1}) - a_{k-1} = c(b_{k-1} - a_{k-1}) = \frac{3-\sqrt{5}}{2}(b_{k-1} - a_{k-1})$. Sada je očito $z_k - y_k < y_k - a_{k-1}$.

Zadatak 2.1. Analizirajući slučaj 2. iz III. pokažite da je također $c = \frac{3-\sqrt{5}}{2}$.

Primjedba 2.1. Promatramo li segment $[a, b]$ te u njemu odredimo točku $y = a + c(b - a)$, gdje je $c = \frac{3-\sqrt{5}}{2}$ kažemo da točka y dijeli segment $[a, b]$ u omjeru zlanog reza.

Zadatak 2.2. Dokažite da vrijedi $\frac{b-a}{b-y} = \frac{b-y}{y-a}$.

Primjedba 2.2. Metoda zlatnog reza specijalan je slučaj Fibbonacijske metode više o tome vidi u [10], [21], [23].

Izgradimo sada odgovarajući Mathematica – modul za određivanje točke x^* u kojoj se postiže minimum zadane funkcije f .

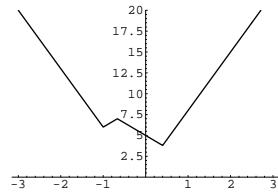
```
ln[1]:=ZlatniRez[f_, a1_, b1_, eps_] := Module[{c, i, y, z, x, a, b},
  a = a1; b = b1;
  c = N[(3 - Sqrt[5])/2];
  y = a + c(b - a);
  z = a + b - y;
  If[f[y] <= f[z], a = a, a = y];
  If[f[y] <= f[z], b = z, b = b];
  i = 1;
  Print["Iteracija      a      b      x      f[x]      greska"];
  While[b - a > eps,
    If[f[y] <= f[z], z = y; f[z] = f[y]; y = a + c(b - a); x = y, y = z;
     f[y] = f[z]; z = a + b - z; x = z];
```

```

If[f[y] <= f[z], a = a, a = y];
If[f[y] <= f[z], b = z, b = b];
greska = b - a;
Print[i, "      ", a, "      ", b, "      ", x, "      ", f[x], "      ", greska];
i++]

```

Primjer 2.1. Zadana je funkcija $f : \mathbb{R} \rightarrow \mathbb{R}$ zadana s $f(x) = 5|x+1| - |3x+2| + |5x-2|$.



Graf funkcije $f(x) = 5|x+1| - |3x+2| + |5x-2|$

Primjenom Mathematica-modula `ZlatniRez[f,a,b,eps]` odredit ćemo točku minimuma funkcije f tako da je $a = 0.1$, $b = 2$ i $\text{eps} = 10^{-3}$.

```

ln[2]:=f[t_]:=5 Abs[t+1]-3 Abs[3 t+2]+Abs[5 t-2];
a=0.1; b=2; eps=10^(-3);
ZlatniRez[f,a,b,eps];

```

Dobivamo sljedeću tablicu:

Iteracija	a	b	x	f(x)	greška
1	0.1	0.825735	0.54829	4.8397	0.725735
2	0.1	0.548529	0.377206	3.86838	0.448529
3	0.271323	0.548529	0.271323	4.166838	0.277206
4	0.271323	0.442646	0.442646	4.09852	0.171323
5	0.336762	0.442646	0.336762	3.98971	0.105883
6	0.377206	0.442646	0.402202	3.81541	0.0654395
7	0.377206	0.41765	0.41765	3.92355	0.0404438
8	0.392654	0.41765	0.392654	3.82204	0.0249957
9	0.392654	0.408103	0.408103	3.85672	0.0154482
10	0.392654	0.402202	0.398555	3.86433	0.0095475
11	0.396301	0.402202	0.396301	3.81111	0.00590068
12	0.398555	0.402202	0.399948	3.80016	0.00364682
13	0.398555	0.400809	0.400809	3.80566	0.00225386
14	0.399416	0.400809	0.399416	3.80175	0.00139296
15	0.399416	0.400277	0.400277	3.80194	0.000860897

Tablica 1. Iterativni postupak minimizacije funkcije f primjenom Mathematica-modula `ZlatniRez[f,a,b,eps]`

Nakon 15 iteracija dobivamo da je $x^* \approx 0.400277$.

2.2. Metoda parabole

Razmotrit ćemo još jednu jednostavnu metodu za određivanje točke x^* u kojoj se postiže minimum zadane funkcije $f : [a, b] \rightarrow \mathbb{R}$, $x^* \in [a, b]$. Odredimo najprije realni broj $c \in \langle a, b \rangle$ tako da je $f(a) > f(c)$ i $f(c) < f(b)$. Za točke $A = (a, f(a))$, $C = (c, f(c))$ i $B = (b, f(b))$ sa zadanim svojstvom postoji jedinstveni polinom drugog stupnja $P_2(x) = \alpha x^2 + \beta x + \gamma$ čiji graf (kvadratna parabola) prolazi zadanim točkama (vidi primjerice [18]). Koeficijente α, β i γ polinoma P_2 potražit ćemo primjenom programskog paketa *Mathematica*:

```
In[1]:=p2=InterpolatingPolynomial[{{a, f[a]}, {b, f[b]}, {c, f[c]}}, x];
koeficijent=CoefficientList[p2];
alfa=koeficijent[[3]];
beta=koeficijent[[2]];
gama=koeficijent[[1]]
```

Dobivamo

$$\begin{aligned}\alpha &= \frac{f(a)}{(a-c)(a-b)} + \frac{f(c)}{(c-a)(c-b)} + \frac{f(b)}{(b-a)(b-c)}, \\ \beta &= -\left(\frac{bf(a)+cf(a)}{(a-c)(a-b)} + \frac{af(c)+bf(c)}{(c-a)(c-b)} + \frac{af(b)+cf(b)}{(b-a)(b-c)}\right), \\ \gamma &= \frac{cbf(a)}{(a-c)(a-b)} + \frac{abf(c)}{(c-a)(c-b)} + \frac{acf(b)}{(b-a)(b-c)}.\end{aligned}$$

Nakon što smo odredili koeficijente polinoma P_2 , odredit ćemo apscisu tjemena parabole. Ona glasi

$$x_T = \frac{-\beta}{2\alpha} = -\frac{b^2 f(a) - c^2 f(a) - a^2 f(b) + c^2 f(b) + a^2 f(c) - b^2 f(c)}{2(-bf(a) + cf(a) + af(b) - cf(b) - af(c) + bf(c))}. \quad (2.7)$$

Zadatak 2.3. Algebarski izvedite formulu (2.7).

Točku x_T uzimamo kao prvu aproksimaciju točke x^* . Zadamo li točnost ε iterativni postupak nastavljamo na sljedeći način: Ako je $|f(x_T) - P_2(x_T)| < \varepsilon$ uzimamo $x^* = x_T$ i postupak je završen. U suprotnom između četiri broja a, c, b, x_T za novi c biramo onaj u kojem funkcija f poprima najmanju vrijednost (primijetite da to mogu biti samo x_T ili c), dok za novi a i b uzimamo prvi najveći broj lijevo od novog c odnosno prvi najmanji broj desno od novog c . Novi x_T sada dobivamo primjenom formule (2.7). Izgradimo odgovarajući *Mathematica-modul*.

```
In[2]:=Parabola[f_, a1_, b1_, c1_, epsilon_] :=
Module[{c, b, a, x1, x2, x3, p2, x, pogreska, xT, xt, greska, lista,
sortiranlista, pozicija},
c = c1; b = b1; a = a1;
p2[x_, x1_, x2_, x3_] :=
InterpolatingPolynomial[{{x1, f[x1]}, {x2, f[x2]}, {x3, f[x3]}}, x];
tjeme[x1_, x2_, x3_] := -(x2^2 f[x1] - x3^2 f[x1] - x1^2 f[x2] +
x3^2 f[x2] + x1^2 f[x3] - x2^2 f[x3])/2 (-x2 f[x1] + x3 f[x1] +
x1 f[x2] - x3 f[x2] - x1 f[x3] + x2 f[x3]);
pogreska[xt_, x1_, x2_, x3_] := Abs[f[xt] - p2[xt, x1, x2, x3]];
xT = tjeme[a, b, c] // N;
greska = pogreska[xT, a, b, c];
Print["Iteracija      a      c      b      xT      f[xT]      greska"];
s1[1] = Plot[{f[x], p2[x, a, b, c]}, {x, a-0.5 (b-a), b+0.5 (b-a)},
PlotStyle -> {Hue[0.1], {Thickness[0.015], Hue[0.6]}},
DisplayFunction -> Identity];
i = 1;
While[Abs[f[xT] - p2[xT, a, b, c]] > epsilon,
lista = {a, b, c, xT};
If[f[c] > f[xT], xT, c];
sortiranlista = Sort[lista];
```

```

pozicija = Flatten[Position[sortiranlista,c]][[1]];
b=sortiranlista[[pozicija + 1]];
a = sortiranlista[[pozicija - 1]];
xT = tjeme[a, b, c] // N;
greska = pogreska[xT, a, b, c];
Print[i, " ", a, " ", c, " ", b, " ", xT, " ", f[xT], " ", greska];
sl[i+1] = Plot[{f[x], p2[x, a, b, c]}, {x, a-0.5 (b-a), b+0.5 (b-a)},
PlotStyle -> {Hue[0.1], {Thickness[0.015], Hue[0.6]}},
DisplayFunction -> Identity];
i++];
]

```

Primjer 2.2. Zadana je funkcija $f : \mathbb{R} \rightarrow \mathbb{R}$ zadana s $f(x) = 5|x+1| - |3x+2| + |5x-2|$ iz Primjera 2.1.. Primjenom Mathematica-modula Parabola[f,a,b,c,eps] odredit ćemo točku minimuma funkcije f tako da je $a = -2$, $c = 0$, $b = 2$ i $\varepsilon = 10^{-3}$. Primjetite da je zadovoljena relacija $f(a) > f(c) & f(c) < f(b)$.

```

In[2]:=f[x_]:=5 Abs[x+1]-Abs[3 x+2]+Abs[5 x-2];
a=-2; c=0; b=2; eps=10^(-3);
Parabola[f,a,b,c,eps];

```

Dobivamo sljedeću tablicu:

Iteracija	a	c	b	x_T	$f(x_T)$	greška
1	-0.111111	0	2	0.340278	3.97917	0.0582051
2	0	0.340278	2	0.481337	4.36936	0.486099
3	0	0.340278	0.481337	0.295353	4.11394	0.158951
4	0.295353	0.340278	0.481337	0.366197	3.90441	0.0569293
5	0.340278	0.366197	0.481337	0.38319	3.85043	0.0365175
6	0.366197	0.38319	0.481337	0.395534	3.81342	0.0260649
7	0.38319	0.395534	0.481337	0.404892	3.83245	0.0293058
8	0.38319	0.395534	0.404892	0.395589	3.81323	0.000164881

Tablica 2. Iterativni postupak minimizacije funkcije f primjenom Mathematica-modula
Parabola[f,a,b,c,eps]

Nakon 8 iteracija dobivamo da je $x^* \approx 0.395589$. Za svaku iteraciju isrtajmo još graf funkcije f i grafove odgovarajućih kvadratnih parabola.

```

In[3]:=slike=Partition[Table[sl[j],{j,i}],3];
Show[GraphicsArray[slike],DisplayFunction->$DisplayFunction];

```

Složimo li graf funkcije f i grafove odgovarajućih kvadratnih parabola jednu ispod druge primjenom naredbe

```

In[4]:=Table>Show[sl[j], DisplayFunction -> $DisplayFunction], {j, i}];

```

te selektiramo vanjsku ćeliju i pritisnemo tipke Ctrl+Y dobivamo animaciju funkcije f i grafova odgovarajućih kvadratnih parabola.

Primjedba 2.3. U primjenama često se koristi tzv. Brentova metoda za jednodimenzionalnu minimizaciju (vidi Brent, [8]) koja se zasniva kombinaciji metode zlatnog reza i metode parbole.

2.3. Newtonova metoda tangenti

Pretpostavimo da je $f \in C^2[a, b]$ i da je $x^* \in (a, b)$ točka lokalnog minimum funkcije f . To znači da je $f'(x^*) = 0$ i $f''(x^*) > 0$. I obrnuto, ako je $f'(x^*) = 0$ i $f''(x^*) > 0$, onda funkcija f u točki x^* postiže lokalni minimum.

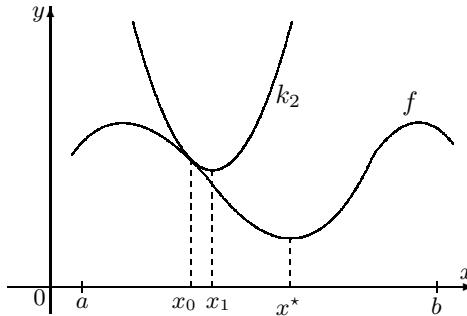
Iz navedenog slijedi da se lokalni minimum x^* funkcije f može tražiti tako da najprije lokaliziramo interval u kome funkcija postiže lokalni minimum. Nakon toga na tom intervalu riješimo jednadžbu $f'(x) = 0$ primjenom neke od metoda za rješavanje nelinearne jednadžbe (vidi primjerice [18]). Točka x^* za koju vrijedi $f'(x^*) = 0$ naziva se **stacionarna točka** funkcije f .

Ako za rješavanje jednadžbe $f'(x) = 0$ primijenimo Newtonovu metodu uz odgovarajući izbor početne aproksimacije x^0 (vidi primjerice [18]), dobivamo iterativnu metodu koju u literaturi možemo naći pod nazivom **Newtonova metoda za jednodimenzionalnu minimizaciju**

$$x_{n+1} = x_n - \frac{f'(x_n)}{f''(x_n)}, \quad n = 0, 1, \dots \quad (2.8)$$

Istu formulu mogli bi dobiti i na sljedeći način. Najprije u okolini točke $x_0 \in \Omega$) funkciju f aproksimiramo kvadratnom funkcijom pomoću Taylorove formule

$$k_2(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{1}{2}f''(x_0)(x - x_0)^2$$



Newtonova metoda

Sljedeću aproksimaciju x_1 tražene točke x^* birat ćemo tako da odredimo minimum navedene kvadratne funkcije k_1 :

$$x_1 = x_0 - \frac{f'(x_0)}{f''(x_0)}.$$

Ponavljujući postupak dobivamo niz $x_0, x_1, \dots, x_n, \dots$ zadan rekursivnom formulom (4.3), koji uz neke uvjete (vidi primjerice DENNIS (1996)) konvergira prema x^* .

U tu svrhu sagradit ćemo *Mathematica*-modul kome ćemo predati funkciju f , početnu aproksimaciju x_0 , traženu točnost eps , te maksimalno dozvoljen broj iteracija it . Iterativni proces zaustaviti ćemo za neki k ako bude $|f'(x_k)| < eps$ ili ako $k > it$. Na taj način dobit ćemo zapravo stacionarnu točku funkcije f . Ako je $|f'(x_k)| < eps$ i ako je $|f''(x_k)| > 0$, smatrati ćemo da smo pronašli točku minimuma funkcije f s točnošću eps . Kao rezultat možemo ispisivati svaku iteraciju, te konačni rezultat.

```
In[1]:= NewtonMin1[f_,x0_,eps_,it_]:=Module[{x=N[x0],k=0},
  While[Abs[f'[x]] > eps && k < it,
    Print["x",k,"=",x," ", f'',k,"=",f[x]];
    x=x-f'[x]/f'',x];
  ];
```

```

k=k+1
];
If[f''[x]<0,Print["Pronadjena je stacionarna tocka"],{x,f[x]}
];

```

U ovom primjeru modul ćemo koristiti na sljedeći način

```

In[2]:= q[x_]:= .5 x^3 - 6 x + 2; x0=3; y0=4;
f[x_]:=(x - x0)^2 + (q[x] - y0)^2
NewtonMin1[f, 4, 0.005, 10]

x0 = 4.          f0 = 37.
x1 = 3.72544,   f1 = 2.77591
x2 = 3.62874,   f2 = 0.40942
x3 = 3.61692,   f3 = 0.382444
Out[4]:= {3.61676, 0.382438}

```

Ako stavimo $\text{NewtonMin1}[f, -3.5, -0.005, 10]$, dobivamo drugi lokalni minimum $\{-3.2173, 39.0807\}$, a za $\text{NewtonMin1}[f, 2, -0.005, 10]$, pronađena je stacionarna točka $\{1.98298\}$ u kojoj funkcija postiže lokalni maksimum.

Lokalni minimum iste funkcije možemo potražiti direktnom primjenom *Mathematica*-modula

```

In[4]:= FindMinimum[f[x], {x, 4}]
Out[4]:= {0.382438, {x->3.61676}}

```

Dakle, globalni minimum funkcije f postiže se u točki $x^* = 3.61676$, pri čemu je $f(x^*) = 0.382438$. To znači da je udaljenost točke T_0 do grafa kubne parabole $q(x) = .5x^3 - 6x + 2$ jednaka $d(T_0, q) = \sqrt{f(x^*)} = 0.618416$, pri čemu se taj minimum postiže u točki $T^*(x^*, q(x^*)) = (3.61676, 3.95472)$.

3. Gradijentne metode

Iterativni proces za traženje točke lokalnog minimuma dovoljno puta neprekidno diferencijabilne funkcije $f : \mathbb{R}^n \rightarrow \mathbb{R}$ općenito je oblika

$$x_{k+1} = x_k + \alpha_k p_k, \quad k = 0, 1, \dots, \quad (3.1)$$

gdje je x_0 početna aproksimacija, p_k vektor smjera kretanja od točke x_k u točku x_{k+1} , a $\alpha_k > 0$ duljina koraka u smjeru p_k .

Kretanje od točke x_k u točku x_{k+1} treba ostvariti tako da se postigne smanjenje vrijednosti funkcije, tj. tako da bude $f(x_{k+1}) < f(x_k)$. To se može postići tako da vektor p_k izaberemo tako da bude (vidi primjerice [10])

$$(f'(x_k), p_k) < 0, \quad (3.2)$$

gdje je $f'(x_k)$ gradijent funkcije f u točki x_k . Naime, ako za funkciju f napišemo Taylorovu formulu u okolini točke x_k

$$f(x) = f(x_k) + (f'_k, x - x_k) + \frac{1}{2} (f''(x_k + \vartheta(x - x_k)) (x - x_k), x - x_k), \quad \vartheta \in (0, 1)$$

i stavimo $x = x_k + \alpha_k p_k$, uz oznaku $\xi_k = x_k + \vartheta(x - x_k)$ dobivamo

$$f(x) = f(x_k) + \alpha_k (f'_k, p_k) + \frac{\alpha_k^2}{2} (f''(\xi_k) p_k, p_k), \quad \vartheta \in (0, 1)$$

Ako je $(f'_k, p_k) < 0$, onda za male vrijednosti parametara α_k vrijedi $f(x_{k+1}) := f(x_k + \alpha_k p_k) < f(x_k)$.

3.1. Gradijentna metoda i metoda najbržeg spusta

Još je A. Cauchy 1845. godine uočio da je smjer najbržeg pada neprekidno derivabilne funkcije $f : \mathbb{R}^n \rightarrow \mathbb{R}$ u točki \mathbf{x} u smjeru antigradijenta $(-f'(x))$. Naime, ako za neki vektor $d \in \mathbb{R}^n$ definiramo diferencijabilnu funkciju $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ formulom

$$\varphi(t) := f(x + td),$$

onda zbog $\varphi'(0) = (f'(x), d)$:

- za $d := \frac{f'(x)}{\|f'(x)\|}$, vrijedi $\varphi'(0) = \|f'(x)\| > 0$, pa smjer gradijenta pokazuje smjer porasta funkcije f ;
- za $d := -\frac{f'(x)}{\|f'(x)\|}$, vrijedi $\varphi'(0) = -\|f'(x)\| < 0$, pa smjer antigradijenta pokazuje smjer pada funkcije f .

Na toj ideji zasniva se **obična gradijentna metoda** za minimizaciju funkcije $f : \mathbb{R}^n \rightarrow \mathbb{R}$

$$x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}, \quad k = 0, 1, \dots, \quad (3.3)$$

gdje je $\alpha_k > 0$ duljina koraka u smjeru vektora smjera kretanja $p^{(k)} = -f'(x^{(k)})$, koji očigledno zadovoljava uvjet (4.2). Duljina koraka α_k računamo sljedećim algoritmom (koji će biti opravda u dokazu *Leme 3.1.* i *Teorema 3.1.*):

Algoritam za izračunavanje duljine koraka

Korak 0. Izabradi $0 < \varepsilon < 1$ i stavi $\alpha = 1$

Korak 1. Izračunati $x = x_k + \alpha_k p_k$ i provjeriti uvjet

$$f(x) - f(x^{(k)}) \leq \varepsilon \alpha (f'(x^{(k)}), p^{(k)}) \quad (3.4)$$

Korak 2. Ako je uvjet (3.4) ispunjen, staviti $\alpha_k = \alpha$; inače staviti $\alpha := h\alpha$, $h \in (0, 1)$ i prijeći na *Korak 1.*

Najprije ćemo sagraditi *Mathematica*-modul **Korak[n, f, d, pk, xk]**, koji će izračunavati duljinu koraka α_k iz točke $x^{(k)}$ u smjeru vektora $p^{(k)}$. Pri tome je n broj varijabli, f ime minimizirajuće funkcije, a d njezin gradijent.

```
In[1]:= Korak[n_, f_, pk_, xk_] := Module[{epsilon = .5, h = .5, f0, f1, fd},
  al = 1; w = Table[x[i] -> xk[[i]], {i, n}];
  d[x_] := Table[D[f[x], x[i]], {i, n}];
  f0 = f[x] /. w;
  fd = d[x] /. w;
  While[f1 = f[x] /. Table[x[i] -> xk[[i]] + al pk[[i]], {i, n}];
        f1 - f0 > epsilon al Apply[Plus, fd pk], al = h al];
  al]
```

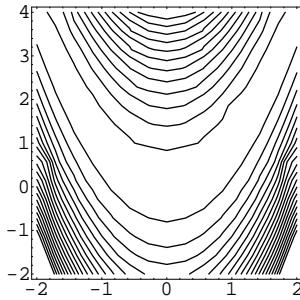
Gradijentna metoda dana je u *Mathematica*-modulu `MinGrad[n,f,d,x0,eps,it]`, gdje je x_0 početnu aproksimaciju, eps traženu točnost, a it maksimalno dozvoljen broj iteracija. Modul `MinGrad` poziva modul `Korak`, a iterativni postupak završava onda ako je $\|f'(x^{(k)})\|_\infty < eps$ za neki k ili ako je $k > it$.

```
In[2]:= MinGrad[n_, f_, x0_, eps_, it_]:= Module[{k = 0, xs = x0, xn, gr, w},
    w = Table[x[i] -> x0[[i]], {i, n}];
    d[x_] := Table[D[f[x], x[i]], {i, n}];
    While[w = Table[x[i] -> xs[[i]], {i, n}]; grad = Max[Abs[d[x] /. w]];
        grad > eps && k < it,
        pk = -d[x] /. w;
        alpha = Korak[n, f, pk];
        Print["x", k, "=" , xs, " f=", f[x] /. Table[x[i] -> xs[[i]], {i, n}],
            " |grad|=", grad, " alpha=", alpha];
        xn = xs + alpha pk;
        xs = xn; k = k + 1;
    ];
    {xn, f[x] /. Table[x[i] -> xn[[i]], {i, n}]}
```

Modul `MinGrad` testirati ćemo na poznatoj *Rosenbrockovoj* funkciji, koja postiže minimum u točki $x^* = (0,0)$ i za koju ćemo odmah definirati gradijent i nacrtati nivo krivulje u okolini minimuma, a djelomične rezultate izvođenja programa za $x_0 = (.5,.5)$ dati u *Tablici 1*.

```
In[3]:= n = 2; f[x_] := 100(x[2] - x[1]^2)^2 + (1 - x[1])^2
          f[x] /. {x[1] -> x1, x[2] -> x2}
          d[x_] := Table[D[f[x], x[i]], {i, n}]
          d[x] /. {x[1] -> x1, x[2] -> x2}
ContourPlot[f[x] /. {x[1] -> x1, x[2] -> x2}, {x1, -2, 2}, {x2, -2, 4},
           Contours -> 20, ContourShading -> None];

Out[3]:= (1 - x1)^2 + 100(-x1^2 + x2)^2
{-2(1 - x1) - 400 x1(-x1^2 + x2), 200(-x1^2 + x2)}
```



k	$(x^{(k)})$	$f(x^{(k)})$	$\ f'(x^{(k)})\ _\infty$	α_k
0	(0.5,0.5)	6.5	51	0.00195313
1	(0.599609, 0.402344)	0.343602	11.0691	0.00195313
2	(0.621229, 0.38562)	0.143477	0.681796	0.00195313
10	(0.703733, 0.492322)	0.0886257	0.58356	0.00195313
100	(0.785646, 0.615674)	0.0461927	0.313171	0.00195313
500	(0.895571, 0.801784)	0.0109123	0.114267	0.00195313
1000	(0.984068, 0.968167)	0.000258777	0.0556747	0.03125

Tablica 1.

Sljedeća lema pokazuje da gradijentna metoda (3.3) osigurava konvergenciju iterativnog procesa ili prema inf f ili prema nekoj stacionarnoj točki funkcije f .

Lema 3.1. Ako je

- (i) funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ograničena odozdo
- (ii) gradijent f' zadovoljava Lipschitzov uvjet

$$\|f'(x) - f'(y)\| \leq R\|x - y\| \quad \text{za sve } x, y \in \mathbb{R}^n, \quad (3.5)$$

(iii) parametri α_k biraju se iz uvjeta (3.4),

tada za gradijentnu metodu (3.3) vrijedi

$$\|f'(x_k)\| \rightarrow 0, \quad \text{za } k \rightarrow \infty$$

neovisno o izboru početne aproksimacije x_0 , a parametri α_k uvjek se mogu izabrati prethodno opisanim Algoritmom za izračunavanje duljine koraka.

Dokaz. Prema Lagrangeovom teoremu o srednjoj vrijednosti postoji $\vartheta \in (0, 1)$, tako da bude

$$f(x_k + (x - x_k)) - f(x_k) = (f'(x_k + \vartheta(x - x_k)), x - x_k).$$

Dodavanjem i oduzimanjem $f'(x_k)(x - x_k)$ na desnoj strani, t označavanjem: $\xi := x_k + \vartheta(x - x_k)$, $f_k := f(x_k)$, $f'_k := f'(x_k)$, $f'_\xi := f'(\xi)$ ovu jednakost možemo zapisati:

$$f(x) - f_k = (f'_k, x - x_k) + (f'_\xi - f'_k, x - x_k)$$

Za $x = x_k - \alpha f'_k$ korištenjem Cauchy-Schwartzove nejednakosti i uvjeta (3.5) dobivamo

$$\begin{aligned} f(x) - f_k &= -\alpha(f'_k, f'_k) - \alpha(f'_\xi - f'_k, f'_k) \quad \left[-\alpha(f'_k, f'_k) + \alpha(f'_k - f'_\xi, f'_k) \right] \\ &\leq -\alpha\|f'_k\|^2 + \alpha\|f'_\xi - f'_k\|\|f'_k\| \leq -\alpha\|f'_k\|^2 + \alpha R\|\xi - x_k\|\|f'_k\| \quad [\xi - x_k = \vartheta(x - x_k)] \\ &\leq -\alpha\|f'_k\|^2 + \alpha R\|x - x_k\|\|f'_k\| = -\alpha\|f'_k\|^2 + \alpha R\alpha\|f'_k\|\|f'_k\| \\ &= \alpha\|f'_k\|^2(\alpha R - 1) \end{aligned}$$

Kako je $R < \infty$, za $\varepsilon \in (0, 1)$ iz Algoritma za izračunavanje duljine koraka parametar α možemo uzeti tako da bude $\alpha > 0$ i $\alpha R - 1 \leq -\varepsilon$. Zato iz prethodne nejednakosti dobivamo

$$f(x) - f_k \leq \alpha(f'_k, f'_k)(-\varepsilon) \implies f(x) - f_k \leq \varepsilon\alpha(f'_k, -f'_k), \quad (3.6)$$

što je upravo uvjet (3.4). Drugim riječima uvjet (3.4) bit će ispunjen za $\alpha \leq \frac{1-\varepsilon}{R}$.

Ako stavimo $x := x_{k+1}$, onda prethodna nejednakost pokazuje da je $f_{k+1} < f_k$ za svaki $k = 0, 1, \dots$ uz uvjet da je $\|f'_k\| \neq 0$, tj niz (f_n) je monotono padajuć. Kako je po pretpostavci funkcija f ograničena odozdo, onda to znači da je i niz (f_n) ograničen odozdo. Dakle, niz (f_n) je konvergentan, a onda i Cauchyjev, pa možemo zaključiti da vrijedi

$$f_{k+1} - f_k \rightarrow 0 \quad \text{za } k \rightarrow \infty.$$

što uz nejednakost $[f_{k+1} - f_k \leq -\varepsilon\alpha\|f'_k\|^2]$

$$\|f'_k\|^2 \leq \frac{f_k - f_{k+1}}{\varepsilon\alpha_k}$$

koja slijedi iz nejednakosti (3.6) za $x = x_{k+1}$ dokazuje tvrdnju leme. ♣

Teorem 3.1. Neka je $f \in C^2(\mathbb{R}^n)$ i

$$m\|y\|^2 \leq (f''(x)y, y) \leq M\|y\|^2, \quad M > m > 0 \quad \text{za sve } x, y \in \mathbb{R}^n \quad (3.7)$$

Ako se niz (x_n) gradi pomoću iterativnog procesa (3.3), a parametri α_k biraju iz uvjeta (3.4), tada neovisno o izboru početne aproksimacije $x_0 \in \mathbb{R}^n$ vrijedi

$$x_k \rightarrow x^* \quad i \quad f(x_k) \rightarrow f(x^*),$$

gdje je $x^* \in \mathbb{R}^n$ jedinstvena točka minimuma funkcije f . Pri tome vrijede ocjene:

$$\|x - x^*\| \leq \frac{\|f'(x)\|}{m}, \quad f_k - f^* \leq g^k(f_0 - f^*), \quad \|x_k - x^*\| \leq C q^{\frac{k}{2}}, \quad (3.8)$$

gdje je $C < \infty$, $q \in (0, 1)$.

Dokaz. Prema Teoremu 1.1. lijevi dio nejednakosti (3.7) ekvivalentan je činjenici da je f jako konveksna funkcija. Nadalje, prema Teoremu 1.2. funkcija f ograničena je odozdo i postoji jedinstvena točka minimuma $x^* \in \mathbb{R}^n$. Zato još treba dokazati da niz (x_n) konvergira prema x^* neovisno o izboru početne aproksimacije $x_0 \in \mathbb{R}^n$ i dokazati ocjene (3.8).

Pokažimo najprije da niz (x_n) konvergira prema x^* . Primjenom Taylorove formule za funkciju f u okolini točke x , za x^* dobivamo

$$f(x^*) = f(x) + (f'(x), x^* - x) + \frac{1}{2} (f''(\xi)(x^* - x), x^* - x)$$

a odavde korištenjem (3.7) dobivamo

$$f(x) - f(x^*) = (f'(x), x - x^*) - \frac{1}{2} (f''(\xi)(x^* - x), x^* - x) \leq (f'(x), x - x^*) - \frac{m}{2} \|x - x^*\|^2,$$

što uz primjenu Cauchyjeve nejednakosti daje

$$f(x) - f(x^*) \leq \|f'(x)\| \|x - x^*\| - \frac{m}{2} \|x - x^*\|^2. \quad (3.9)$$

Primjenom Taylorove formule za funkciju f u okolini točke x^* i korištenjem činjenice da je $f'(x^*) = 0$, dobivamo

$$f(x) - f(x^*) = \frac{1}{2} (f''(\zeta)(x - x^*), x - x^*).$$

Koristeći ovdje (3.7) dobivamo

$$\frac{m}{2} \|x - x^*\|^2 \leq f(x) - f(x^*) \leq \frac{M}{2} \|x - x^*\|^2. \quad (3.10)$$

Iz (3.9) i (3.10) slijedi

$$\|f'(x)\| \|x - x^*\| - \frac{m}{2} \|x - x^*\|^2 \geq f(x) - f(x^*) \geq \frac{m}{2} \|x - x^*\|^2, \Rightarrow m \|x - x^*\|^2 \leq \|f'(x)\| \|x - x^*\|$$

a odavde

$$\|x - x^*\| \leq \frac{\|f'(x)\|}{m}. \quad (3.11)$$

Desna strana ove nejednakosti za $x = x_k$ prema Lemu 3.1. konvergira prema nuli, što znači da $\|x_k - x^*\| \rightarrow 0$ za $k \rightarrow \infty$, tj. $x_k \rightarrow x^*$.

Korištenjem nejednakosti (3.10) i (3.11) u (3.9) dobivamo

$$f(x) - f(x^*) \leq \|f'(x)\| \frac{\|f'(x)\|}{m} - \frac{m}{2} \frac{2}{M} (f(x) - f(x^*)),$$

iz čega slijedi $\left[\frac{1}{m} \|f'(x)\|^2 \geq (f(x) - f(x^*)) + \frac{m}{M} (f(x) - f(x^*)) \right]$

$$\|f'(x)\|^2 \geq m \left(1 + \frac{m}{M} \right) (f(x) - f(x^*)). \quad (3.12)$$

Korištenjem ove nejednakosti u (3.6) za $x = x_k - \alpha f'_k$ $[f(x) - f(x_k) \leq -\varepsilon \alpha \|f'_k\|^2]$ dobivamo

$$f_{k+1} - f_k \leq -\varepsilon \alpha_k m \left(1 + \frac{m}{M} \right) (f(x_k) - f(x^*)). \quad (3.13)$$

S druge strane primjenom Taylorove formule za funkciju f u okolini točke x_k , za $x = x_k - \alpha f'_k$ dobivamo

$$\begin{aligned} f(x) - f(x_k) &= (f'_k, x - x^*) + \frac{1}{2} (f''(\xi)(x - x_k), x - x_k) = -\alpha \|f'_k\|^2 + \frac{\alpha^2}{2} (f''(\xi) f'_k, f'_k) \\ (3.7) \quad &\leq -\alpha \|f'_k\|^2 + \frac{\alpha^2}{2} M \|f'_k\|^2 = -\alpha \left(1 - \frac{\alpha M}{2} \right) \|f'_k\|^2. \end{aligned}$$

Ako $\varepsilon > 0$ izaberemo tako da bude $1 - \frac{\alpha M}{2} > \varepsilon$, onda iz prethodne nejednakosti dobivamo uvjet (3.4) pomoću kojeg biramo duljinu koraka α_k

$$f(x) - f(x_k) \leq -\alpha \varepsilon \|f'_k\|^2.$$

Dakle uvjet (3.4) bit će ispunjen za $\alpha_k \leq \bar{\alpha} = \frac{2(1-\varepsilon)}{M}$.

Iz (3.13) slijedi $[f_{k+1} - f_k \leq -\varepsilon \alpha_k m \left(1 + \frac{m}{M} \right) (f(x_k) - f(x^*))]$

$$f_{k+1} - f^* = (f_{k+1} - f_k) + (f_k - f^*) \leq \left(1 - \varepsilon \alpha_k m \left(1 + \frac{m}{M} \right) \right) (f(x_k) - f(x^*)) \leq q(f_k - f^*),$$

uz označku $q := 1 - \varepsilon \alpha_k m \left(1 + \frac{m}{M} \right)$, što više puta primijenjeno daje

$$f_k - f^* \leq q^k (f_0 - f^*). \quad (3.14)$$

Kako je $\alpha_k \leq \bar{\alpha} = \frac{2(1-\varepsilon)}{M}$, bit će $q \geq 1 - \frac{2\varepsilon(1-\varepsilon)m}{M} \left(1 + \frac{m}{M} \right)$. Ako sada q shvatimo kao realnu funkciju varijable ε i pronađemo njezin minimu, dobivamo $q_{min} = 1 - \frac{m}{2M} \left(1 + \frac{m}{M} \right)$ za $\varepsilon = \frac{1}{2}$. Sada se vidi da je u uvjet (3.4) najbolje staviti $\varepsilon = \frac{1}{2}$. To će osigurati najveću moguću brzinu konvergencije gradijentne metode.

Na kraju, iz (3.10) i (3.14) izlazi

$$\|x_k - x^*\| \leq \sqrt{\frac{2}{m}} \sqrt{f_k - f^*} \leq q^{\frac{k}{2}} \sqrt{\frac{2}{m}} \sqrt{f_0 - f^*} \leq C q^{\frac{k}{2}}.$$



4. Metode Newtonovog tipa

Iterativni proces za traženje točke lokalnog minimuma dovoljno puta neprekidno diferencijabilne funkcije $f : \mathbb{R}^n \rightarrow \mathbb{R}$ općenito je oblika

$$x_{k+1} = x_k + \alpha_k p_k, \quad k = 0, 1, \dots, \quad (4.1)$$

gdje je x_0 početna aproksimacija, p_k vektor smjera kretanja od točke x_k u točku x_{k+1} , a $\alpha_k > 0$ duljina koraka u smjeru p_k .

Kretanje od točke x_k u točku x_{k+1} treba ostvariti tako da se postigne smanjenje vrijednosti funkcije, tj. tako da bude $f(x_{k+1}) < f(x_k)$. To se može postići tako da vektor p_k izaberemo tako da bude (vidi primjerice [10], [16])

$$(f'(x_k), p_k) < 0, \quad (4.2)$$

gdje je $f'(x_k)$ gradijent funkcije f u točki x_k . Naime, ako za funkciju f napišemo Taylorovu formulu u okolini točke x_k

$$f(x) = f(x_k) + (f'_k, x - x_k) + \frac{1}{2} (f''(x_k + \vartheta(x - x_k)) (x - x_k), x - x_k), \quad \vartheta \in (0, 1)$$

i stavimo $x = x_k + \alpha_k p_k$, uz oznaku $\xi_k = x_k + \vartheta(x - x_k)$ dobivamo

$$f(\textcolor{red}{x_k + \alpha_k p_k}) = f(x_k) + \alpha_k (f'_k, p_k) + \frac{\alpha_k^2}{2} (f''(\xi_k) p_k, p_k), \quad \vartheta \in (0, 1)$$

Ako je $(f'_k, p_k) < 0$, onda za male vrijednosti parametara α_k vrijedi $f(x_{k+1}) := f(x_k + \alpha_k p_k) < f(x_k)$.

4.1. Newtonova metoda

Pretostavimo da je promatrana funkcija f strogo konveksna i dovoljno glatka i da je na neki način izabrana početna aproksimacija x_0 . Analogno Newtonovoj metodi za jednodimenzionalnu minimizaciju u okolini točke x_0 funkciju f aproksimirat ćemo kvadratnom funkcijom dobivenom iz Taylorove formule

$$\psi(x) = f(x_0) + (f'(x_0), x - x_0) + \frac{1}{2} (f''(x_0) (x - x_0), x - x_0)$$

Funkcija ψ također je strogo konveksna i njezin minimum postiže se u točki $x_1 = x_0 - (f''(x_0)^{-1} f'(x_0))$, koju ćemo smatrati sljedećom aproksimacijom. Primijetite da smo iz točke x_0 u točku x_1 "došli" preko vektora smjera kretanja definiranog s $p = -(f''(x_0)^{-1} f'(x_0))$. Ovaj vektor definira smjer spusta iz točke x_0 jer zbog konveksnosti funkcije f ispunjava uvjet spusta (4.2)

$$\begin{aligned} (f'(x_0), p) &= (f'(x_0), -(f''(x_0)^{-1} f'(x_0))) = -(f''(x_0)p, p) < 0 \\ [(f'_0, p) &= (f'_0)^T p = -(f'_0)^T ((f''_0)^{-1} f''_0) (f''_0)^{-1} f'_0 = -\textcolor{red}{p}^T f''_0 p = - (f''_0 p, p)] \end{aligned}$$

Ponavljajući navedeni postupak dolazimo do iterativne metode

$$x_{k+1} = x_k - (f''(x_k)^{-1} f'(x_k)), \quad k = 0, 1, \dots,$$

koja se u literaturi obično naziva obična Newtonova ili Newton-Raphsonova metoda (vidi primjerice [6], [8], [10], [12], [15], [16], [20]). Pri tome u implementaciji metode računanje inverzne matrice $(f''(x_k)^{-1})$ izbjegava se tako da umjesto toga u svakom koraku rješavamo jedan sustav linearnih jednadžbi:

$$x_{k+1} = x_k + p_k, \quad (\text{gdje je } p_k \text{ rješenje sustava})$$

$$f''(x_k)p = f'(x_k).$$

Uzevši u obzir da kretanje od točke x_k u smjeru vektora p_k donosi smanjenje vrijednosti funkcije, kao i u slučaju gradijentne metode, uvodimo duljinu koraka α_k i tako definiramo Newtonovu metodu s regulacijom koraka

$$x_{k+1} = x_k - \alpha_k f''(x_k)^{-1} f'(x_k), \quad k = 0, 1, \dots, \quad (4.3)$$

koju u implementaciji definiramo kao

$$\begin{aligned} x_{k+1} &= x_k + p_k, \quad (\text{gdje je } p_k \text{ rješenje sustava}) \\ f''(x_k)p &= f'(x_k). \end{aligned} \quad (4.4)$$

Kao i u slučaju gradijentne metode parametar duljine koraka α_k možemo definirati na dva načina. Prvi način definiran je sljedećim algoritmom:

Algoritam za izračunavanje duljine koraka

Korak 0. Staviti $\alpha = 1$ i izabrati $0 < \varepsilon < \frac{1}{2}$;

Korak 1. Izračunati $x = x_k + \alpha_k p_k$ i provjeriti uvjet

$$f(x) - f(x_k) \leq \varepsilon \alpha (f'(x_k), p_k); \quad (4.5)$$

Korak 2. Ako je uvjet (4.5) ispunjen, staviti $\alpha_k = \alpha$; inače staviti $\alpha := h\alpha$, $h \in (0, 1)$ i prijeći na Korak 1.

Drugi način izbora duljine koraka α_k dobivamo postupkom jednodimenzionalne minimizacije

$$\alpha_k := \arg \min_{\alpha \geq 0} f(x_k - \alpha p_k). \quad (4.6)$$

4.1.1. Svojstva Newtonove metode

Prepostavit ćemo da je promatrana funkcija $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ dvostruko neprekidno diferencijabilna i jako konveksna, tj.

$$m\|y\|^2 \leq (f''(x)y, y) \leq M\|y\|^2, \quad M > m > 0 \quad \text{za sve } x, y \in \mathbb{R}^n. \quad (4.7)$$

Primijetite da su takve funkcije ograničene odozdo i da posjeduju jedinstvenu točku minimuma.

Može se pokazati da također vrijedi (vidi primjerice [10], [16])

$$\frac{m}{M^2}\|y\|^2 \leq ((f''(x))^{-1}y, y) \leq \frac{1}{m}\|y\|^2, \quad M > m > 0 \quad \text{za sve } x, y \in \mathbb{R}^n. \quad (4.8)$$

iz čega slijedi ocjena

$$(f'_k, p_k) = -(f'_k, (f''(x_k))^{-1}f'_k) \leq -\frac{m}{M^2}\|f'_k\|^2. \quad (4.9)$$

Teorem 4.1. Neka funkcija $f \in C^2(\mathbb{R}^n)$ zadovoljava uvjet (4.7) i neka se parametri duljine koraka α_k biraju iz uvjeta (4.5).

Tada, neovisno o izboru početne aproksimacije x_0 , iterativni proces (4.3) konvergira prema jedinstvenoj točki minimuma x^* superlinearnom brzinom

$$\|x_{k+1} - x^*\| \leq \lambda_k \|x_k - x^*\|, \quad (4.10)$$

gdje $\lambda_k \rightarrow 0$ za $k \rightarrow \infty$.

Dokaz. Za $x = x_k + \alpha p_k$, gdje je $p_k = -f_k''^{-1} f'_k$, korištenjem (4.7) u Taylorovoj formuli dobivamo

$$f(x) - f(x_k) = \alpha(f'_k, p_k) + \frac{\alpha^2}{2}(f''(\xi)p_k, p_k) \leq \alpha(f'_k, p_k) \left(1 + \frac{\alpha M \|p_k\|^2}{2(f'_k, p_k)}\right)$$

Kako je s druge strane $[(f'_k, p_k) = (f'_k)^T p_k = (f'_k)^T (f''_k)^{-1} f'_k \quad p_k = -p_k^T f''_k p_k =]$

$$(f'_k, p_k) = -(f''(x_k)p_k, p_k) \leq -m\|p_k\|^2,$$

$$\text{dobivamo} \quad -(f'_k, p_k) \geq m\|p_k\|^2 \quad \Rightarrow \quad \left(1 + \frac{\alpha M \|p_k\|^2}{2(f'_k, p_k)}\right) = \left(1 - \frac{\alpha M \|p_k\|^2}{-2(f'_k, p_k)}\right) \leq \left(1 - \frac{\alpha M}{2m}\right)$$

$$f(x) - f(x_k) \leq \alpha(f'_k, p_k) \left(1 - \frac{\alpha M}{2m}\right).$$

Izaberimo $\varepsilon > 0$ tako da bude

$$1 - \frac{\alpha M}{2m} \geq \varepsilon. \quad (4.11)$$

Množenjem ove nejednakosti s negativnim brojem $\alpha(f'_k, p_k) < 0$ dobivamo

$$\varepsilon \alpha(f'_k, p_k) \geq \alpha(f'_k, p_k) \left(1 - \frac{\alpha M}{2m}\right) \geq f(x) - f(x_k)$$

Odavde slijedi da će uvjet (4.5) biti ispunjen ako je ispunjen uvjet (4.11), odnosno ako je $\alpha \leq \bar{\alpha} = \frac{2(1-\varepsilon)m}{M}$. Time je opravdan način izbora duljine koraka α_k .

Kako je $(f'_k, p_k) < 0$ za $\|f'_k\| \neq 0$ iz uvjeta

$$f_{k+1} - f_k \leq \varepsilon \alpha_k(f'_k, p_k) \quad (4.12)$$

slijedi $f_{k+1} < f_k$, tj. niz (f_k) je monotono padajuć. Zbog uvjeta jake konveksnosti funkcije f on je i ograničen odozdo, što znači da je konvergentan i da vrijedi $f_{k+1} - f_k \rightarrow \infty$. Korištenjem uvjeta (4.8) u (4.12) i činjenice da je $f''(x_k)$ simetrična matrica dobivamo

$$f_{k+1} - f_k \leq \varepsilon \alpha_k(f'_k, p_k) = -\varepsilon \alpha_k((f''_k)^{-1} f'_k, f'_k) \leq -\varepsilon \alpha_k \frac{m}{M^2} \|f'_k\|^2, \quad (4.13)$$

a odavde

$$\|f'_k\|^2 \leq \frac{M^2}{m\varepsilon\alpha_k} (f_k - f_{k+1}),$$

iz čega slijedi $\|f'_k\| \rightarrow 0$. Time je pokazano da su rezultati analogni rezultatima Leme 3.1. ostali sačuvani.

Nadalje, slično kao u dokazu Teorema 3.1. pokazat ćemo da niz definiran s (4.3) konvergira prema točki minimuma x^* . Budući da je f jako konveksna funkcija, postoji jedinstvena točka minimuma $x^* \in \mathbb{R}^n$. Pokažimo još da niz (x_n) konvergira prema x^* neovisno o izboru početne aproksimacije $x_0 \in \mathbb{R}^n$.

Primjenom Taylorove formule za funkciju f u okolini točke x , za x^* dobivamo

$$f(x^*) = f(x) + (f'(x), x^* - x) + \frac{1}{2}(f''(\xi)(x^* - x), x^* - x)$$

a odavde korištenjem uvjeta jake konveksnosti (4.7) dobivamo $(f''(\xi)(x^* - x), (x^* - x)) \geq m\|x^* - x\|^2$

$$f(x) - f(x^*) = (f'(x), x - x^*) - \frac{1}{2}(f''(\xi)(x^* - x), x^* - x) \leq (f'(x), x - x^*) - \frac{m}{2}\|x - x^*\|^2,$$

što uz primjenu Cauchyjeve nejednakosti daje

$$f(x) - f(x^*) \leq \|f'(x)\| \|x - x^*\| - \frac{m}{2} \|x - x^*\|^2. \quad (4.14)$$

Primjenom Taylorove formule za funkciju f u okolini točke x^* i korištenjem činjenice da je $f'(x^*) = 0$, dobivamo

$$f(x) - f(x^*) = \frac{1}{2} (f''(\zeta)(x - x^*), x - x^*).$$

Koristeći ovdje **uvjet jake konveksnosti** (4.7) dobivamo

$$\frac{m}{2} \|x - x^*\|^2 \leq f(x) - f(x^*) \leq \frac{M}{2} \|x - x^*\|^2. \quad (4.15)$$

Iz (4.14) i (4.15) slijedi

$$\|f'(x)\| \|x - x^*\| - \frac{m}{2} \|x - x^*\|^2 \geq f(x) - f(x^*) \geq \frac{m}{2} \|x - x^*\|^2,$$

a odavde $[m\|x - x^*\|^2 \leq \|f'(x)\| \|x - x^*\|]$

$$\|x - x^*\| \leq \frac{\|f'(x)\|}{m}. \quad (4.16)$$

Kao što smo ranije utvrdili desna strana ove nejednakosti za $x = x_k$ konvergira prema nuli, što znači da $\|x_k - x^*\| \rightarrow 0$ za $k \rightarrow \infty$, tj. $x_k \rightarrow x^*$.

Prijedimo sada na dokaz ocjene brzine konvergencije (4.10). U tu svrhu najprije primijetimo da vrijedi

$$(f'_k, p_k) = -(f''(x_k)p_k, p_k) \leq -m\|p_k\|^2, \quad (4.17)$$

Iz (4.12) $[f_{k+1} - f_k \leq \varepsilon \alpha_k(f'_k, p_k)]$ slijedi $(f'_k, p_k) \rightarrow 0$. Zato iz (4.17) slijedi

$$\|p_k\| \rightarrow 0, \quad k \rightarrow \infty.$$

Pokažimo nadalje da su u općoj Newtonovoj metodi (4.7), počevši od neke iteracije, svi parametri α_k jednaki 1. Koristeći Taylorovu formulu, te dodavanjem i oduzimanjem broja $\frac{\alpha_k^2}{2}(f''_k p_k, p_k)$ dobivamo

$$\begin{aligned} f_{k+1} - f_k &= \alpha_k(f'_k, p_k) + \frac{\alpha_k^2}{2}(f''_k p_k, p_k) + \frac{\alpha_k^2}{2}((f''(\xi) - f''_k)p_k, p_k) \\ (4.17) \quad &\leq \alpha_k(f'_k, p_k) \left(1 - \frac{\alpha_k}{2} + \frac{\alpha_k(-1)}{2} \frac{\|(f''(\xi) - f''_k)p_k\| \cdot \|p_k\|}{(-1)(f'_k, p_k)}\right) \\ (4.17) \quad &\leq \alpha_k(f'_k, p_k) \left(1 - \frac{\alpha_k}{2} - \frac{\alpha_k}{2} \frac{\|f''(\xi) - f''_k\| \cdot \|p_k\|^2}{m\|p_k\|^2}\right), \end{aligned}$$

gdje je $\xi = x_k + \vartheta(x_{k+1} - x_k)$, $\vartheta \in [0, 1]$.

Budući da

$$\|f''(\xi) - f''(x_k)\| \leq \|f''(\xi) - f''(x^*)\| + \|f''(x^*) - f''(x_k)\|,$$

i $\|x_k - x^*\| \rightarrow 0$ za $k \rightarrow \infty$, onda zbog neprekidnosti funkcije f'' vrijedi $\|f''(\xi) - f''(x_k)\| \rightarrow 0$ za $k \rightarrow \infty$.

Zbog toga za proizvoljni $0 < \varepsilon < \frac{1}{2}$ postoji prirodan broj $N_0(\varepsilon) \in \mathbb{N}$ takav da za svaki $k \geq N_0(\varepsilon)$ vrijedi $\alpha_k \geq 1 \Rightarrow -\frac{\alpha_k}{2} \leq -\frac{1}{2} \Rightarrow 1 - \frac{\alpha_k}{2} \leq \frac{1}{2}$

$$1 - \frac{1}{2} \geq 1 - \frac{\alpha_k}{2} - \frac{\alpha_k}{2} \frac{\|f''(\xi) - f''_k\|}{m} \geq \varepsilon,$$

uz uvjet da je $\alpha_k \geq 1$. Budući da je α_k u uvjetu (4.5) biran tako da bude $\alpha_k \leq 1$, to znači da će u svim iteracijama, čiji je redni broj veći ili jednak $N_0(\varepsilon)$, biti $\alpha_k = 1$.

Dakle, za $k \geq N_0(\varepsilon)$ vrijedi $x_{k+1} = x_k - (f''_k)^{-1} f'_k$

$$(x_{k+1} - x^*, x_{k+1} - x^*) = (x_k - x^* - (f''_k)^{-1} f'_k, x_{k+1} - x^*).$$

Ako na desnoj strani ove jednakosti iskoristimo Lagrangeovu formulu

$$\begin{aligned} ((f_k'')^{-1} f'_k, x_{k+1} - x^*) & [f'(x^*) = 0] = ((f_k'')^{-1} (f'_k - f'(x^*)), x_{k+1} - x^*) \\ & = ((f_k'')^{-1} f''(\xi) (x_k - x^*), x_{k+1} - x^*) \end{aligned}$$

gdje je $\xi = x^* + \vartheta(x_k - x^*)$, $\vartheta \in (0, 1)$, dobivamo

$$\begin{aligned} \|x_{k+1} - x^*\|^2 &= ((I - (f_k'')^{-1} f''(\xi)) (x_k - x^*), x_{k+1} - x^*) \\ &= ((f_k'')^{-1} (f''_k - f''(\xi)) (x_k - x^*), x_{k+1} - x^*) \\ (4.8) \quad &\leq \frac{1}{m} \|f''_k - f''(\xi)\| \cdot \|x_k - x^*\| \cdot \|x_{k+1} - x^*\|, \end{aligned}$$

a odavde

$$\|x_{k+1} - x^*\| \leq \lambda_k \|x_k - x^*\|, \quad \lambda_k = \frac{1}{m} \|f''_k - f''(\xi)\|. \quad (4.18)$$

Budući da $\|f''_k - f''(\xi)\| \rightarrow 0$ za $k \rightarrow \infty$, teorem je dokazan. ♣

Korolar 4.1. Neka funkcija $f \in C^2(\mathbb{R}^n)$ zadovoljava uvjet (4.7) i Lipschitzov uvjet

$$\|f''(x) - f''(y)\| \leq R \|x - y\| \quad \forall x, y \in \mathbb{R}^n.$$

Tada niz (4.3)

$$x_{k+1} = x_k - \alpha_k f''(x_k)^{-1} f'(x_k), \quad k = 0, 1, \dots,$$

gdje se parametri α_k biraju iz uvjeta (4.5), konvergira prema točki minimuma x^* neovisno o izboru početne aproksimacije x_0 kvadratičnom brzinom konvergencije

$$\|x_{k+1} - x^*\| \leq \frac{R}{m} \|x_k - x^*\|^2.$$

Dokaz. Koristeći Lipschitzov uvjet broj λ_k iz nejednakost (4.18) možemo pisati

$$[\xi = x^* + \vartheta(x_k - x^*), \quad 0 < \vartheta < 1]$$

$$\begin{aligned} \lambda_k = \frac{1}{m} \|f''(x_k) - f''(\xi)\| &\leq \frac{R}{m} \|x_k - x^* - \vartheta(x_k - x^*)\| \\ &= \frac{R}{m} \|x_k(1 - \vartheta) - x^*(1 - \vartheta)\| \\ &< \frac{R}{m} \|x_k - x^*\|, \end{aligned}$$

što daje traženu ocjenu. ♣

Ako duljinu koraka α_k biramo iz uvjeta (4.6)

$$\alpha_k := \arg \min_{\alpha \geq 0} f(x_k - \alpha p_k),$$

tada za Newtonovu metodu (4.3)

$$x_{k+1} = x_k - \alpha_k f''(x_k)^{-1} f'(x_k), \quad k = 0, 1, \dots,$$

vrijedi

Korolar 4.2. Neka funkcija $f \in C^2(\mathbb{R}^n)$ zadovoljava uvjet (4.7) i neka se duljina koraka α_k bira iz uvjeta (4.6).

Tada Newtonov iterativni proces (4.3) konvergira prema rješenju x^* bez obzira na izbor početne aproksimacije x_0 . superlinearnom brzinom. Ako pored toga funkcija f zadovoljava i Lipschitzov uvjet, onda je brzina kvadratična.

Dokaz. Neka je

$$\begin{aligned}\bar{x}_{k+1} &= x_k - (f''(x_k))^{-1} f'(x_k) \\ x_{k+1} &= x_k - \alpha_k (f''(x_k))^{-1} f'(x_k),\end{aligned}$$

gdje je α_k izabran iz uvjeta (4.6). Budući da je $f(x_{k+1}) \leq f(\bar{x}_{k+1})$, koristeći nejednakost (4.15), dobivamo
 $[\frac{m}{2} \|x - x^*\|^2 \leq f(x) - f(x^*) \leq \frac{M}{2} \|x - x^*\|^2]$

$$\frac{m}{2} \|x_{k+1} - x^*\|^2 \leq f(x_{k+1}) - f(x^*) \leq f(\bar{x}_{k+1}) - f(x^*) \leq \frac{M}{2} \|\bar{x}_{k+1} - x^*\|^2. \quad (4.19)$$

Za $\bar{x}_{k+1} = x_k - (f''(x_k))^{-1} f'(x_k)$ možemo primijeniti nejednakost (4.18)

$$\|\bar{x}_{k+1} - x^*\| \leq \lambda_k \|x_k - x^*\|, \quad \lambda_k = \frac{1}{m} \|f''_k - f''(\xi)\| = \frac{1}{m} \|f''_k - f''(x^* + \vartheta(x_k - x^*))\|$$

gdje $\lambda_k \rightarrow 0$ za $k \rightarrow \infty$. Ako ovu nejednakost iskoristimo u (4.19), dobivamo

$$\begin{aligned}\|x_{k+1} - x^*\| &\leq \sqrt{\frac{M}{m}} \|\bar{x}_{k+1} - x^*\| \leq \lambda_k \sqrt{\frac{M}{m}} \|x_k - x^*\| \\ &\leq \gamma_k \|x_k - x^*\|,\end{aligned}$$

gdje $\gamma_k = \lambda_k \sqrt{\frac{M}{m}} \rightarrow 0$ za $k \rightarrow \infty$.

Ako još vrijedi i Lipschitzov uvjet, onda je $\lambda_k \leq \frac{R}{m} \|x_k - x^*\|$, pa vrijedi

$$\|x_{k+1} - x^*\| \leq C \|x_k - x^*\|^2, \quad C = \frac{R}{m} \sqrt{\frac{M}{m}}.$$

♣

4.2. Quasi–Newtonove metode

Budući da problem minimizacije diferencijabilne funkcije $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ možemo gledati kao problem rješavanja jednadžbe

$$F(x) = 0, \quad F : \mathbb{R}^n \rightarrow \mathbb{R}^n$$

gdje je $F(x) = f'(x)$, najprije ćemo razmotriti problem rješavanja sustava nelinearnih jednadžbi.

Općenito se sustav nelinearnih jednadžbi, kao i problem minimizacije funkcije više varijabli rješava iterativnim metodama. Smatra se da je klasu novih "quasi-Newtonovih" metoda za rješavanje problema minimizacije funkcije više varijabli bez ograničenja uveo DAVIDON (1959), a za rješavanje sustava nelinearnih jednadžbi BROYDEN (1965). U literaturi su za klasu ovih metoda korišteni razni nazivi: *quasi-Newton, variable metric, variance, secant, update, modification methods*.

4.2.1. Sustavi nelinearnih jednadžbi

Za funkciju $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$ promatramo problem rješavanja jednadžbe $F(x) = 0$, odnosno sustava nelinearnih jednadžbi

$$f_i(x_1, \dots, x_n) = 0, \quad i = 1, \dots, n,$$

gdje su funkcije f_i komponente vektorske funkcije $F(x) = (f_1(x), \dots, f_n(x))^T$, $x = (x_1, \dots, x_n)^T$.

Pretpostavimo da funkcija F ima sljedeća svojstava

- (i) F je neprekidno diferencijabilna na otvorenom konveksnom skupu \mathcal{D} , tj. $F \in C^1(\mathcal{D})$;
- (ii) postoji $x^* \in \mathcal{D}$ tako da bude $F(x^*) = 0$, i da je pri tome $F'(x^*)$ nesingularna matrica ;

Dodatno, uz uvjete (4.20) možemo zahtijevati i ispunjenje jačeg *Lipschitzovog uvjeta*

$$(iii) \quad \|F'(x) - F'(X^*)\| \leq R\|x - x^*\|, \quad x \in \mathcal{D}. \quad (4.21)$$

Primijetite da ako je \mathcal{D} dovoljno malen, onda je ovaj uvjet ispunjen za dvostruko neprekidno diferencijabilnu funkciju u x^* .

Uz pretpostavku da imamo k -tu aproksimaciju x_k rješenja x^* , sljedeću $(k+1)$ -u aproksimaciju kod obične Newtonove metode dobit ćemo tako da funkciju F u okolini točke x_k pomoću Taylorove formule aproksimiramo linearnim aproksimandom

$$L(x) = F(x_k) + F'(x_k)(x - x_k)$$

i riješimo linearni sustav $L(x) = 0$. Tako dobivamo Newtonov iterativni postupak za rješavanje jednadžbe $F(x) = 0$

$$x_{k+1} = x_k - F'(x_k)^{-1}F(x_k).$$

Za praktičnu implementaciju obično koristimo sljedeći algoritam

Korak 1 za poznati x_k izračunati $F(x_k)$; ako je x_k prihvatljiv, stop. U protivnom izračunati $F'(x_k)$ i prijeći na **Korak 2**

Korak 2 riješiti sustav $F'(x_k)p = -F(x_k)$ za p , staviti $p_k := p$ i izračunati $x_{k+1} = x_k + p_k$.

Newtonova metoda poboljšava se uvođenjem parametra duljine koraka $0 < \alpha_k \leq 1$

$$x_{k+1} = x_k - \alpha_k F'(x_k)^{-1}F(x_k).$$

Karakteristike Newtonove metode dane su sljedećim teoremom (dokaz vidi u [15], str. 312)

Teorem 4.2. Neka funkcija $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$ zadovoljava pretpostavke (4.20). Tada postoji otvoren skup \mathcal{S} koji sadržava x^* , takav da je za proizvoljni $x_0 \in \mathcal{S}$ niz (x_n) definiran Newtonovim iterativnim postupakom dobro definiran, ostaje u \mathcal{S} i konvergira prema x^* superlinearnom brzinom, tj. postoji nul-niz (λ_n) , takav da je

$$\|x_{k+1} - x^*\| \leq \lambda_k \|x_k - x^*\|, \quad k = 0, 1, \dots.$$

Ako funkcija F dodatno zadovoljava Lipschitzov uvjet, onda je brzina konvergencije kvadratična, tj. postoji konstanta β takva da je

$$\|x_{k+1} - x^*\| \leq \beta \|x_k - x^*\|, \quad k = 0, 1, \dots.$$

Primjedba 4.1. Može se pokazati (vidi [7]) da za niz (x_n) , koji superlinearnom brzinom konvergira prema x^* , vrijedi

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - x_k\|}{\|x_k - x^*\|} = 1$$

uz uvjet da je $x_k \neq x^*$ za sve $k = 0, 1, \dots$

Kako je [$||\alpha| - |\beta|| \leq |\alpha - \beta|$]

$$||x_{k+1} - x_k|| - ||x_k - x^*|| \leq ||x_{k+1} - x^*||,$$

nakon dijeljenja s $||x_k - x^*||$ i koristeći $||x_{k+1} - x^*|| \leq \lambda_k ||x_k - x^*||$, $\lambda_k \rightarrow 0$, dobivamo

$$\left| \frac{||x_{k+1} - x_k||}{||x_k - x^*||} - 1 \right| \leq \frac{||x_{k+1} - x^*||}{||x_k - x^*||} \leq \lambda_k \rightarrow 0$$

Na osnovi *Primjedbe 4.1.* pored kriterija $\|F(x_k)\| < \varepsilon_1$ za zaustavljanje procesa ima smisla koristiti dodatni kriterij $||x_{k+1} - x_k|| < \varepsilon_2 ||x_k||$

Prethodnim teoremom iskazane su dvije osnovne prednosti Newtonove metode:

- postoji područje prihvaćanja \mathcal{S} Newtonove iterativne metode,
- visoka brzina konvergencije u području prihvaćanja \mathcal{S} .

Nedostaci Newtonove metode su

- potreba izbora dobre početne aproksimacije x_0 ,
- u svakom koraku treba računati matricu parcijalnih derivacija reda n .

U cilju prevladavanja naročito posljednjeg navedenog nedostatka, matricu $F'(x_k)$ (odnosno matricu $F'(x_k)^{-1}$) zamijenit ćemo nekom matricom B_k (odnosno matricom H_k), koja se lako računa, a nalikuje na matricu $F'(x_k)$ (odnosno matricu $F'(x_k)^{-1}$). Tako promatramo iterativne procese

$$\begin{aligned} x_{k+1} &:= x_k - \alpha_k B_k^{-1} F(x_k), \\ \text{odnosno } x_{k+1} &:= x_k - \alpha_k H_k F(x_k). \end{aligned} \tag{4.22}$$

Vrijedi sljedeći teorem (vidi [7])

Teorem 4.3. Neka funkcija $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$ zadovoljava uvjete (4.20), a niz (B_k) neka je niz regularnih matrica. Prepostavimo nadalje da za neki $x_0 \in \mathcal{D}$ niz (x_n) definiran s (4.22) ostaje u \mathcal{D} , $x_k \neq x^*$ za sve $k = 0, 1, \dots$ i konvergira prema x^* . Tada niz (x_n) konvergira superlinearno prema x^* onda i samo onda ako

$$\lim_{k \rightarrow \infty} \frac{(B_k - F'(x^*)) (\|p_k\|)}{\|p_k\|} = 0, \quad p_k = x_{k+1} - x_k. \tag{4.23}$$

Uvjet (4.23) zahtijeva da niz matrica (B_n) konvergira prema $F'(x^*)$ u smjeru vektora kretanja $p_k = x_{k+1} - x_k$.

Primjedba 4.2. Uvjet (4.23) ekvivalentan je uvjetu (vidi primjerice [10])

$$\lim_{k \rightarrow \infty} \frac{\|B_k p_k - y_k\|}{\|p_k\|} = 0, \quad y_k := F(x_{k+1} - F(x_k)), \tag{4.24}$$

što znači da uvjet $B_k p_k \approx y_k$ također garantira superlinearnu konvergenciju.

Ne može se očekivati da bude $B_k p_k = y_k$, ali zato ćemo matricu B_{k+1} brati tako da bude ispunjen tzv. quasi-Newtonov uvjet

$$B_{k+1} p_k = y_k. \tag{4.25}$$

i da je za poznate p_k, y_k, B_k lako izračunati B_{k+1} . Iterativna metoda (4.22) pri čemu niz matrica (B_n) ispunjavaju quasi-Newtonov uvjet naziva se **quasi-Newtonova metoda**. Radi pojednostavljivanja uvedimo sljedeće označke:

$$\begin{aligned} B &:= B_k, & \bar{B} &:= B_{k+1}, & x &:= x_k, & \bar{x} &:= x_{k+1} \\ p &:= p_k = \bar{x} - x, & y &:= y_k = F(\bar{x}) - F(x). \end{aligned}$$

Uz ove označke quasi-Newtonov uvjet glasi

$$\bar{B}p = y.$$

Broyden je 1965. godine prvi puta u radu [3] uveo takav niz matrica, u literaturi poznat pod nazivom **Broydenova korekcija ranga 1**

$$\bar{B} = B + \frac{(y - Bp)p^T}{p^T p}. \quad (4.26)$$

Zadatak 4.1. Provjerite da vrijedi

$$\bar{B}p = y \text{ i } Bz = \bar{B}z \quad \text{za sve } z \text{ takve da je } p^T z = 0.$$

Sljedeći teorem pokazuje da je matrica \bar{B} definirana s (4.26) jedinstvena matrica koja ispunjava quasi-Newtonov uvjet, a najmanje se razlikuje od matrice B .

Teorem 4.4. Za danu matricu $B \in \mathbb{R}^{n \times n}$, $y \in \mathbb{R}^n$ i neki nenul vektor $p \in \mathbb{R}^n$ matrica \bar{B} je jedinstveno rješenje problema minimizacije

$$\min_{\hat{B}} \left\{ \|\hat{B} - B\|_F : \hat{B}p = y \right\},$$

gdje je $\|\cdot\|_F$ Frobenijusova norma.¹

Dokaz. Naprije primijetimo da za proizvoljnu matricu \hat{B} , za koju vrijedi quasi-Newtonov uvjet $\hat{B}p = y$ vrijedi

$$\begin{aligned} \|\bar{B} - B\|_F &= \left\| \frac{(y - Bp)p^T}{p^T p} \right\|_F = \left\| \frac{(\hat{B} - B)p p^T}{p^T p} \right\|_F = \\ &\leq \|\hat{B} - B\|_F \left\| \frac{p p^T}{p^T p} \right\|_F = \left[\|p p^T\|_F = \sum_{ij} (p_i p_j)^2 = \left(\sum_i p_i^2 \right) \left(\sum_j p_j^2 \right) = (p^T p)^2 \right] \\ &= \|\hat{B} - B\|_F \end{aligned}$$

Kako je skup svih $\hat{B} \in \mathbb{R}^{n \times n}$, takvih da je $\hat{B}p = y$ konveksan, a funkcija $\Phi : \mathbb{R}^{n \times n} \mapsto \mathbb{R}$, $\Phi(A) = \|B - A\|_F$ strogo konveksna, matrica \bar{B} na kojoj se postiže minimum je jedinstvena. ♣

Sljedeći teorem pokazuje superlinearnu konvergenciju Broydenove metode. Dokaz se može vidjeti u [7].

Teorem 4.5. Uz uvjete (4.20), (4.21) postoji $\varepsilon > 0$, takav da za proizvoljne x_0 , odnosno B_0 , koji zadovoljavaju $\|x_0 - x^*\| \leq \varepsilon$, odnosno $\|B_0 - F'(x^*)\| \leq \varepsilon$, iterativna metoda (4.22) uz $\alpha_k \equiv 1$ i korekciju (4.26) definira niz (x_n) , koji superlinearnom brzinom konvergira prema x^* .

¹Može se pokazati (vidi primjerice [7]) da za proizvoljnu kvadratnu matricu A reda n vrijedi

$$\|A\|_F^2 = \text{Tr}(A^T A) = \sum_{i=1}^n \|Av_i\|_2^2,$$

za proizvoljni ortonormirani skup v_1, \dots, v_n u \mathbb{R}^n .

Broydenova quasi-Newtonova metoda definirana je dakle, na sljedeći način

$$x_{k+1} = x_k - B_k^{-1} F(x_k), \quad k = 0, 1, \dots, \quad (4.27)$$

gdje se matrice B_k generiraju rekurzivnom formulom

$$B_{k+1} = B_k + \frac{(y_k - B_k p_k) p_k^T}{(p_k, p_k)}, \quad k = 0, 1, \dots, \quad (4.28)$$

gdje je

$$y_k = F(x_{k+1}) - F(x_k), \quad p_k = x_{k+1} - x_k. \quad (4.29)$$

Primjedba 4.3. Navedena Broydenova metoda (4.27-4.29) na svakom koraku uključuje riješavanje sustav linearnih jednadžbi $B_k p_k = -F(x_k)$. To se može izbjegći tako da definiramo tzv. inverznu Broydenovu metodu

$$\begin{aligned} x_{k+1} &= x_k - H_k F(x_k), \\ H_{k+1} &= H_k + \frac{(p_k - H_k y_k) p_k^T H_k}{(p_k, H_k y_k)}, \quad (p_k, H_k y_k) \neq 0 \end{aligned} \quad (4.30)$$

Pri tome koristi se tzv. Sherman-Morrisonova lema

Lema 4.1. Neka je $u, v \in \mathbb{R}^n$, a $A \in \mathbb{R}^{n \times n}$ regularna matrica. Tada je $A + uv^T$ regularna onda i samo onda ako je $\sigma = 1 + (v, A^{-1}u) \neq 0$. Ako je $\sigma \neq 0$, vrijedi

$$(A + uv^T)^{-1} = A^{-1} - \frac{1}{\sigma} A^{-1} u v^T A^{-1} \quad (4.31)$$

Dokaz ove leme provodi se korištenjem niže navedene Leme 4.2. (vidi primjerice [7]) i dirktnom provjerom.

Lema 4.2. Za zadane $v, w \in \mathbb{R}^n$ vrijedi

$$\det(I + vw^T) = 1 + (v, w). \quad (4.32)$$

Dokaz. Označimo $P = I + vw^T$. Pretpostavimo da je $v \neq 0$; u protivnom dokaz je trivijalan.

Neka je λ svojstvena vrijednost, a x odgovarajući svojstveni vektor od P . Tada mora biti

$$Px = \lambda x \Rightarrow (I + vw^T)x = \lambda x \Rightarrow x + v(w^T x) = \lambda x.$$

Ova jednakost može biti ispunjena ili tako da je $w \perp x$ ili da je $v \parallel x$.

Dakle, svaki svojstveni vektor od P je ili okomit na w ili paralelan s v . 1. Ako je $w \perp x$, onda je $\lambda = 1$.

2. Ako je $v \parallel x$, tj. $x = \alpha v$, tada je

$$\alpha v + vw^T \alpha v = \lambda \alpha v \Rightarrow v(1 + w^T v) = \lambda v \Rightarrow \lambda = 1 + (v, w).$$

Budući da može postojati samo jedan svojstveni vektor kolinearan s v , to znači da matrica P ima jednu svojstvenu vrijednost $1 + (v, w)$, dok su preostalih $(n - 1)$ jenake 1. Time je lema dokazana. ♣

Sada možemo računati

$$\begin{aligned} B_{k+1}^{-1} &= \left(B_k + \frac{y_k - B_k p_k}{(p_k, p_k)} p_k^T \right)^{-1} = B_k^{-1} - \frac{1}{\sigma} B_k^{-1} \frac{y_k - B_k p_k}{(p_k, p_k)} p_k^T B_k^{-1} \\ [\sigma(p_k, p_k)] &= \left(1 + p_k^T B_k^{-1} \frac{y_k - B_k p_k}{(p_k, p_k)} \right) (p_k, p_k) = (p_k, p_k) + p_k^T B_k^{-1} y_k - p_k^T p_k = (p_k, B_k^{-1} y_k) \\ &= B_k^{-1} + \frac{p_k p_k^T B_k^{-1} - B_k^{-1} y_k p_k^T B_k^{-1}}{(p_k, B_k^{-1} y_k)} = \\ &= B_k^{-1} + \frac{(p_k - B_k^{-1} y_k) p_k^T B_k^{-1}}{(p_k, B_k^{-1} y_k)} \end{aligned}$$

Odavde uz oznake: $H_k := B_k^{-1}$ i $H_{k+1} := B_{k+1}^{-1}$ dobivamo (4.30).

Zadatak 4.2. Na osnovi Leme 4.2. dokažite Sherman–Morrisonovu lemu (Lema 4.1.)

4.2.2. Minimizacija glatke funkcije

Promatramo sada problem minimizacije bez ograničenja dovoljno glatke funkcije $f : \mathbb{R}^n \rightarrow \mathbb{R}$. Pretpostavimo da je x^* strogi lokalni minimum funkcije f . Tada je prema **Teoremu 1.3.** $f'(x^*) = 0$, a $f''(x^*)$ je pozitivno definitna Hesseova matrica. Uz oznaku $F(x) := f'(x)$, te slijedeći uvjeti (4.20) i (4.20) definirat ćemo uvjet na funkciju $f : \mathbb{R}^n \rightarrow \mathbb{R}$:

- (i) f je dvostruko neprekidno diferencijabilna na otvorenom konveksnom skupu \mathcal{D} , tj. $f \in C^2(\mathcal{D})$;
 - (ii) postoji $x^* \in \mathcal{D}$ tako da bude $f'(x^*) = 0$, a $f''(x^*)$ je pozitivno definitna matrica ;
 - (iii) f'' je u x^* zadovoljava Lipschitzov uvjet
- $$\|f''(x) - f''(x^*)\| \leq R\|x - x^*\| \text{ za sve } x \in \mathcal{D}$$

Uz oznaku $g(x) := f'(x)$ i $g_k = g(x_k)$ iterativna procedura (4.22) postaje

$$x_{k+1} := x_k - \alpha_k B_k^{-1} g_k,$$

odnosno $x_{k+1} := x_k - \alpha_k H_k g_k$,

gdje je sada B_k aproksimacija hessijana $f''(x_k)$, a $H_k = B_k^{-1}$, pri čemu duljinu koraka α_k dobivamo jednodimenzionalnom minimizacijom

$$f(x_{k+1}) \approx \min_{\alpha \geq 0} f(x_k + \alpha p_k), \quad p_k := -B_k^{-1} g_k = -H_k g_k.$$

Budući da matrice B_k trebaju aproksimirati hessian $f''(x_k)$, za njih se mora pretpostaviti simetričnost. Slično kao i ranije uvedimo oznake

$$B := B_k, \quad \overline{B} := B_{k+1}$$

$$p := p_k = x_{k+1} - x_k \quad y := y_k = g_{k+1} - g_k \quad (\text{zbog } g(x) = F(x))$$

Jedna mogućnost za definiranje korekcije ranga 1 je **simetrična formula ranga 1** koju je uveo DAVIDON (1959):

$$\overline{B} = B + \frac{(y - Bp)(y - Bp)^T}{(y - Bp, p)}, \quad (y - Bp, p) \neq 0 \quad (4.33)$$

Zadatak 4.3. Pokažite da ako postoje matrice: $H := B^{-1}$ i $\overline{H} := \overline{B}^{-1}$ i ako je B simetrična, tada vrijedi

$$\overline{H} = H + \frac{(p - Hy)(p - Hy)^T}{(p - Hy, y)} \quad (4.34)$$

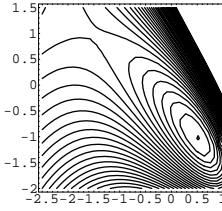
Primjer 4.1. Potražimo lokalni minimum funkcije

$$f(x_1, x_2) = e^{x_1} (4x_1^2 + 2x_2^2 + 4x_1 x_2 + 2x_2 + 1)$$

Gradijent, hessian i ContourPlot dobit ćemo na sljedeći način

```
In[1]:= f[x_] := Exp[x[1]] (4x[1]^2 + 2x[2]^2 + 4x[1]x[2] + 2x[2] + 1); n = 2;
g[x_] := Table[D[f[x], x[i]], {i, n}]
H[x_] := Table[D[g[x][[i]], x[j]], {i, n}, {j, n}]
Print["f'=", Simplify[g[x] /. {x[1] -> x1, x[2] -> x2}] // MatrixForm,
      " H=", Simplify[H[x] /. {x[1] -> x1, x[2] -> x2}] // MatrixForm]
ContourPlot[f[x] /. {x[1] -> x1, x[2] -> x2}, {x1, -2.5, 1}, {x2, -2, 1.5},
            Contours -> 40, PlotPoints -> 30, ContourShading -> None];
```

$$f' = \begin{bmatrix} e^{x_1}(1 + 4x_1^2 + 6x_2 + 2x_2^2 + 4x_1(2 + x_2)) \\ e^{x_1}(2 + 4x_1 + 4x_2) \end{bmatrix}, \quad H = \begin{bmatrix} e^{x_1}(9 + 4x_1^2 + 10x_2 + 2x_2^2 + 4x_1(4 + x_2)) & e^{x_1}(3 + 2x_1 + 2x_2) \\ e^{x_1}(3 + 2x_1 + 2x_2) & e^{x_1} \end{bmatrix}$$



Zadavanjem ulaznih podataka

```
In[2]:= n = 2; x0 = {1., 1}; k = 0; eps = 0.005;
w = Table[x[i] -> x0[[i]], {i, n}]; B0 = IdentityMatrix[n];
B0 = H[x] /. w
g0 = g[x] /. w
```

i korištenjem programa (modul Korak definiran je ranije kod *Metode najbržeg silaska*)

```
In[3]:= While[
p0 = -LinearSolve[B0, g0];
alpha = Korak[n, f, p0, x0];
x1 = x0 + alpha p0;
w1 = Table[x[i] -> x1[[i]], {i, n}]; g1 = g[x] /. w1;
y0 = g1 - g0;
B1 = B0 + Outer[Times, (y0 - B0.p0), (y0 - B0.p0)]/((y0 - B0.p0) . p0);
f1 = f[x] /. w1;
Abs[f1] > eps,
B0 = B1; g0 = g1;
x0 = x1; k = k + 1;
Print["x", k, "= ", x1, " fx=", f[x] /. w1, " grad=", g1, " alpha=", alpha]
];
Print["x", k + 1, "= ", x1, " fx=", f[x] /. w1, " grad=", g1, " alpha=", alpha]
```

nakon 18 itracija dobivamo

```
{x_18 = {-11.43, 19.80}, fx=0.00479, grad= {0.0047, 0.00038}, alpha=1}
```

Zadatak 4.4. Slično kao u Primjedbi 4.3. definirajte inverznu simetričnu formulu ranga 1.

Slično Teoremu 4.4., vrijedi

Teorem 4.6. Neka je $M \in \mathbb{R}^{n \times n}$ simetrična regularna matrica, $y, p \in \mathbb{R}^n$ ($p \neq 0$) i $c := M^{-2}p$. Ako je B simetrična matrica, tada je rješenje problema minimizacije

$$\min_{\hat{B}} \left\{ \|M(\hat{B} - B)M\|_F : \hat{B} = \hat{B}^T, \hat{B}p = y \right\}, \quad (4.35)$$

zadano s

$$\overline{B} = B + \frac{(y - Bp)c^T + c(y - Bp)^T}{c^T p} - \frac{(y - Bp)^T p}{(c^T p)^2} cc^T. \quad (4.36)$$

Matricom M definirana je težinska Frobeniusova norma, \overline{B} je također simetrična matrica, koja ispunjava quasi-Newtonov uvjet $\overline{B}p = y$ i po težinskoj Frobeniusovoj normi najmanje se razlikuje od matrice B . Formulu (4.36) zovemo korekcija ranga 2 jer se \overline{B} dobiva tako da matrici B dodamo jednu matricu ranga 2

Zadatak 4.5. Dva različita dokaza ovog teorema mogu se vidjeti u [10] i [7]. Izvedite i usporedite oba dokaza.

Pokazat ćemo (vidi [7]) kako se izvodi quasi-Newtonova korekcija ranga 2 zadana s (4.36) jer je to način kako se mogu izvesti i druge poznate korekcije ranga 2. Polazimo od simetrične matrice $B \in \mathbb{R}^{n \times n}$, te slično Broydenovoj korekciji ranga 1 (4.26) kao mogućeg kandidata za \bar{B} promatramo

$$C_1 = B + \frac{(y - Bp)c^T}{(c, p)}.$$

koji ispunjava quasi-Newtonov uvjet $C_1p = y$. Budući da C_1 općenito nije simetrična matrica, definiramo simetričnu matricu

$$C_2 = \frac{1}{2} (C_1 + C_1^T).$$

Budući da C_2 ne ispunjava quasi-Newtonov uvjet, ponovimo proceduru i tako rekursivno definiramo niz (C_n)

$$\begin{aligned} C_{2k+1} &= C_{2k} + \frac{(y - C_{2k}p)c^T}{(c, p)}, \\ C_{2k} &= \frac{1}{2} (C_{2k+1} + C_{2k+1}^T), \end{aligned} \quad (4.37)$$

gdje je $C_0 = B$. Vrijedi

Lema 4.3. Neka je $B \in \mathbb{R}^{n \times n}$ simetrična matrica i $c, p, y \in \mathbb{R}^n$ sa svojstvom $(c, p) \neq 0$. Tada niz (C_n) zadan rekursivnom formulom (4.37) uz $C_0 = B$ konvergira prema \bar{B} zadanom s (4.36).

Dokaz. Dokažimo da niz (C_{2k}) konvergira. Uz oznaku $G_k = C_{2k}$ iz (4.37) dobivamo

$$\begin{aligned} G_{k+1} = C_{2(k+1)} &= \frac{1}{2} (C_{2k+1} + C_{2k+1}^T) = \frac{1}{2} \left(G_k + \frac{(y - G_k p)c^T}{(c, p)} + G_k^T + \frac{c(y - G_k p)^T}{(c, p)} \right) \\ &= G_k + \frac{w_k c^T + c w_k^T}{2(c, p)}, \end{aligned}$$

gdje je $w_k = y - G_k p$. Koristeći dobivenu jednakost dobivamo

$$\begin{aligned} w_{k+1} = y - G_{k+1}p &= y - G_k p - \frac{1}{2} \frac{w_k c^T + c w_k^T}{(c, p)} p = w_k - \frac{1}{2} \frac{w_k c^T p}{(c, p)} - \frac{1}{2} \frac{c w_k^T p}{(c, p)} \\ &= \frac{1}{2} w_k - \frac{1}{2} \frac{c(p^T w_k)}{(c, p)}, \end{aligned}$$

što možemo pisati kao

$$w_{k+1} = Pw_k, \quad P = \frac{1}{2} \left[I - \frac{cp^T}{(c, p)} w_k \right]$$

Prema Lemi 4.2. matrica P ima jednu svojstvenu vrijednost $0 \left[\frac{1}{2} \left(1 - \left(\frac{c}{(c, p)}, p \right) \right) = 0 \right]$ i svojstvenu vrijednost $\frac{1}{2}$ kratnosti $(n-1)$. Dakle, spektralni radijus matrice P je $\rho(P) = \frac{1}{2} < 1$. Prema Neumannovoj lemi (vidi primjerice [15], str. 45) tada postoji matrica $(I - P)^{-1}$ i vrijedi

$$(I - P)^{-1} = \lim_{k \rightarrow \infty} \sum_{i=0}^k P^k.$$

Kako je s druge strane

$$w_k = Pw_{k-1} = \cdots = P^k w_0 = P^k (y - Bp),$$

onda imamo

$$\sum_{k=0}^{\infty} w_k = \sum_{k=0}^{\infty} P^k(y - Bp) = (I - P)^{-1}(y - Bp).$$

Također vrijedi

$$\begin{aligned} \sum_{k=0}^n (G_{k+1} - G_k) &= G_{n+1} - G_0 \quad \Rightarrow \quad \sum_{k=0}^{\infty} (G_{k+1} - G_k) = \lim_{n \rightarrow \infty} (G_{n+1} - G_0) \quad \Rightarrow \\ &\Rightarrow \quad \sum_{k=0}^{\infty} (G_{k+1} - G_k) = \lim_{k \rightarrow \infty} G_k - B \end{aligned}$$

Zato vrijedi

$$\begin{aligned} \lim_{k \rightarrow \infty} G_k &= B + \sum_{k=0}^{\infty} (G_{k+1} - G_k) = B + \sum_{k=0}^{\infty} \frac{1}{2} \frac{w_k c^T + c w_k^T}{(c, p)} = B + \frac{1}{2(c, p)} \sum_{k=0}^{\infty} w_k c^T + \frac{1}{2(c, p)} \sum_{k=0}^{\infty} c w_k^T \\ &= B + \frac{1}{2(c, p)} [(I - P)^{-1}(y - Bp)c^T + c(y - Bp)^T(I - P^T)^{-1}] = \\ &\text{prema Lemi 4.1.: } I - P = I - \frac{1}{2} \left[I - \frac{cp^T}{(c, p)} \right] = \frac{1}{2} \left[I + \frac{cp^T}{(c, p)} \right], \quad \sigma = 1 + p^T \frac{c}{(c, p)} = 2 \\ &(I - P)^{-1} = 2 \left[I - \frac{1}{2} \frac{cp^T}{(c, p)} \right], \quad (I - P^T)^{-1} = 2 \left[I - \frac{1}{2} \frac{pc^T}{(c, p)} \right] \\ &= B + \frac{1}{2(c, p)} \left\{ 2 \left[I - \frac{1}{2} \frac{cp^T}{(c, p)} \right] (y - Bp)c^T + c(y - Bp)^T 2 \left[I - \frac{1}{2} \frac{pc^T}{(c, p)} \right] \right\} \\ &= B + \frac{1}{(c, p)} \left\{ (y - Bp)c^T + c(y - Bp)^T - \frac{1}{2} \frac{cp^T}{(c, p)} (y - Bp)c^T - \frac{1}{2} c(y - Bp)^T \frac{pc^T}{(c, p)} \right\} \\ &= B + \frac{1}{(c, p)} \left\{ (y - Bp)c^T + c(y - Bp)^T - \frac{c(y - Bp)^T pc^T}{(c, p)} \right\} \end{aligned}$$

iz čega neposredno slijedi (4.36). ♣

Specijalno za $c = p$ dobiva se Powell–Broydenova simetrična korekcija (Powell Symetric Broyden - PSB)

$$\overline{B}_P SB = B + \frac{(y - Bp)p^T + p(y - Bp)^T}{(p, p)} - \frac{((y - Bp), p)pp^T}{(p, p)^2}. \quad (4.38)$$

4.2.3. Korekcije koje čuvaju pozitivnu definitnost

Do sada smo promatrali korekcije ranga 1 ili 2 koje su čuvale simeričnost matrice B i zadovoljavale quasi-Newtonov uvjet. Dodatni zahtjev koji se postavlja bit će čuvanje pozitivne definitnosti. Quasi-Newtonov uvjet zajedno s uvjetom čuvanja pozitivne definitnosti matrice B pobliže određuje kut između vektora p i y :

$$(y, p) > 0 \quad \left[(y, p) \stackrel{\overline{B}p=y}{=} (\overline{B}p, p) \right]$$

U cilju ispitivanja nasljednosti pozitivne definitnosti koristit ćemo sljedeću lemu (vidi primjerice [7])

Lema 4.4. Neka je $A \in \mathbb{R}^{n \times n}$ simetrična matrica sa svojstvenim vrijednostima

$$\lambda_1 \leq \lambda_2 \leq \cdots \leq \lambda_n,$$

i neka je $A^T = A + \sigma uu^T$ za neki $u \in \mathbb{R}^n$. Ako je $\sigma \geq 0$, onda A^T ima svojstvene vrijednosti λ_i^T , takve da je

$$\lambda_1 \leq \lambda_1^T \leq \lambda_2 \leq \cdots \leq \lambda_n \leq \lambda_n^T,$$

a ako je $\sigma \leq 0$, onda A^T ima svojstvene vrijednosti λ_i^T , takve da je

$$\lambda_1^T \leq \lambda_1 \leq \lambda_2^T \leq \cdots \leq \lambda_n^T \leq \lambda_n.$$

Teorem 4.7. Neka je $B \in \mathbb{R}^{n \times n}$ simetrična pozitivno definitna matrica i neka su $c, p, y \in \mathbb{R}^n$ takvi da je $(c, p) \neq 0$. Tada je \bar{B} definiran s (4.36) pozitivno definitna matrica onda i samo onda ako je $\det \bar{B} > 0$.

Dokaz. Ako je $\bar{B} > 0$, onda je iz opće teorije poznato da je $\det \bar{B} > 0$. Za dokaz obrata, matricu \bar{B} napišimo najprije u obliku

$$\begin{aligned}\bar{B} &= B + \frac{(y-Bp)c^T + c(y-Bp)^T}{c^T p} - \frac{(y-Bp)^T p}{(c^T p)^2} cc^T \\ \bar{B} &= B + vw^T + \textcolor{red}{wv}^T,\end{aligned}$$

gdje je

$$v = \frac{y - Bp}{(c, p)} - \frac{1}{2} \frac{(y - Bp, p)}{(c, p)^2} c, \quad w = c.$$

Zbog toga je $[(v+w)(v+w)^T - (v-w)(v-w)^T] = (\|v\|^2 + \|w\|^2 + 2vw^T) - (\|v\|^2 + \|w\|^2 - 2wv^T)$

$$\bar{B} = B + \frac{1}{2} ((v+w)(v+w)^T - (v-w)(v-w)^T)$$

Na taj način smo \bar{B} napisali kao zbroj od jedne pozitivno definitne matrice (B) i dvije simetrične matrice ranga 1. Matrica

$$C = B + \frac{1}{2}(v+w)(v+w)^T$$

prema Lemi 4.4. je pozitivno definitna jer je $\sigma = \frac{1}{2} > 0$. Nadalje, također prema Lemi 4.4., obzirom da je $C > 0$ i $\sigma = -\frac{1}{2} < 0$ matrica

$$\bar{B} = C - \frac{1}{2}(v-w)(v-w)^T$$

može imati najviše jednu svojstvenu vrijednost nepozitivnu. Kako je s druge strane

$$0 < \det \bar{B} = \lambda_1 \cdots \lambda_n$$

i ta jedna svojstvena vrijednost mora biti pozitivna. Dakle, $\bar{B} > 0$. ♣

U cilju ispitivanje za koji $c \in \mathbb{R}^n$ će rekurzivna formula (4.36) čuvati pozitivnu definitnost sljedeća lema ispituje $\det \bar{B}$.

Lema 4.5. Neka je $u_i \in \mathbb{R}^n$, $i = 1, 2, 3, 4$. Tada vrijedi

$$\det(I + u_1 u_2^T + u_3 u_4^T) = (1 + (u_1, u_2))(1 + (u_3, u_4)) - (u_1, u_4)(u_2, u_3).$$

Dokaz. Ako trenutno pretpostavimo da je $(u_1, u_2) \neq -1$, tj. da je, sukladno Sherman-Morrisonovoj lemi, $I + u_1 u_2^T$ regularna matrica, onda možemo pisati

$$I + u_1 u_2^T + u_3 u_4^T = (I + u_1 u_2^T) (I + (I + u_1 u_2^T)^{-1} u_3 u_4^T)$$

Zato je $\det(I + u_1 u_2^T + u_3 u_4^T) = D_1 \cdot D_2$, gdje je

$$\begin{aligned}D_1 &= \det(I + u_1 u_2^T) = 1 + (u_1, u_2), \\ D_2 &= \det(I + (I + u_1 u_2^T)^{-1} u_3 u_4^T).\end{aligned}$$

Kako je $(I + (I + u_1 u_2^T)^{-1})^{-1} I = I - \frac{1}{1+(u_1,u_2)} u_1 u_2^T$, onda

$$\begin{aligned}D_2 &= \det \left[I + \left(I - \frac{u_1 u_2^T}{1+(u_1,u_2)} \right) u_3 u_4^T \right] = \det \left[I + u_3 u_4^T - \frac{u_1 u_2^T u_3 u_4^T}{1+(u_1,u_2)} \right] \\ &= \det \left[I + \left(u_3 - \frac{(u_2, u_3)}{1+(u_1,u_2)} u_1 \right) u_4^T \right] = 1 + \left(u_3 - \frac{(u_2, u_3)}{1+(u_1,u_2)} u_1, u_4 \right) \\ &= 1 + (u_3, u_4) - \frac{(u_2, u_3)}{1+(u_1,u_2)} (u_1, u_4),\end{aligned}$$

iz čega slijedi tražena jednakost. ♣

Primjenom **Leme 4.5.** na (4.36) uz pretpostavku da je postoji B^{-1} i oznaku $H := B^{-1}$, dobivamo

$$\det \overline{B} = \det B \left[((c, Hy)^2 - (c, Hc)(y, Hy) + (c, Hc)(y, p)) \frac{1}{(c, p)^2} \right]. \quad (4.39)$$

U svrhu dokaza ove formule najprije ćemo (4.36)

$$\overline{B} = B + \frac{(y - Bp)c^T + c(y - Bp)^T}{c^T p} - \frac{(y - Bp)^T p}{(c^T p)^2} cc^T$$

napisati u obliku [$(y - Bp)^T p$ je broj pa ga možemo "staviti unutar" cc^T]

$$\overline{B} = B + \frac{1}{(c, p)} \left[(y - Bp)c^T + c(y - Bp)^T \left(I - \frac{pc^T}{(c, p)} \right) \right]$$

Uvođenjem oznake $H := B^{-1}$, dobivamo

$$\overline{B} = B \left[I + \frac{H(y - Bp)}{(c, p)} c^T + Hc \frac{(y - Bp)^T}{(c, p)} \left(I - \frac{pc^T}{(c, p)} \right) \right].$$

Sada vrijedi

$$\det \overline{B} = \det B \det (I + u_1 u_2^T + u_3 u_4^T)$$

gdje je

$$\begin{aligned} u_1 &= \frac{Hy - p}{(c, p)}, & u_2 &= c, \\ u_3 &= Hc, & u_4 &= \left(I - \frac{cp^T}{(c, p)} \right) \frac{(y - Bp)}{(c, p)}. \end{aligned}$$

Prema **Leći 4.5.** je $\det (I + u_1 u_2^T + u_3 u_4^T) = (1 + (u_1, u_2))(1 + (u_3, u_4)) - (u_1, u_4)(u_2, u_3)$, gdje je

$$\begin{aligned} 1 + (u_1, u_2) &= 1 + c^T \frac{Hy - p}{(c, p)} = 1 + \frac{c^T Hy}{(c, p)} - \frac{c^T p}{(c, p)} = \frac{c^T Hy}{(c, p)} \\ 1 + (u_3, u_4) &= 1 + c^T \left(H - \frac{Hcp^T}{(c, p)} \right) \frac{(y - Bp)}{(c, p)} = 1 + \frac{c^T}{(c, p)} \left(Hy - \frac{Hcp^T y}{(c, p)} - s + \frac{Hcp^T Bp}{(c, p)} \right) = \\ &= 1 + \frac{c^T Hy}{(c, p)} - \frac{c^T Hcp^T y}{(c, p)^2} - 1 + \frac{c^T Hcp^T Bp}{(c, p)^2}, \\ (1 + (u_1, u_2))(1 + (u_3, u_4)) &= \frac{(c, Hy)^2}{(c, p)^2} - \frac{(c, Hy)(c, Hc)(p, y)}{(c, p)^3} + \frac{(c, Hy)(c, Hc)(p, Bp)}{(c, p)^3} \\ (u_1, u_4) &= \frac{y^T H - p^T}{(c, p)^2} \left(I - \frac{cp^T}{(c, p)} \right) (y - Bp) = \frac{y^T Hy}{(c, p)^2} - \frac{p^T y}{(c, p)^2} - \frac{y^T Hcp^T y}{(c, p)^3} + \frac{y^T Hcp^T Bp}{(c, p)^3} \end{aligned},$$

iz čega slijedi

$$\det (I + u_1 u_2^T + u_3 u_4^T) = \frac{(c, Hy)^2}{(c, p)^2} - \frac{(c, Hc)(y, Hy)}{(c, p)^2} + \frac{(c, Hc)(y, p)}{(c, p)^2}$$

i tražena formula (4.39). Ako pretpostavimo da je $B > 0$, onda je i $H := B^{-1} > 0$, pa možemo definirati $v = H^{1/2}y$ i $w = H^{1/2}c$. Time (4.39) postaje

$$\det \overline{B} = \det B \left[((v, w)^2 - \|v\|^2 \|w\|^2 + \|w\|^2 (y, p)) \frac{1}{(c, p)^2} \right]. \quad (4.40)$$

Na osnovi **Teorema 4.7.** zaključujemo da je $\overline{B} > 0$ onda i samo onda ako vrijedi

$$\|w\|^2 (y, p) > \|v\|^2 \|w\|^2 - (v, w)^2. \quad (4.41)$$

Jednostavan način kako se može zadovoljiti ova nejednakost uveo je Davidon (1959) (kasnije objašnjeno i implementirano u radu Fletchera i Powella 1963). Naime ako je $w \parallel v$ (odnosno $c \parallel y$), onda je (4.41) zadovoljeno ako je $(y, p) > 0$. Zato se poznata Davidon – Fletcher – Powella korekcija (DFP) ranga 2 dobiva iz (4.36) uz $c = y$

$$\begin{aligned}\overline{B}_{DFP} &= B + \frac{(y-Bp)y^T + y(y-Bp)^T}{(y,p)} - \frac{(y-Bp,p)}{(y,p)^2} yy^T \\ &= \left(I - \frac{yp^T}{(y,p)}\right) B \left(I - \frac{py^T}{(y,p)}\right) + \frac{yy^T}{(y,p)}.\end{aligned}\quad (4.42)$$

Zadatak 4.6. Provjerite valjanost formula (4.42)!

Vrijedi sljedeći teorem

Teorem 4.8. Neka je $B \in \mathbb{R}^{n \times n}$ regularna simetrična matrica i neka je $\overline{B}_{DFP} \in \mathbb{R}^{n \times n}$ definiran sa (4.42) za neke vektore $y, p \in \mathbb{R}^n$, koji zadovoljavaju $(y, p) \neq 0$.

Tada je \overline{B}_{DFP} regularna onda i samo onda ako je $(y, Hy) \neq 0$, gdje je $H := B^{-1}$.

Ako je \overline{B}_{DFP} regularna, tada se $\overline{H}_{DFP} := \overline{B}_{DFP}^{-1}$ može zapisati kao

$$\overline{H}_{DFP} = H + \frac{pp^T}{(y,p)} - \frac{Hy y^T H}{(y, Hy)}.\quad (4.43)$$

Nadalje, ako je $B > 0$, onda je i $\overline{B}_{DFP} > 0$ onda i samo onda ako vrijedi $(y, p) > 0$.

Zadatak 4.7. Provjerite valjanost formula (4.42) i dokažite Teorem 4.8.!

4.3. Inverzne korekcije

U prethodnim razmatranjima nastojali smo dobiti rekurzivne formule za matrice–korekcije, koje što više nalikuju na hesijan minimizirajuće funkcije. Sada ćemo pokušati definirati rekurzivne formule za matrice–korekcije, koje će što više nalikovati na inverznu matricu hesijana minimizirajuće funkcije. Te matrice nazivat ćemo inverzne korekcije.

U tu svrhu pretpostavimo da posjedujemo neku aproksimaciju H od $(\nabla^2 f(x))^{-1}$ i pomoću nje pokušajmo pronaći što bolju aproksimaciju \overline{H} od $(\nabla^2 f(\bar{x}))^{-1}$, gdje je $\bar{x} = x + p$. Analogno quasi-Newtonovom uvjetu (4.25) ($\overline{B}p = y$) postavimo inverzni quasi-Newtonov uvjet

$$\overline{H}y = p.\quad (4.44)$$

Odmah je jasno da opća inverzna korekcija ranga 1, koja zadovoljava inverzni quasi-Newtonov uvjet (4.44) mora biti oblika

$$\overline{H} = H + \frac{(p - Hy)d^T}{(d, y)}, \quad \text{za neki } d \in \mathbb{R}^n, \quad (d, y) \neq 0.\quad (4.45)$$

Zadatak 4.8. Pokžite da korekcija ranga 1 (4.26) i inverzna korekcija ranga 1 (4.45) reprezentiraju istu korekciju ako je $c = B^T d$.

Kao i u slučaju prethodno razmatranih korekcija koje aproksimiraju $(\nabla^2 f(x))$ i ovdje se najprije postavlja pitanje čuvanja naljeđa simetričnosti, tj. vrijedi li

$$H \text{ je simetrična matrica} \quad \Rightarrow \quad \overline{H} \text{ je simetrična matrica}$$

Zadatak 4.9. Pokažite da je inverzna korekcija ranga 1 koja zadovoljava inverzni quasi-Newtonov uvjet (4.44) i čuva simetričnost također zadana formulom (4.34).

Zadatak 4.10. Slično kao u dokazu Leme 4.3. izvedite formulu za inverznu quasi-Newtonova korekcija ranga 2

$$\overline{H} = H + \frac{(p - Hy)d^T + d(p - Hy)^T}{(d, y)} - \frac{(p - Hy)^T y}{(d, y)^2} dd^T. \quad (4.46)$$

Najvažniju varijantu inverzne quasi-Newtonove korekcije ranga 2 (4.46), koja pri tome čuva i pozitivnu definitnost, nezavisno su napravili Broyden, Fletcher, Goldfarb i Shano 1970. godine, pa se ona u literaturi naziva Broyden–Fletcher–Goldfarb–Shano korekcija ili skraćeno BFGS-korekcija. Dobiva se tako da u (4.46) stavimo $d = p$. Može se pokazati da u tom služaju vrijedi

$$\overline{H}_{BFGS} = \left(I - \frac{py^T}{(y, p)} \right) H \left(I - \frac{yp^T}{(y, p)} \right) + \frac{pp^T}{(y, p)}. \quad (4.47)$$

kao i sljedći teorem

Teorem 4.9. Neka je $H \in \mathbb{R}^{n \times n}$ regularna simetrična matrica i neka je $\overline{H}_{BFGS} \in \mathbb{R}^{n \times n}$ definirana sa (4.47) za neke vektore $y, p \in \mathbb{R}^n$, $(y, p) \neq 0$.

Tada je \overline{H}_{BFGS} regularna onda i samo onda ako je $(p, Bp) \neq 0$, gdje je $B = H^{-1}$.

Ako je \overline{H}_{BFGS} regularna, onda se $\overline{B}_{BFGS} := \overline{H}_{BFGS}^{-1}$ može zapisati kao

$$\overline{B}_{BFGS} = B + \frac{yy^T}{(y, p)} - \frac{Bpp^T B}{(p, Bp)}.$$

Nadalje, ako je $H > 0$, onda je $\overline{H}_{BFGS} > 0$ onda i samo onda ako je $(y, p) > 0$.

Zadatak 4.11. Provjerite valjanost formule (4.47) i dokažite Teorem 4.9.!

5. Seminarski radovi

1. Dva različita dokaza **Teorema 4.6.** mogu se vidjeti u [10] i [7]. Izvedite i usporedite oba dokaza.
Literatura: [10], Ch. 6.6.2 (pp 178-179), [7], (pp 66-69)
2. Provjerite valjanost formula (4.42) i dokažite **Teorem 4.8.!**
3. Izradite zadatke: **Zadatak 4.3., Zadatak 4.8., Zadatak 4.9..**
4. Slično kao u dokazu **Leme 4.3.** izvedite formulu za inverznu quasi-Newtonova korekcija ranga 2 navedenu u (4.46). Pokažite da u slučaju $d = p$ vrijedi (4.47)

$$\overline{H}_{BFGS} = \left(I - \frac{py^T}{(y, p)} \right) H \left(I - \frac{yp^T}{(y, p)} \right) + \frac{pp^T}{(y, p)}.$$

5. Provjerite valjanost formule (4.47) i dokažite **Teorem 4.9.!**
6. Primijenite direktne i inverzne quasi-Newtonove korekcije na Gauss-Newtonovu metodu za rješavanje nelinearnog problema najmanjih kvadrata.
Literatura: [10], Ch. 6.7.1 (pp 186-191), [19]
7. Najbolja L_2 aproksimacija funkcije $f : [a, b] \rightarrow \mathbb{R}$ na podprostoru svih polinoma \mathcal{P}_n stupnja $\leq n$.
Ortogonalni polinomi.
Literatura: [4], Ch. 6.8 (pp 421-434), [14], Ch. 15 (401-411)
8. Najbolja L_2 aproksimacija funkcije $f : [a, b] \rightarrow \mathbb{R}$ na podprostoru svih trigonometrijskih polinoma \mathcal{T}_n stupnja $\leq n$.
Literatura: [4], Ch. 6.8 (pp 421-434), [18], Ch. 5 (93-103)
9. Trigonometrijska interpolacija i aproksimacija
Literatura: [4], Ch. 6.12 (pp 477-490),
10. Najbolja L_∞ aproksimacija funkcije $f : [a, b] \rightarrow \mathbb{R}$ na podprostoru svih polinoma \mathcal{P}_n stupnja $\leq n$.
Čebiševljevi polinomi.
Literatura: [4], Ch. 6.8 (pp 434-449), [14], Ch. 15 (411-421)
11. Najbolja L_p , $p = 1, 2, \infty$ aproksimacija podataka mjerena y_i , $i = 1, \dots, m$
Literatura: radni papiri
12. Shepardova interpolacija i aproksimacija
Literatura: [4], Ch. 6.10 (pp 459-462)
13. Moving least squares
Literatura: [4], Ch. 6.10 (pp 465-467), [19]
14. Least Squares Spline 1. reda
[13], [4], Ch. 6.14 (pp 493-498),
15. Linearno programiranje
[4], Ch. 10 (pp 735-767),

16. Metoda zlatnog raza za traženje loklnog minimuma jednodimenzionalne funkcije bez korištenja derivacija
Literatura: Jare, Stoer [10], Zlobec [23], Jukić, Scitovski [11]
17. Metoda parabole za traženje loklnog minimuma jednodimenzionalne funkcije bez korištenja derivacija
Literatura: Jare, Stoer [10], Zlobec [23], Jukić, Scitovski [11]
18. Brentova metoda za traženje loklnog minimuma jednodimenzionalne funkcije bez korištenja derivacija
Literatura: Brent [2], Ch. 5, Jare, Stoer [10], Zlobec [23]
19. Traženje globalnog minimuma jednodimenzionalne funkcije bez korištenja derivacija
Literatura: Brent [2], Ch. 6
20. Powellova metoda za traženje minimuma višedimenzionalne funkcije bez korištenja derivacija
Literatura: Brent [2], Ch. 7
21. Test funkcije za traženje minimuma jednodimenzionalne i višedimenzionalne funkcije
Literatura: Brent [2], Ch. 7, Gill [8], Jare, Stoer [10], Kelley [12], Himmelblau

Literatura

- [1] M. ALIĆ, G. NOGO, *Optimizacija: Uvod u teoriju nužnih i dovoljnih uvjeta ekstrema*, Odjel za matematiku, Sveučilište u Osijeku, Osijek, 2004.
- [2] R. P. BRENT, *Algorithms for Minimization without Derivatives*, Dover Publications, New York, 1973.
- [3] BROYDEN, *A class of methods for solving nonlinear simultaneous equation*, Math. Comput., **19**(1965), 577-593
- [4] D. KINCAID, W. CHENEY, *Numerical Analysis*, Brooks/Cole Publishing company, New York, 1996.
- [5] W.C. DAVIDON, *Variable metric method for minimization*, Rep. ANL-5990 Rev, Argonne National Laboratories, Argonne, Ill., 1959.
- [6] J. E. DENNIS, JR, R. B. SCHNABEL, *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*, SIAM, Philadelphia, 1996
- [7] J. E. DENNIS JR., J. J. MORE, *Quasi-Newton methods, motivation and theory*, SIAM Review, **19**(1977), 46-89
- [8] P. E. GILL, W. MURRAY AND M. H. WRIGHT, *Practical Optimization*, Academic Press, 1981
- [9] J. B. HIRIART-URRUTY, C. LEMARÉCHAL, *Fundamentals of Convex Analysis*, Springer-Verlag, Berlin - Heidelberg, 2001.
- [10] F. JARE, J. STOER, *Optimierung*, Springer-Verlag, Berlin, 2004
- [11] D. JUKIĆ, R. SCITOVSKI, *Metode optimizacije – pravdavanja*, Tuzla, 2005.
- [12] C. T. KELLEY, *Iterative Methods for Optimization*, SIAM, Philadelphia, 1999

- [13] P. LANCASTER, K. ŠALKAUSKAS, *Curve and Surface Fitting: An Introduction*, Academic Press, London, 1986.
- [14] R. PLATO, *Concise Numerical Mathematics*, Providence : American Mathematical Society, 2003.
- [15] J. M. ORTEGA, W. C. RHEINBOLDT, *Iterative Solution of Nonlinear Equations in Several Variables*, Academic Press, New York, 1970. (postoji i ruski prijevod)
- [16] B.N.PSENICNIJ, J.M.DANILIN, *Čislenie metodi v ekstremalnih zadačah*, Nauka, Moskva, 1975
- [17] W. H. PRESS, B. P. FLANNERY, S. A. TEUKOLSKY, W. T. VETTERLING, *Numerical Recipes*, Cambridge University Press, Cambridge, 1989
- [18] R. SCITOVSKI, *Numerička matematika*, Odjel za matematiku, Sveučilište u Osijeku, Osijek, 2004
- [19] R. SCITOVSKI, Š. UNGAR, D. JUKIĆ, *Approximating surfaces by moving total least squares method*, Applied Mathematics and Computation **93**(1998) 219-232
- [20] J. STOER, R. BULIRSCH, *Introduction to Numerical Analysis*, Springer-Verlag, New York, 1993
- [21] F. P. VASILJEV, Lekcii po metodam rešenija ekstremalnih zadač, Moskovski univerzitet, Moskva, 1974.
- [22] S. WOLFRAM, *The Mathematica Book*, Wolfram Media, Champaign, 1999.
- [23] S. ZLOBEC, J. PETRIĆ, *Nelinearno programiranje*, Naučna knjiga, Beograd, 1989.