

Matematički praktikum

Predavanje 4 – *

prof. dr. sc. Rudolf Scitovski

prof. dr. sc. Kristian Sabo

doc. dr. sc. Danijel Grahovac

dr. sc. Matea Ugrica[†]

2. studenoga 2020.

Sadržaj

1 Optimizacijski problem	1
2 Konveksne funkcije	2
2.1 Metoda tangenti za konveksnu derivabilnu funkciju	5
3 Kvazikonveksne funkcije	9
3.1 Unimodalne funkcije	13
4 Diferencijabilne funkcije	14

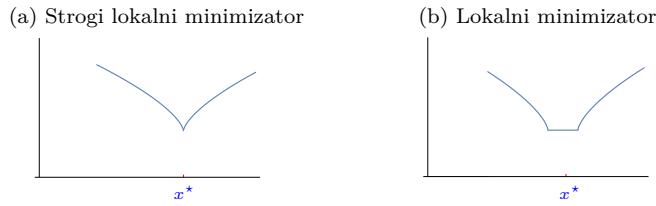
1 Optimizacijski problem

Definicija 1. [6] Kažemo da funkcija $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ u točki $x^* \in \mathcal{D}$ postiže **lokalni minimum** ako postoji okolina $\mathcal{O}(x^*)$ takva da je $f(x) \geq f(x^*)$ za sve $x \in \mathcal{O}(x^*) \cap \mathcal{D}$. Točku x^* zovemo **točka lokalnog minimuma ili lokalni minimizator funkcije f** .

Kažemo da je x^* točka **strogog lokalnog minimuma ili strogji lokalni minimizator funkcije f** ako postoji okolina $\mathcal{O}(x^*)$ takva da je $f(x) > f(x^*)$ za sve $x \in \mathcal{O}(x^*) \cap \mathcal{D} \setminus \{x^*\}$.

*Matematički praktikum obavezni je predmet u zimskom semestru druge godine sveučilišnog Diplomskog studija matematike na smjerovima Financijska matematika i statistika i Računarstvo, te na petoj godini sveučilišnog Nastavničkog studija matematike i informatike (30 sati predavanja i 30 sati vježbi, 6 ECTS bodova)

[†]scitowsk@mathos.hr, ksabo@mathos.hr, dgrahova@mathos.hr, mugrica@mathos.hr



Slika 1: Lokalni minimizator i strogi lokalni minimizator

Definicija 2. Kažemo da funkcija $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ u točki $x^* \in \mathcal{D}$ postiže globalni minimum na \mathcal{D} ako je

$$f(x^*) \leq f(x), \quad \forall x \in \mathcal{D}.$$

Točku $x^* \in \mathcal{D}$ zovemo **točka globalnog minimuma** ili **globalni minimizator** funkcije f na \mathcal{D} . Skup svih točaka globalnog minimuma funkcije f označavamo s

$$\operatorname{argmin}_{x \in \mathcal{D}} f(x),$$

vrijednost

$$f(\hat{x}), \quad \text{za } \hat{x} \in \operatorname{argmin}_{x \in \mathcal{D}} f(x),$$

zovemo **globalni minimum** funkcije f na \mathcal{D} , a funkciju f nazivamo *minimizirajuća funkcija*.

Primjedba 1. Analogno definiciji globalnog minimuma može se definirati pojam *globalnog maksimuma* i *točka globalnog maksimuma* funkcije f , ali kako je

$$(i) \quad \max_{x \in \mathcal{D}} f(x) = -\min_{x \in \mathcal{D}} (-f(x)),$$

$$(ii) \quad \operatorname{argmax}_{x \in \mathcal{D}} f(x) = \operatorname{argmin}_{x \in \mathcal{D}} (-f(x)),$$

dovoljno je proučavati samo problem globalnog minimuma.

2 Konveksne funkcije

Za funkciju $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$, promatrajmo optimizacijski problem definiran u t.??, str.???. U nastavku navodimo definicije konveksnog skupa i konveksne funkcije te dajemo odgovarajuće karakterizacije (vidi primjerice [2, 3, 5]).

Definicija 3. Kažemo da je skup $\mathcal{D} \subseteq \mathbb{R}^n$ **konveksan** ako je za sve $x, y \in \mathcal{D}$, $\alpha x + (1-\alpha)y \in \mathcal{D}$ za svaki $\alpha \in [0, 1]$. Za funkciju $f: \mathcal{D} \rightarrow \mathbb{R}$, definiranu na konveksnom skupu $\mathcal{D} \subseteq \mathbb{R}^n$ kažemo da je **konveksna** ako za sve $x, y \in \mathcal{D}$ vrijedi

$$f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y), \quad \forall \alpha \in [0, 1]. \quad (1)$$

Ako u prethodnoj nejednakosti vrijedi znak „ $<$ ” za svaki $\alpha \in (0, 1)$ i $x \neq y$, onda kažemo da je funkcija f **stogo konveksna**.

U sljedećim lemama navedena su neka važna svojstva konveksnih funkcija [1–4].

Lema 1. Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$, konveksna funkcija definirana na konveksnom skupu $\mathcal{D} \subseteq \mathbb{R}^n$. Onda vrijedi:

- (i) nivo-skup (level-set) $\mathcal{D}_\lambda(f) = \{x \in \mathcal{D}: f(x) \leq \lambda\}$ je konveksan skup za svaki $\lambda \in \mathbb{R}$;
- (ii) ako je \mathcal{D} otvoren skup, onda je funkcija f neprekidna na \mathcal{D} .

Lema 2. Neka je $f: [a, b] \rightarrow \mathbb{R}$ konveksna derivabilna funkcija. Tada:

- (i) $f(u) \geq f(v) + f'(v)(u - v)$, $\forall u, v \in [a, b]$ (gradijentna nejednakost)
- (ii) Derivacija f' ne opada na $[a, b]$.

Dokaz. U svrhu dokaza tvrdnje (i) nejednakost (1) za $\alpha \in (0, 1)$ zapišimo u obliku

$$\alpha f(u) \geq f(v + \alpha(u - v)) - (1 - \alpha)f(v),$$

što nakon dijeljenja s α možemo zapisati kao:

$$f(u) \geq f(v) + \frac{f(v + \alpha(u - v)) - f(v)}{\alpha(u - v)}(u - v).$$

Za $\alpha \rightarrow 0+$ dobivamo nejednakost (i).

Dokažimo tvrdnju (ii). U gradijentnoj nejednakosti (i) varijable u i v su ravnopravne. Zamijenimo li ih, iz (i) dobivamo $f(v) \geq f(u) + f'(u)(v - u)$. Zbrajanjem ove nejednakosti s gradijentnom nejednakosti (i) dobivamo

$$(f'(u) - f'(v))(u - v) \geq 0,$$

iz čega slijedi tražena tvrdnja (vidi također Zadatak 1). \square

Zadatak 1. Pokažite da je funkcija $f: [a, b] \rightarrow \mathbb{R}$ rastuća onda i samo onda ako vrijedi

$$(x_2 - x_1)(f(x_2) - f(x_1)) \geq 0, \quad \forall x_1, x_2 \in [a, b], x_1 < x_2,$$

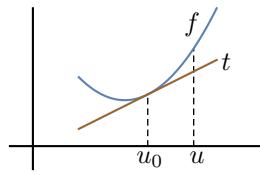
a da je padajuća onda i samo onda ako vrijedi

$$(x_2 - x_1)(f(x_2) - f(x_1)) \leq 0, \quad \forall x_1, x_2 \in [a, b], x_1 < x_2.$$

Geometrijski smisao gradijentne nejednakosti je da njena tangenta $t(u) = f(u_0) + f'(u_0)(u - u_0)$ u proizvoljnoj točki $u_0 \in [a, b]$ leži ispod grafa te funkcije (vidi Sliku 2).

Tvrđnje sljedećih zadataka u sebi sadrže nekoliko kriterija konveksnosti, ovisno o pretpostavkama koje funkcija zadovoljava.

Zadatak 2. Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$ konveksna derivabilna funkcija definirana na otvorenom konveksnom skupu $\mathcal{D} \subseteq \mathbb{R}$. Dokažite da ako je $x^* \in \mathcal{D}$ takav da je $f'(x^*) = 0$, tada je x^* globalni minimizator funkcije f .



Slika 2: Ilustracija gradijentne nejednakosti

Zadatak 3. Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$ dva puta derivabilna funkcija definirana na otvorenom konveksnom skupu $\mathcal{D} \subseteq \mathbb{R}$. Dokažite:

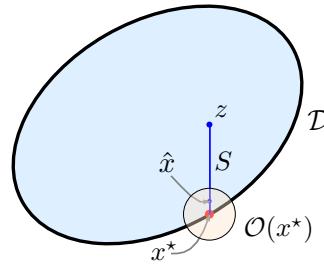
- (a) Funkcija f je konveksna ako i samo ako je $f''(x) \geq 0$ za svaki $x \in \mathcal{D}$.
- (b) Ako je $f''(x) > 0$ za svaki $x \in \mathcal{D}$, onda je f strogo konveksna.
- (c) Na primjeru funkcije $f: \mathbb{R} \rightarrow \mathbb{R}$, $f(x) = x^4$ pokažite da obrat tvrdnje pod (b) ne vrijedi.

Konveksnost minimizirajuće funkcije značajno pojednostavljuje optimizacijski problem zbog činjenice da lokalna optimalnost rješenja garantira globalnu optimalnost o čemu govori sljedeća lema.

Lema 3. Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$ konveksna funkcija definirana na konveksnom skupu $\mathcal{D} \subseteq \mathbb{R}^n$. Ako je x^* lokalni minimizator funkcije f , tada je x^* i globalni minimizator funkcije f .

Dokaz. Kako je x^* lokalni minimizator funkcije f , po Definiciji 1 postoji okolina $\mathcal{O}(x^*)$ takva da je $f(x) \geq f(x^*)$ za sve $x \in \mathcal{O}(x^*) \cap \mathcal{D}$. Pretpostavimo da x^* nije globalni minimizator funkcije f . Po Definiciji 2 postoji $z \in \mathcal{D}$, takav da je $f(z) < f(x^*)$. Koristeći ovu nejednakost i svojstvo konveksnosti funkcije f definirane na konveksnom skupu \mathcal{D} , za proizvoljni $\alpha \in (0, 1]$ dobivamo

$$f(\alpha z + (1 - \alpha)x^*) \leq \alpha f(z) + (1 - \alpha)f(x^*) < \alpha f(x^*) + (1 - \alpha)f(x^*) = f(x^*).$$

Slika 3: Globalni minimum konveksne funkcije na konveksnom skupu \mathcal{D}

To znači da za svaki x iz spojnica $S = \{\alpha z + (1 - \alpha)x^* \in \mathcal{D}: \alpha \in (0, 1]\}$ vrijedi $f(x) < f(x^*)$. Zato postoji $\hat{x} \in S \cap \mathcal{O}(x^*)$ za koji je također $f(\hat{x}) < f(x^*)$, što se protivi prepostavci da je x^* lokalni minimizator funkcije f . \square

Zadatak 4. Pokažite da je funkcija $F_1: \mathbb{R}^2 \rightarrow \mathbb{R}$ definirana u Primjeru ?? konveksna.

Zadatak 5. Dokažite da je konveksna funkcija $f : [a, b] \rightarrow \mathbb{R}$ neprekidna u svim unutrašnjim točkama intervala $[a, b]$ i da ima konačne derivacije slijeva i sdesna, pri čemu vrijedi $f'(x-) \leq f'(x+)$, $x \in (a, b)$.

Uputa: Dokazati da vrijedi

$$\frac{f(u) - f(u - \tau)}{\tau} \leq \frac{f(u) - f(u - h)}{h} \leq \frac{f(u + h) - f(u)}{h} \leq \frac{f(u + \tau) - f(u)}{\tau}, \quad (2)$$

gdje je $0 < h < \tau$; $u, u \pm \tau, u \pm h \in [a, b]$.

Zadatak 6. Pokažite da za konveksnu funkciju $f : [a, b] \rightarrow \mathbb{R}$ vrijedi

$$\frac{f(u) - f(v)}{u - v} \leq \frac{f(w) - f(v)}{w - v} \leq \frac{f(w) - f(u)}{w - u}, \quad a \leq v < u < w \leq b. \quad (3)$$

Koji je geometrijski smisao ovih nejednakosti?

Uputa. Iskoristiti konveksnost funkcije f i zapis $u = \alpha v + (1 - \alpha)w$, gdje je $v < u < w$, $\alpha = \frac{w-u}{w-v}$, $\alpha \in (0, 1)$.

Zadatak 7. Dokažite da ako je $f : [a, b] \rightarrow \mathbb{R}$ konveksna funkcija, onda vrijedi

$$f(u) \geq f(v) + \gamma_n(u - v), \quad \forall u \in [a, b], \forall v \in (a, b), \quad (4)$$

gdje je $\gamma_n \in \mathbb{R}$ proizvoljni broj takav da je $f'(v-) \leq \gamma_n \leq f'(v+)$.

Uputa. Iskoristiti nejednakost (2) razmotrivši slučajevе $u > v$ i $u < v$ i nejednakost $f'(v-) \leq f'(v+)$.

Zadatak 8. Dokažite da je $x^* \in [a, b]$ točka minimuma konveksne funkcije $f : [a, b] \rightarrow \mathbb{R}$ onda i samo onda ako je $f'(x^*+) \geq 0$ i $f'(x^*-) \leq 0$. Specijalno, ako $f'(x^*)$ postoji i ako je $x^* \in (a, b)$, onda je $f'(x^*) = 0$.

Uputa. U (4) stavite $\gamma_n = 0$.

Zadatak 9. Dokažite da je derivabilna funkcija $f : [a, b] \rightarrow \mathbb{R}$ konveksna onda i samo onda ako njezina derivacija f' ne opada na $[a, b]$ (vidi Lemu 2).

Zadatak 10. Dokažite da ako je funkcija $f : [a, b] \rightarrow \mathbb{R}$ monotono rastuća, a $z : [c, d] \rightarrow [a, b]$ konveksna, onda je $f \circ z : [c, d] \rightarrow \mathbb{R}$ konveksna.

2.1 Metoda tangenti za konveksnu derivabilnu funkciju

Za konveksnu derivabilnu funkciju $f : [a, b] \rightarrow \mathbb{R}$ može se konstruirati jednostavan algoritam za traženje njenog globalnog minimuma.

Za fiksni $u_0 \in [a, b]$ definiramo funkciju

$$\Lambda(u; u_0) = f(u_0) + f'(u_0)(u - u_0), \quad u \in [a, b], \quad (6)$$

koju u algoritmu označavamo s $P_0(u)$. Zbog svojstva (i) iz Leme 2 vrijedi $f(u) \geq \Lambda(u; u_0)$, odnosno $f(u) \geq P_0(u)$, za svaki $u \in [a, b]$, tj. P_0 je donja ograda funkcije f .

Algorithm 1 (Metoda tangenti)

Require: $f, u_0 \in [a, b]$

- 1: Definirati $\Lambda(u; u_0) = f(u_0) + f'(u_0)(u - u_0); P_0(u) := \Lambda(u; u_0);$
 - 2: Odrediti $u_1 = \underset{u \in [a, b]}{\operatorname{argmin}} P_0(u)$ (Očigledno je $u_1 = a$ ili $u_1 = b$);
 - 3: Provjeriti je li $f'(u_1) \neq 0$ [ako je $f'(u_1) = 0$, onda funkcija f u točki u_1 postiže minimum]
 - 4: Definirati $\Lambda(u; u_1)$ i $P_1(u) = \max_{i=0,1} \Lambda(u; u_i) = \max\{\Lambda(u; u_1), P_0(u)\};$
 - 5: Odrediti $u_2 = \underset{u \in [a, b]}{\operatorname{argmin}} P_1(u);$
 - 6: Uz pretpostavku da je funkcija P_{n-1} i čvorovi u_0, u_1, \dots, u_{n-1} ($n \geq 2$) poznati, definirati $u_n = \underset{u \in [a, b]}{\operatorname{argmin}} P_{n-1}(u)$ i provjeriti je li $f'(u_n) \neq 0$ [ako je $f'(u_n) = 0$, onda funkcija f postiže minimum u točki u_n];
 - 7: Definirati
- $$P_n(u) = \max_{i=0, \dots, n} \Lambda(u; u_i) = \max \{\Lambda(u; u_n), P_{n-1}(u)\}; \quad (5)$$
- 8: Odrediti $u_{n+1} = \underset{u \in [a, b]}{\operatorname{argmin}} P_n(u)$
-

Nadalje, definiramo sljedeću aproksimaciju $u_1 = \underset{u \in [a, b]}{\operatorname{argmin}} P_0(u)$ koja se očigledno postiže na jednom od rubova intervala $[a, b]$. Nakon toga analogno definiramo $\Lambda(u; u_1) := f(u_1) + f'(u_1)(u - u_1)$ i funkciju

$$P_1(u) = \max\{\Lambda(u; u_1), \Lambda(u; u_0)\} = \max\{\Lambda(u; u_1), P_0(u)\}.$$

Sljedeća aproksimacija dobiva se kao

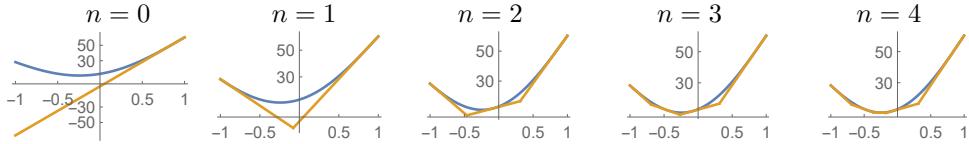
$$u_2 = \underset{u \in [a, b]}{\operatorname{argmin}} P_1(u).$$

Iterativni postupak nastavlja se do unaprijed zadanog broja iteracija ili primjenom nekog drugog kriterija zaustavljanja (vidi primjerice Zadatak ??).

Navodimo odgovarajući algoritam, čiju implementaciju možemo vidjeti u t.??, str.???. Funkcija P_n neprekidna je po dijelovima linearna funkcija, čiji je graf sastavljen od dijelova tangent na graf funkcije f . Zato ovu metodu zovemo **Metoda tangenti**.

Primjer 1. Metodu tangenti ilustrirat ćemo na primjeru minimizacije funkcije $f : [-1, 1] \rightarrow \mathbb{R}$, $f(x) = 13 + 18x + 37x^2 - 2x^3 - 6x^4 + \frac{1}{4}x^6$ koja predstavlja lokalnu LS-udaljenost točke do kubne parabole (vidi Primjer ??, str.?? i Primjer ??, str.??). Primijetite da je ovako definirana funkcija konveksna i derivabilna.

Na Slici 1 dana je ilustracija Algoritma 1 primjenom Mathematica-modula **MeTang** (vidi t.??, str.??), a u Tablici 1 može se detaljnije pratiti iterativni postupak. Globalni minimum postiže se u točki $u^* = -0.243094$.



Slika 4: Ilustracija Metode tangenti za funkciju iz Primjera 1

n	1	2	3	4	5
u_n	-1	-0.078	-0.464	-0.266	-0.172
$f(u_n)$	28.25	11.825	12.545	10.838	11.006
$ u^* - u_n $	0.757	0.165	0.221	0.023	0.071

Tablica 1: Prvih 5 iteracija Metode tangenti na Primjeru 1

Lema 4. Neka je $f: [a, b] \rightarrow \mathbb{R}$ konveksna derivabilna funkcija, u_n niz čvorova i (P_n) niz funkcija definiranih kao u Algoritmu 1. Tada vrijedi (usporedite sa svojstvima koja su navedena u Lemama ??, str.?? u Metodi Pijavskog):

- (i) P_n je po dijelovima linearna funkcija;
- (ii) $P_n(u) \leq P_{n+1}(u)$, $\forall u \in [a, b]$ i $\forall n = 0, 1, \dots$ (monotonni rast)
- (iii) $P_n(u) \leq f(u)$, $\forall u \in [a, b]$ i $\forall n = 0, 1, \dots$ (ograničenost odozgo)
- (iv) $P_n(u_i) = f(u_i)$, $\forall i = 0, 1, \dots, n$ (podudaranje u čvorovima)

Dokaz. Tvrđnja (i) je očigledna, a (ii) slijedi iz nejednakosti $P_{n+1}(u) = \max\{\Lambda(u; u_{n+1}, P_n(u))\} \geq P_n(u)$.

Tvrđnja (iii) dokazuje se induktivno. Najprije zbog gradijentne nejednakosti zaključujemo da je $P_0(u) = \Lambda(u; u_0) \leq f(u)$ i prepostavimo da je $P_{n-1}(u) \leq f(u)$.

Kako također prema gradijentnoj nejednakosti vrijedi $\Lambda(u; u_n) \leq f(u)$, imamo

$$P_n(u) = \max\{\Lambda(u; u_n), P_{n-1}(u)\} \leq \max\{f(u), f(u)\} = f(u).$$

Za dokaz tvrdnje (iv) najprije primijetimo da iz gradijentne nejednakosti slijedi

$$f(u_i) = \Lambda(u_i; u_i), \quad i = 0, 1, \dots, n. \quad (7)$$

Nadalje, kako je $P_n(u) = \max_{i=0,1,\dots,n} \Lambda(u; u_i) \geq \Lambda(u; u_i)$, slijedi

$$P_n(u_i) \geq \Lambda(u_i; u_i), \quad i = 0, 1, \dots, n. \quad (8)$$

Zato iz (7) slijedi

$$f(u_i) \stackrel{(7)}{=} \Lambda(u_i; u_i) \stackrel{(8)}{\leq} P_n(u_i) \stackrel{(iii)}{\leq} f(u_i), \quad i = 0, 1, \dots, n,$$

a to znači da u prethodnoj nejednakosti svuda mora biti jednakost. \square

Primjedba 2. Niz (u_n) dobiven Algoritmom 1 konvergira prema točki globalnog minimuma funkcije f . Dokaz ove činjenice analogan je dokazu Teorema ??, str.??.

Primjedba 3. Opisana *Metoda tangenti* može se modificirati za traženje minimuma konveksne funkcije (ne nužno derivabilne), koja na intervalu $[a, b]$ postiže svoj minimum. Naime, konveksna funkcija $f : [a, b] \rightarrow \mathbb{R}$ neprekidna je na (a, b) i u svakoj točki $x \in (a, b)$ postoje konačni limesi

$$\lim_{h \rightarrow 0+} \frac{f(x+h) - f(x)}{h} =: f'(x+), \quad \lim_{h \rightarrow 0+} \frac{f(x) - f(x-h)}{h} =: f'(x-),$$

pri čemu je $f'(x-) \leq f'(x+)$ (vidi Zadatak 5). Zato u prethodno opisanoj *Metodi tangenti* možemo staviti

$$\Lambda(u; u_n) = f(u_n) + \gamma_n(u - u_n), \quad u \in [a, b], \quad (9)$$

gdje je γ_n proizvoljna konstanta koja zadovoljava nejednakost

$$f'(u_n-) \leq \gamma_n \leq f'(u_n+).$$

Primijetite da nejednakost $f(u) \geq \Lambda(u; u_n)$, $u \in [a, b]$ pri tome ostaje sačuvana (vidi Zadatak 7). U primjeni je najjednostavnije γ_n odrediti iz uvjeta

$$|\gamma_n| = \min\{|f'(u_n-)|, |f'(u_n+)|\}.$$

Ako se za neki n pokaže da vrijedi

$$f'(u_n-) \leq 0 \leq f'(u_n+),$$

onda je u_n točka minimuma (vidi Zadatak 8) i proces je završen.

U cilju izbjegavanja mogućih degeneracija $f'(a-) = -\infty$ ili $f'(b+) = +\infty$, dovoljno je iterativni proces započeti točkama $u_0 = a + h_0$, $u_1 = b - h_1$, gdje h_0 i h_1 treba izabrati tako da računalo prepoznae $f'(a + h_0+)$ i $f'(b - h_1-)$.

Primjedba 4. Ideja *Metode tangenti* za traženje globalnog minimuma konveksne derivabilne funkcije iskoristit će se u t.??, str.?? za konstrukciju važne metode za traženje globalnog minimuma Lipschitz neprekidne funkcije.

Zadatak 11. Za funkciju $f : [1, 4] \rightarrow \mathbb{R}$, $f(x) = \frac{x}{2} + \frac{1}{x}$, odredite prve tri aproksimacije globalnog minimuma Metodom tangenti uz $u_0 = 1$.

Zadatak 12. Provjerite li se za minimizaciju funkcije $f : [-1, 1] \rightarrow \mathbb{R}$, $f(x) = x^3 + 3x^2$ primijeniti Metoda tangenti te ako može, provedite prve tri iteracije uz početnu aproksimaciju $u_0 = -1$.

3 Kvazikonveksne funkcije

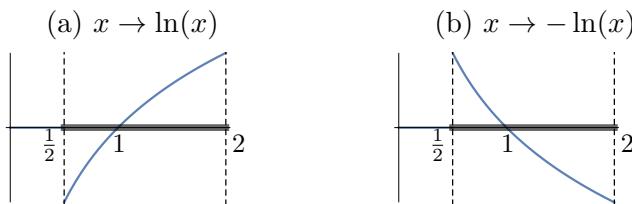
Kao što smo vidjeli iz Leme 3, konveksne funkcije imaju svojstvo izrazito korisno u optimizaciji, a koje glasi da je svaki lokalni minimizator funkcije (ako postoji) ujedno i globalni minimizator te funkcije. U mnogim optimizacijskim problemima pojavljuju se funkcije koje imaju slično svojstvo, a pri tome nisu konveksne. Prirodno je postaviti pitanje može li se oslabjeti zahtjev na konveksnost funkcije, a da se zadrži neki oblik ovog svojstva. S tim ciljem uvodimo sljedeću definiciju.

Definicija 4. Funkcija $f : \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ je **kvazikonveksna** na konveksnom skupu \mathcal{D} ako za sve $x, y \in \mathcal{D}$ vrijedi

$$f(\alpha x + (1 - \alpha)y) \leq \max\{f(x), f(y)\}, \quad \forall \alpha \in [0, 1]. \quad (10)$$

Ako u (10) vrijedi stroga nejednakost za $\alpha \in (0, 1)$ i $x \neq y$, onda kažemo da je f **strogo kvazikonveksna** na \mathcal{D} (vidi [6]).

Primjedba 5. Primijetite da je svaka monotona funkcija ujedno i kvazikonveksna. Kao primjer razmotrite monotono rastuću funkciju $x \rightarrow \ln(x)$ i monotono padajuću funkciju $x \rightarrow -\ln(x)$, obje definirane na segmentu $[0.5, 2]$ (vidi Sliku 5).



Slika 5: Kvazikonveksne funkcije

Sljedeća lema daje jedan praktičan kriterij za ispitivanje kvazikonveksnosti neke funkcije.

Lema 5. Funkcija $f : \mathcal{D} \rightarrow \mathbb{R}$ je kvazikonveksna na \mathcal{D} onda i samo onda ako je za svaki $\lambda \in \mathbb{R}$ nivo-skup $\mathcal{D}_\lambda(f) = \{x \in \mathcal{D} : f(x) \leq \lambda\}$ konveksan.

Dokaz. (*Nužnost*) Prepostavimo da je funkcija $f : \mathcal{D} \rightarrow \mathbb{R}$ kvazikonveksna i dokažimo da je za proizvoljni $\lambda \in \mathbb{R}$ skup $\mathcal{D}_\lambda(f)$ konveksan.

Neka su $x, y \in \mathcal{D}_\lambda(f)$. To znači da je $f(x) \leq \lambda$ i $f(y) \leq \lambda$. Kako je f kvazikonveksna, za proizvoljni $\alpha \in [0, 1]$ vrijedi

$$f(\alpha x + (1 - \alpha)y) \leq \max\{f(x), f(y)\} \leq \lambda,$$

iz čega zaključujemo da je $\alpha x + (1 - \alpha)y \in \mathcal{D}_\lambda(f)$.

(*Dovoljnost*) Prepostavimo da je za proizvoljni $\lambda \in \mathbb{R}$ skup $\mathcal{D}_\lambda(f)$ konveksan i dokažimo da je tada funkcija $f : \mathcal{D} \rightarrow \mathbb{R}$ kvazikonveksna.

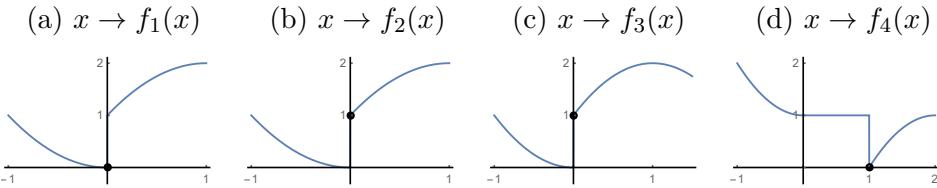
Za proizvoljne $x, y \in \mathcal{D}$ definirajmo $\mu = \max\{f(x), f(y)\}$. Tada su $x, y \in \mathcal{D}_\mu(f)$, a kako je $\mathcal{D}_\mu(f)$ konveksan, onda je $\alpha x + (1 - \alpha)y \in \mathcal{D}_\mu(f)$, $\forall \alpha \in [0, 1]$, iz čega slijedi

$$f(\alpha x + (1 - \alpha)y) \leq \mu = \max\{f(x), f(y)\}.$$

□

Primjedba 6. Primijetite da vrijedi [1, 6]:

- (i) Svaka konveksna funkcija f je kvazikonveksna, ali obrat ne vrijedi, tj. kvazikonveksna funkcija ne mora biti konveksna. Primjerice, na osnovu Leme 1, nije teško vidjeti da su funkcije $f : \langle 0, \infty \rangle \rightarrow \mathbb{R}$ zadane s $f(x) = \ln x$ te $g : [-1, 1] \rightarrow \mathbb{R}$, $g(x) = \sqrt[3]{x^2}$ kvazikonveksne, ali nisu konveksne.
- (ii) Ako su funkcije f_i , $i = 1, \dots, m$, kvazikonveksne na \mathcal{D} , onda je i funkcija $f(x) = \max_{i=1, \dots, m} f_i(x)$ također kvazikonveksna na \mathcal{D} .
- (iii) Kvazikonveksna funkcija ne mora biti neprekidna. Primjerice, funkcija $f : \mathbb{R} \rightarrow \mathbb{R}$, $f(x) = \text{sign } x$ je kvazikonveksna na \mathbb{R} , ali nije neprekidna. Primijetite također da ova funkcija nije strogo kvazikonveksna.



Slika 6: Koje od ovih funkcija su kvazikonveksne funkcije?

Primjer 2. Promatramo sljedeće funkcije (vidi Sliku 6)

$$\begin{aligned} f_1(x) &= \begin{cases} x^2, & x \in [-1, 0], \\ 2 - (x-1)^2, & x \in (0, 1] \end{cases}, & f_2(x) &= \begin{cases} x^2, & x \in [-1, 0), \\ 2 - (x-1)^2, & x \in [0, 1] \end{cases}, \\ f_3(x) &= \begin{cases} x^2, & x \in [-1, 0], \\ 2 - (x-1)^2, & x \in (0, 1.5] \end{cases}, & f_4(x) &= \begin{cases} x^2 + 1, & x \in [-1, 0] \\ 1, & x \in (0, 1) \\ 1 - (x-2)^2, & x \in [1, 2] \end{cases}. \end{aligned}$$

Funkcija f_1 je strogo kvazikonveksna funkcija za koju je $\operatorname{argmin}_{x \in [-1, 1]} f_1(x) = \{0\}$. Funkcija f_2 je strogo kvazikonveksna funkcija za koju vrijedi $\operatorname{argmin}_{x \in [-1, 1]} f_2(x) = \emptyset$. Funkcija f_3 nije kvazikonveksna funkcija, dok je f_4 kvazikonveksna, ali ne i strogo kvazikonveksna funkcija. Nadalje, lokalni minimizator funkcije f_4 svaka je točka iz intervala $[0, 1)$, ali niti jedna od tih točaka nije globalni

minimizator. Njezin globalni minimizator je $\underset{x \in [-1,2]}{\operatorname{argmin}} f_4(x) = x^* = 1$, a globalni minimum iznosi $f_4(x^*) = 0$.

Primjer funkcije f_4 pokazuje kako se može dogoditi da lokalni minimizator kvazikonveksne funkcije nije ujedno globalni minimizator, odnosno da tvrdnja iz Leme 3 ne vrijedi općenito za kvazikonveksne funkcije. Međutim, analogna tvrdnja može se dokazati uz nešto jaču pretpostavku na skup lokalnih minimizatora funkcije f .

Lema 6. *Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ kvazikonveksna funkcija definirana na konveksnom skupu \mathcal{D} . Ako je x^* strogi lokalni minimizator funkcije f , tada je x^* strogi globalni minimizator funkcije f .*

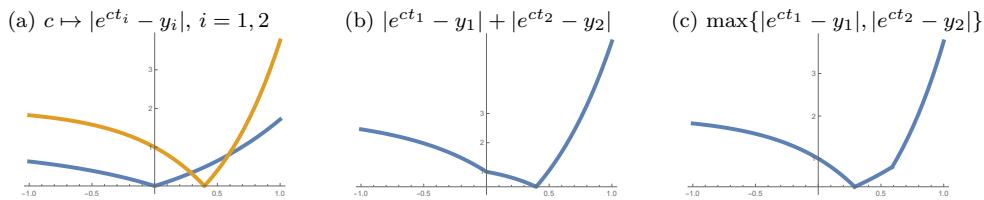
Dokaz. Ako je x^* strogi lokalni minimizator funkcije f na skupu \mathcal{D} , onda postoji otvoreni skup $\mathcal{O}(x^*)$ oko točke x^* takav da je $f(x^*) < f(x)$, za svaki $x \in \mathcal{O}(x^*) \cap \mathcal{D}$ i $x \neq x^*$. Pretpostavimo da x^* nije strogi globalni minimizator od f na \mathcal{D} , odnosno da postoji $z \in \mathcal{D}$, $z \neq x^*$ i $f(z) < f(x^*)$. Zbog kvazikonveksnosti funkcije f vrijedi

$$f(\alpha z + (1 - \alpha)x^*) \leq \max\{f(z), f(x^*)\} = f(x^*), \quad \forall \alpha \in (0, 1].$$

To znači (vidi Sliku 3, str. 4) da za svaki x iz spojnica $S = \{\alpha z + (1 - \alpha)x^* \in \mathcal{D} : \alpha \in (0, 1]\}$ vrijedi $f(x) \leq f(x^*)$ što se protivi pretpostavci da je x^* strogi lokalni minimizator. \square

Zadatak 13. *Dokažite sljedeću varijantu Leme 6. Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ strogo kvazikonveksna funkcija definirana na konveksnom skupu \mathcal{D} . Ako je x^* lokalni minimizator funkcije f , tada je x^* globalni minimizator funkcije f .*

Zadatak 14. *Je li zbroj dviju kvazikonveksnih funkcija također kvazikonveksna funkcija? Za podatke (t_i, y_i) , $i = 1, \dots, m$, funkcija $c \mapsto |e^{ct_i} - y_i|$ je kvazikonveksna. Je li i funkcija $c \mapsto \sum_{i=1}^m |e^{ct_i} - y_i|$ kvazikonveksna (vidi Sliku 7b)?*



Slika 7: Zbroj i maksimum dviju kvazikonveksnih funkcija

Zadatak 15. *Je li maksimum dviju kvazikonveksnih funkcija također kvazikonveksna funkcija? Za podatke (t_i, y_i) , $i = 1, \dots, m$, funkcija $c \mapsto |e^{ct_i} - y_i|$ je kvazikonveksna. Je li i funkcija $c \mapsto \max_{i=1}^m |e^{ct_i} - y_i|$ kvazikonveksna (vidi Sliku 7c)?*

Zadatak 16. Provjerite koje su od ovih funkcija konveksne, a koje kvazikonveksne:

- (a) $f_1 : [a, b] \rightarrow \mathbb{R}$, $f_1(x) = x^2$,
- (b) $f_2 : [a, b] \rightarrow \mathbb{R}$, $f_2(x) = |x| + x + \text{sign } x$,
- (c) $f_3 : [1, 2] \rightarrow \mathbb{R}$, $f_3(x) = \ln x$,
- (d) $g_1 : [a, b] \rightarrow \mathbb{R}$, $g_1(x) = \begin{cases} |x|, & x \neq 0 \\ -1, & x = 0 \end{cases}$,
- (e) $g_2 : [a, b] \rightarrow \mathbb{R}$, $g_2(x) = \begin{cases} |x|, & x \neq 0 \\ 1, & x = 0 \end{cases}$,
- (f) $g_3 : [0, 2] \rightarrow \mathbb{R}$, $g_3(x) = \begin{cases} x^2, & x \in [0, 1] \\ \sqrt{x}, & x \in [1, 2] \end{cases}$.

Zadatak 17. Provjerite svojstvo konveksnosti i kvazikonveksnosti sljedećih funkcija:

- (a) $f_1 : [a, b] \rightarrow \mathbb{R}$, $f_1(x) = x^4 + 3x$,
- (b) $f_2 : (0, \infty) \rightarrow \mathbb{R}$, $f_2(x) = -e^{-x}$,
- (c) $f_3 : [0, 3] \rightarrow \mathbb{R}$, $f_3(x) = \frac{-1}{x^2 + 1}$.

Zadatak 18. Kako treba proširiti funkciju $f(x) = \frac{1}{e^{1/x^2} + 1}$ u točki $x_0 = 0$ tako da ona bude

- (a) strogo kvazikonveksna na $[0, 1]$,
- (b) strogo kvazikonveksna na $[-1, 1]$,
- (c) strogo kvazikonveksna na $[-1, 0]$?

Zadatak 19. Kako treba proširiti funkciju

$$f(x) = \begin{cases} x, & x > 0 \\ -x + A, & x < 0 \end{cases}$$

u točki $x_0 = 0$ tako da ona bude

- (a) strogo kvazikonveksna na $[0, 1]$,
- (b) strogo kvazikonveksna na $[-1, 0]$,
- (c) strogo kvazikonveksna na $[-1, 1]$,
- (d) strogo kvazikonveksna na $[a, b]$ za proizvoljne $a, b \in \mathbb{R}$?

Razmotrite slučajeve: $A = 0, +1, -1$.

Zadatak 20. Ako su funkcije f_1, f_2 strogo kvazikonveksne na $[a, b]$, jesu li takve i funkcije $f_1 + f_2$, $f_1 - f_2$, $f_1 \cdot f_2$ te f_1/f_2 pod pretpostavkom da su dobro definirane?

Zadatak 21. Neka je $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}$ derivabilna funkcija na otvorenom konveksnom skupu \mathcal{D} . Pokažite da je tada f kvazikonveksna na \mathcal{D} ako i samo ako za svaki $x, y \in \mathcal{D}$ vrijedi

$$f(y) \leq f(x) \Rightarrow f'(x)(y - x) \leq 0.$$

Zadatak 22. Neka je $f: \mathbb{R} \rightarrow \mathbb{R}$ dva puta derivabilna funkcija. Dokažite da je f kvazikonveksna ako i samo ako za svaki $x \in \mathbb{R}$

$$f'(x) = 0 \Rightarrow f''(x) \geq 0.$$

Zadatak 23. Provjerite je li funkcija $f: (0, \infty)^2 \rightarrow \mathbb{R}$, $f(x_1, x_2) = -x_1 x_2$ kvazikonveksna.

Zadatak 24. Neka je funkcija $f: \mathbb{R}^n \rightarrow \mathbb{R}$ definirana s $F(x) = \max\{i: x_i \neq 0\}$ i $f(\mathbf{0}) = 0$. Pokažite da je f kvazikonveksna.

Zadatak 25. Provjerite jesu li sljedeće funkcije kvazikonveksne.

a) $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} = \{x \in \mathbb{R}^n : c^T x + d > 0\}$ zadana s

$$f(x) = \frac{a^T x + b}{c^T x + d},$$

gdje su $a, b, c, d \in \mathbb{R}^n$.

b) $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} = \{x \in \mathbb{R}^n : \|x - a\|_2 \leq \|x - b\|_2\}$ zadana s

$$f(x) = \frac{\|x - a\|_2}{\|x - b\|_2},$$

gdje su $a, b \in \mathbb{R}^n$.

3.1 Unimodalne funkcije

U slučaju funkcija jedne varijable pojам „stroge kvazikonveksnosti” u literaturi se može pronaći i pod nazivom „unimodalne funkcije” (vidi primjerice [4, 6]).

Definicija 5. [4] Kažemo da je funkcija $f: [a, b] \rightarrow \mathbb{R}$ **unimodalna** ako postoji $x^* \in [a, b]$ takav da je $f(x^*) = \min_{x \in [a, b]} f(x)$, a za proizvoljne $a \leq x_1 < x_2 \leq b$ vrijedi

$$\begin{aligned} x_2 \leq x^* &\implies f(x_1) > f(x_2), \\ x^* \leq x_1 &\implies f(x_2) > f(x_1). \end{aligned}$$

Primjedba 7. [4]

- (i) Uočimo da svojstvo unimodalnosti povlači da je funkcija f strogo padajuća na $[a, x^*]$ i strogo rastuća na $[x^*, b]$ dok u točki x^* postiže globalni minimum.
- (ii) Svaka je strogo monotono rastuća (padajuća) funkcija $f: [a, b] \rightarrow \mathbb{R}$ unimodalna.
- (iii) Strogo konveksna funkcija je unimodalna.
- (iv) Unimodalna funkcija ne mora biti neprekidna.
- (v) Ako je $f: [a, b] \rightarrow \mathbb{R}$ unimodalna funkcija i $[a_1, b_1] \subset [a, b]$, onda je $f|_{[a_1, b_1]}$ unimodalna funkcija na $[a_1, b_1]$.

- (vi) Ako je $f : [a, b] \rightarrow \mathbb{R}$ unimodalna funkcija, $x^* = \operatorname{argmin}_{x \in [a, b]} f(x)$ i ako je $a < x_1 < x_2 < b$, onda vrijedi

$$\begin{aligned} f(x_1) \leq f(x_2) &\implies x^* \in [a, x_2], \\ f(x_1) > f(x_2) &\implies x^* \in [x_1, b]. \end{aligned}$$

Zadatak 26. Neka za funkciju $f : [a, b] \rightarrow \mathbb{R}$ postoji $x^* = \operatorname{argmin}_{x \in [a, b]} f(x)$. Pokažite da je tada funkcija f strogo kvazikonveksna na $[a, b]$ onda i samo onda ako je unimodalna.

4 Diferencijabilne funkcije

Ako se može pretpostaviti da je promatrana funkcija diferencijabilna, pristup rješavanju optimizacijskog problema može se preciznije postaviti. Svojstvo diferencijabilnosti funkcije ima posebno veliki značaj u karakterizaciji lokalnog minimizatora funkcije te kod konstrukcije iterativne numeričke metode za rješavanje optimizacijskog problema. U nastavku navodimo definiciju i neka važna svojstva diferencijabilnih funkcija.

Definicija 6. [6] Kažemo da funkcija $f : \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ u točki $x \in \text{int } \mathcal{D}$ diferencijabilna ako postoji $a \in \mathbb{R}^n$ takav da za svaki $h \in \mathbb{R}^n$ vrijedi

$$\lim_{t \rightarrow 0} \frac{f(x + th) - f(x) - ta^T h}{t} = 0. \quad (11)$$

Ako za h redom uzmemmo j -ti koordinatni vektor e^j , dobivamo

$$\lim_{t \rightarrow 0} \frac{f(x + te^j) - f(x) - ta_j}{t} = 0.$$

Dakle, komponente vektora a parcijalne su derivacije $a_j = \frac{\partial f(x)}{\partial x_j} = \partial_j f(x)$.

Ako je funkcija f diferencijabilna u točki $x \in \text{int } \mathcal{D}$, onda ćemo derivaciju funkcije f u točki $x = (x_1, \dots, x_n)^T \in \text{int } \mathcal{D}$ označavati s

$$f'(x) = \left(\frac{\partial f(x)}{\partial x_1}, \dots, \frac{\partial f(x)}{\partial x_n} \right) = (\partial_1 f(x), \dots, \partial_n f(x)),$$

a gradijent funkcije f u točki x s

$$\operatorname{grad} f(x) = \nabla f(x) = f'(x)^T.$$

Nadalje, drugu derivaciju (Hessian) funkcije f u točki x (ako postoji) označavat ćeemo s

$$f''(x) = H_f(x) = \nabla^2 f(x) = \begin{bmatrix} \frac{\partial^2 f(x)}{\partial x_1^2} & \cdots & \frac{\partial^2 f(x)}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f(x)}{\partial x_n \partial x_1} & \cdots & \frac{\partial^2 f(x)}{\partial x_n^2} \end{bmatrix} = \left(\frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right).$$

Prisjetimo se kako skup svih p -puta neprekidno diferencijabilnih funkcija $f: \mathcal{D} \rightarrow \mathbb{R}$, $\mathcal{D} \subseteq \mathbb{R}^n$ označavamo s $C^p(\mathcal{D})$.

Ako je $f \in C^p(\mathcal{D})$ te $x + \alpha h \in \mathcal{D}$ za $\alpha \in [0, 1]$, onda za nju vrijedi Taylorova formula (vidi primjerice [6, 7]). Specijalno, za $p = 1, 2$ vrijedi

$$\begin{aligned} f(x + h) - f(x) &= (\nabla f(x))^T h + o(\|h\|), & p = 1, \\ f(x + h) - f(x) &= (\nabla f(x))^T h + \frac{1}{2} h^T \nabla^2 f(x) h + o(\|h\|^2), & p = 2. \end{aligned}$$

Literatura

- [1] M. AVRIEL, *Nonlinear Programming: Analysis and Methods.*, Dover Publications, Inc. Mineola, New York, 2006.
- [2] D. L. BOYD, L. VANDENBERGHE, *Convex Optimization*, Cambridge University Press, Cambridge, 2004.
- [3] E. M. T. HENDRIX, B. G. TÓTH, *Introduction to Nonlinear and Global Optimization*, Springer, 2010.
- [4] F. JARRE, J. STOER, *Optimierung*, Springer Verlag, Berlin, Heidelberg, 2004.
- [5] D. JUKIĆ, *Konveksni skupovi*, Odjel za matematiku, Sveučilište u Osijeku, 2015.
- [6] J. M. ORTEGA, W. C. RHEINBOLDT, *Iterative Solution of Nonlinear Equations in Several Variables*, SIAM, Philadelphia, 2000.
- [7] E. SÜLI, D. MAYER, *An Introduction to Numerical Analysis*, 2nd Ed., Cambridge University Press, Second printing, 2006.