Najbolja l_∞ aproksimacija rješenja sustava linearnih jednadžbi s jednom nepoznanicom

IVANA KUZMANOVIĆ*

Sažetak. *U radu se promatra karakterizacija i metode određivanja najbolje l_∞ aproksimacije rješenja sustava linearnih jednadžbi s jednom nepoznanicom.*

Ključne riječi: *preodređen sustav linearnih jednadžbi, sustav linearnih jednadžbi s jednom nepoznanicom, Čebiševljeva aproksimacija, l_∞ aproksimacija*

The best l_∞ solution of the system of linear equations with one unknown

Abstract. *In this paper characterization and methods for determing the best l_∞ solution of the system of linear equations with one unknown is considered.*

Key words: *overdetermined system of linear equations, system of linear equations with one unknown, Chebyshev approximation, l_∞ approximation*

1. Uvod

Neka je zadan sustav linearnih jednadžbi s jednom nepoznanicom

$$a_i x = b_i,\ a_i, b_i \in \mathbb{R}, \quad i \in I,\ I = \{1, \dots, m\},\ m > 1 \tag{1}$$

Kako se radi o sustavu s više jednadžbi nego nepoznanica (takozvani preodređeni sustav), ovaj problem općenito nema rješenje. Iako se na prvi pogled sustavi bez rješenja ne čine zanimljivim, takvi sustavi se pojavljuju u praksi i potrebno je na neki način odrediti aproksimaciju rješenja.

Primjer 1. *Da bi se odredila konstanta elastičnosti žice, vrši se mjerenje linearne deformacije pri djelovanju različitih sila. Prema Hookeovom zakonu, veza između sile a, deformacije b i konstante elastičnosti x je $ax = b$. Zbog pogrešaka*

*Odjel za matematiku, Sveučilište u Osijeku, Trg Ljudevita Gaja 6, HR-31000 Osijek, e-mail: ikuzmano@mathos.hr

uzrokovanih nepreciznošću mjernih uređaja, potrebno je izvršiti više mjerenja od kojih svako daje jednu linearnu jednadžbu s jednom nepoznanicom. Na taj način problem određivanja konstante elastičnosti svodi se na problem rješavanja preodređenog sustava linearnih jednadžbi s jednom nepoznanicom.

Zapišimo sustav (1) u obliku

$$a_i x - b_i = 0,\ i \in I,$$

i označimo

$$r_i(x) = a_i x - b_i,\ i \in I.$$

Funkcije r_i nazivaju se reziduali. Kad bi ovaj sustav imao rješenje x^*, vrijedilo bi $r_i(x^*) = 0,\ i \in I$. Kako takav x^* općenito ne postoji, ima smisla kao aproksimacijsko rješenje uzeti onaj x za koji je najveće apsolutno odstupanje (od nule) minimalno, odnosno točku minimuma funkcije

$$\Delta(x) = \max_{i \in I} |a_i x - b_i| = \max_{i \in I} |r_i(x)|. \tag{2}$$

Točka minimuma funkcije Δ naziva se najbolja l_∞ aproksimacija rješenja sustava linearnih jednadžbi s jednom nepoznanicom.

Primjer 2. *Težinski problem mjerenja u l_∞-normi*
Zadani su podaci mjerenja (ω_i, y_i), $i \in I$, $\omega_i > 0$. Treba pronaći najbolju aproksimaciju mjerene veličine tako da najveće težinsko odstupanje bude minimalno, tj. treba odrediti minimum funkcije

$$\Delta(x) = \max_{i \in I} \omega_i |x - y_i|. \tag{3}$$

Specijalno, za $\omega_1 = \cdots = \omega_m = 1$, rješenje problema mjerenja (3) je jednostavno. Bez smanjenja općenitosti možemo pretpostaviti da su podaci sortirani, odnosno

$$y_1 \le y_2 \le \cdots \le y_m.$$

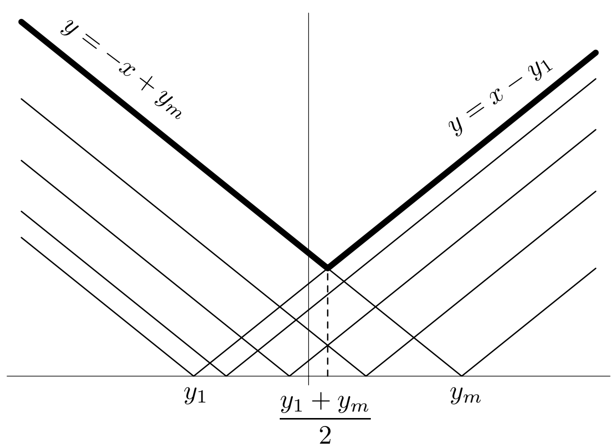

Slika 1. Graf funkcije $\Delta(x) = \max_{i \in I} |x - y_i|$.

Uočimo (Slika 1.) *da je*

$$\Delta(x) = \begin{cases} -x + y_m, & x \leq \frac{y_1+y_m}{2} \\ x - y_1, & x > \frac{y_1+y_m}{2} \end{cases},$$

te je

$$\min_{x\in\mathbb{R}} \Delta(x) = \Delta\left(\frac{y_1+y_m}{2}\right) = \frac{y_m - y_1}{2}.$$

U slučaju kada je barem jedna težina različita od jedan, težinski problem mjerenja u l_∞ normi svodi se na problem l_∞ rješenja sustava linearnih jednadžbi s jednom nepoznanicom. Uz oznaku $\tilde{y}_i := \omega_i y_i$, problem minimuma (3) možemo pisati

$$\Delta(x) = \max_{i\in I} |\omega_i x - \tilde{y}_i| \to \min_{x\in\mathbb{R}}, \quad \omega_i > 0,$$

a ovo je specijalni slučaj l_∞ rješenja sustava jednadžbi s jednom nepoznanicom

$$\max |a_i x - b_i| \to \min_{x\in\mathbb{R}},$$

gdje uvijek možemo pretpostaviti da je $a_i > 0$, $i \in I$.

2. Karakterizacija rješenja

Da bi odredili najbolju l_∞ aproksimacije rješenja sustava jednadžbi (1), umjesto problema određivanja točke minimuma funkcije

$$\Delta(x) = \max_{i\in I} |a_i x - b_i| = \max_{i\in I} |r_i(x)|,$$

možemo promatrati problem određivanja točke minimuma funkcije

$$\delta(x) = \max_{i\in I_2} (a_i x - b_i) = \max_{i\in I_2} r_i(x)$$

pri čemu je

$$I_2 = \{1, \ldots, m, m+1, \ldots, 2m\}, \quad a_{i+m} = -a_i, \quad b_{i+m} = -b_i, \quad r_{i+m}(x) = -r_i(x), \quad i \in I.$$

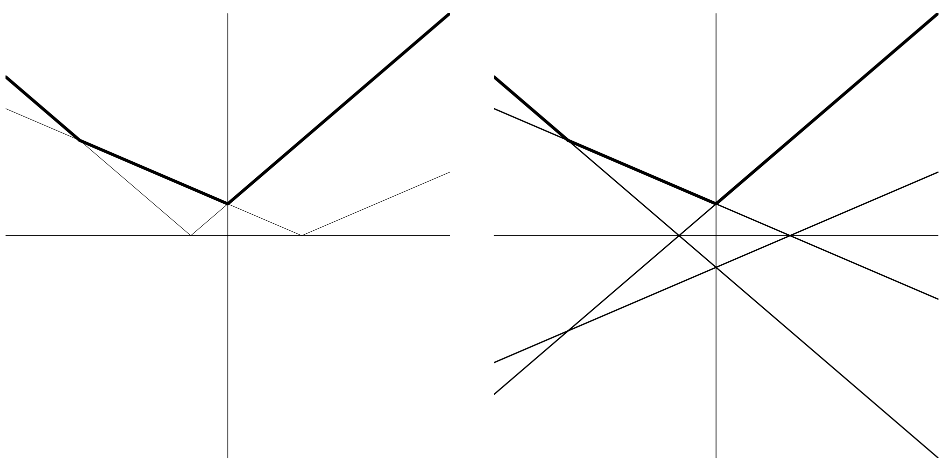

Slika 2. Grafovi funkcija $\Delta(x) = \max\limits_i |r_i(x)|$ (lijevo) i $\delta(x) = \max\limits_i r_i(x)$ (desno)

Teorem 1. *(Karakterizacija točke minimuma funkcije δ)*
Neka je $x \in \mathbb{R}$ i $M = \{k \in I_2 : r_k(x) = \delta(x)\}$. Točka x je točka minimuma funkcije δ ako i samo ako postoje $i, j \in M$ takvi da je $a_i a_j \leq 0$.

Dokaz. Pretpostavimo da je $a_i a_j > 0,\ \forall i, j \in M$. Tada postoji $h \in \mathbb{R}$ takav da je $a_i h > 0,\ \forall i \in M$. Tada je i $\alpha = \min(a_i h) > 0$. Za $i \in M$ je

$$r_i(x - \lambda h) = r_i(x) - \lambda a_i x \leq \delta(z) - \lambda\alpha,$$

te se rezidualima u smjeru $-h$ smanjuje vrijednost. Kako za $i \notin M$ vrijedi $r_i(x) < \delta(x)$, zbog neprekidnosti reziduala postoji neka okolina U od x na kojoj je $r_i(z) < \delta(z),\ \forall z \in U$. Dakle, x ne može biti točka minimuma funkcije δ.
Obratno, pretpostavimo da x nije točka minimuma funkcije δ. Tada postoji točka u kojoj funkcija δ postiže manju vrijednost, tj. postoji $h \in \mathbb{R}$ takav da je $\delta(x-h) < \delta(z)$. Za $i \in M$ je

$$r_i(x - h) \leq \delta(x - h) < \delta(h) = r_i(x),$$

odnosno

$$a_i(x - h) - b_i < a_i x - b_i,$$

iz čega slijedi da je $a_i h > 0,\ \forall i \in M$, a to je moguće samo ako su svi $a_i,\ i \in M$ istog predznaka, tj. $a_i a_j > 0,\ \forall i, j \in M$.

□

Slična tvrdnja vrijedi i za funkciju Δ.

Teorem 2. *(Karakterizacija točke minimuma funkcije Δ)*
Neka je $x \in \mathbb{R}$, $\sigma_i = \operatorname{sign} r_i(x)$ i $M = \{k \in I : |r_k(x)| = \Delta(x)\}$. Točka x je točka minimuma funkcije Δ ako i samo ako postoje $i, j \in M$ takvi da je $(\sigma_i a_i)(\sigma_j a_j) \leq 0$.

3. Metode traženja najboljeg l_∞ rješenja

3.1. Metoda silaska po vrhovima

Neka je x_0 proizvoljna početna aproksimacija. Najprije je potrebno odrediti skup $M = \{i \in I_2 : r_i(x_0) = \delta(x_0)\}$ indeksa svih reziduala koji u točki x_0 poprimaju istu vrijednost kao i funkcija δ. Ako postoje indeksi $j, k \in M$ takvi da je $a_j a_k \leq 0$, onda je prema Teoremu 1. x_0 rješenje. U suprotnom, potrebno je odrediti $j \in M$ za koji je $|a_j|$ minimalan. Sljedeća aproksimacija je prva točka x s lijeva (ako je $a_j > 0$) ili s desna (ako je $a_j < 0$) od x_0 takva da je $r_j(x) = r_i(x)$.

Primjer 3. *Zadan je sustav $a_i x = b_i$, $i = 1, \ldots, 6$, gdje je*

i	1	2	3	4	5	6
a	−20	−6	−5	7	20	30
b	−10	30	7	6	2	19

Najbolja l_∞ aproksimacija rješenja danog sustava je točka minimuma funkcije

$$\delta(x) = \max_{1 \leq i \leq 12} r_i(x),$$

pri čemu je $r_1(x) = -20x + 10$, $r_2(x) = -6x - 30$, $r_3(x) = -5x - 7$, $r_4(x) = 7x - 6$, $r_5(x) = 20x - 2$, $r_6(x) = 30x - 19$, $r_{i+6}(x) = -r_i(x)$, $i = 1, \ldots, 6$.

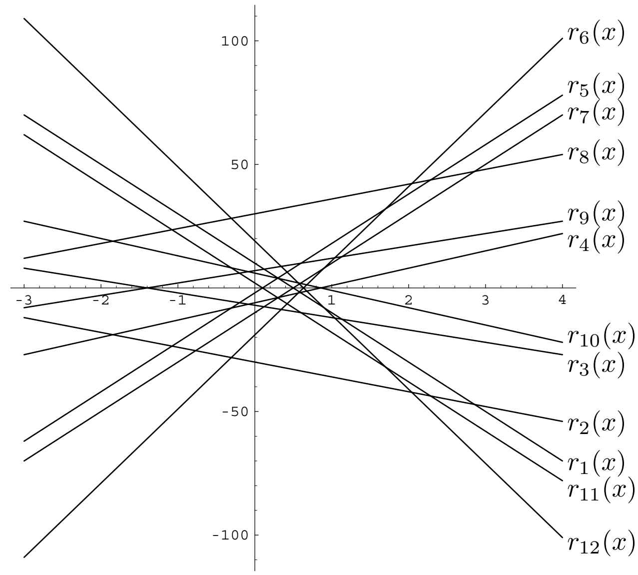

Slika 3. Grafovi funkcija $r_i(x)$, $i = 1, \ldots, 12$

Neka je dana početna aproksimacija $x_0 = 3.5$.

P*rva iteracija*

$\delta(x_0) = 86, \quad M = \{6\}$
Sljedeća aproksimacija je rješenje jednadžbe $r_6(x) = r_8(x)$, *tj* $x_1 = 2.04167$.

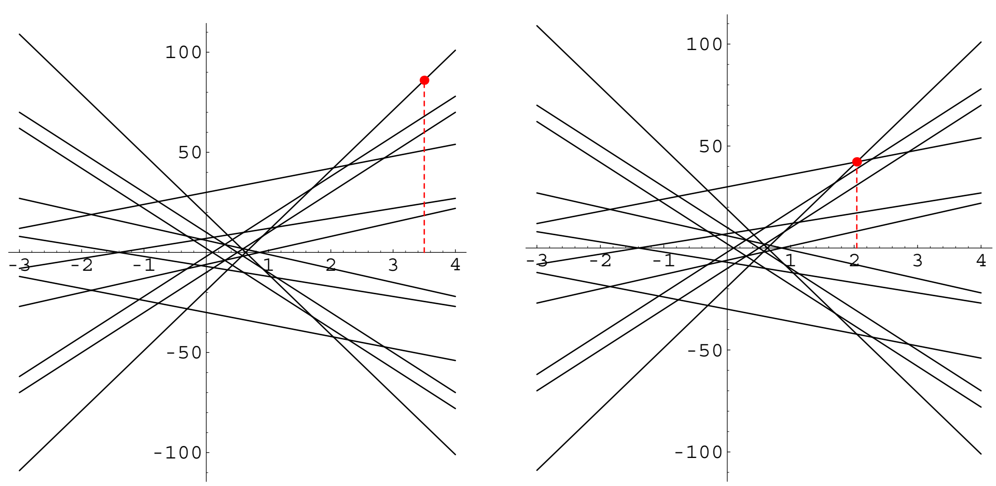

Slika 4. Metoda silaska po vrhovima - početna aproksimacija (lijevo), prva iteracija (desno)

Druga iteracija

$\delta(x_1) = 42.25, \quad M = \{6, 8\}$

Kako je $a_6 \cdot a_8 = 30 \cdot 6 > 0$, x_1 *nije rješenje. Sljedeća aproksimacija je rješenje jednadžbe* $r_8(x) = r_{12}(x)$, *tj.* $x_2 = -0.305556$.

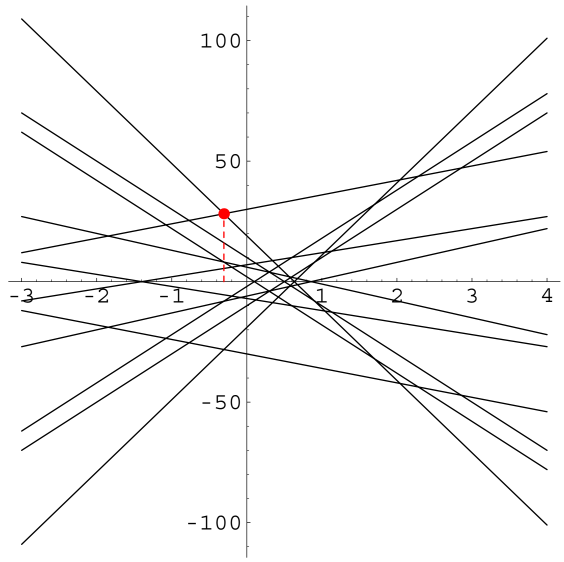

Slika 5. Metoda silaska po vrhovima - druga iteracija

Kako je $\delta(x_2) = r_8(x_2) = r_{12}(x_2)$ *i* $a_8 \cdot a_{12} = 6 \cdot (-30) < 0$, x_2 *je točka minimuma funkcije* δ.

3.2. Metoda uzlaska po vrhovima

U svakoj iteraciji ove metode aproksimacija rješenja je apscisa sjecišta dvaju pravaca od kojih je jedan rastući, drugi padajući. Neka je x_0 aproksimacija u nekoj iteraciji i r_i, r_j reziduali takvi da je $a_i \leq 0 \leq a_j$ i $r_i(x_0) = r_j(x_0)$. Za dobivanje sljedeće aproksimacije, odredi se rezidual r_k za koji je $r_k(x_0) = \delta(x_0)$.

- Ako je $a_k > 0$, sljedeća aproksimacija je apscisa sjecišta grafova reziduala r_i i r_k.
- Ako je $a_k < 0$, sljedeća aproksimacija je apscisa sjecišta grafova reziduala r_j i r_k.
- Ako je $a_k = 0$, onda je sljedeća aproksimacija apscisa sjecišta grafova reziduala r_k i bilo kojeg od r_i, r_j kojemu koeficijent smjera nije nula.

Primjer 4. *Odredimo rješenje prethodnog primjera metodom uzlaska po vrhovima. Neka je početna iteracija rješenje jednadžbe* $r_1(x) = r_4(x)$.

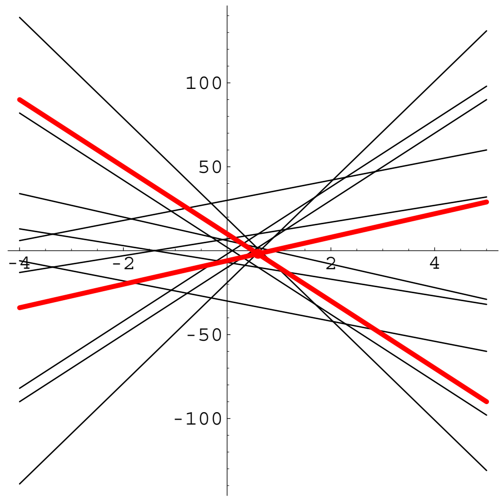

Slika 6. Metoda uzlaska po vrhovima - početna aproksimacija

P*rva iteracija*

$\delta(x_0) = 33.5556$, $r_8(x_0) = \delta(x_0)$, $a_8 = 6 > 0$

Sljedeća aproksimacija je rješenje jednadžbe $r_1(x) = r_8(x)$, *tj.* $x_1 = -0.769231$.

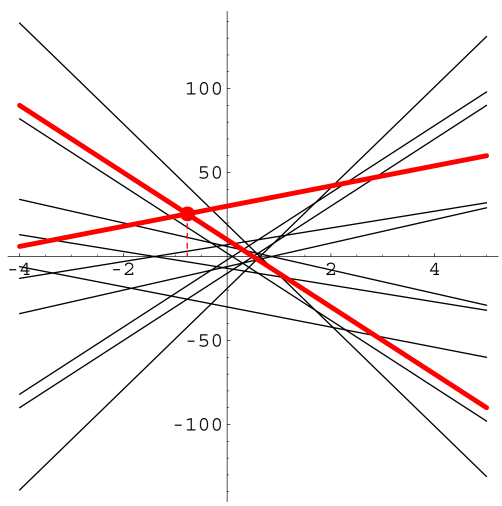

Slika 7. Metoda uzlaska po vrhovima - prva iteracija

D*ruga iteracija*

$\delta(x_1) = 42.0769$, $r_{12}(x_1) = \delta(x_1)$, $a_{12} = -30 < 0$

Sljedeća aproksimacija je rješenje jednadžbe $r_8(x) = r_{12}(x)$, *tj.* $x_2 = -0.305556$.

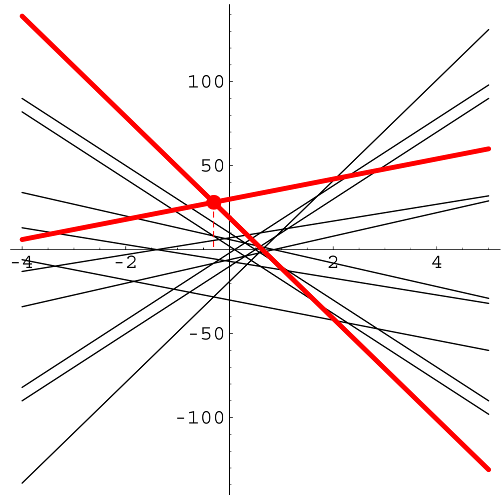

Slika 8. Metoda uzlaska po vrhovima - druga iteracija

Kako je $r_{12}(x_2) = r_8(x_2) = \delta(x_2)$ *i* $a_8 a_{12} = 6 \cdot (-30) < 0$, x_2 *je točka minimuma funkcije* δ.

3.3. Metoda pretraživanja

U svakom koraku metode pretraživanja imamo dvije aproksimacije x_0, y_0, $x_0 < y_0$ koje se nalaze na suprotnim stranama od točke minimuma. Neka je $r_i(x_0) = \delta(x_0)$ i $r_j(y_0) = \delta(y_0)$. Tada je $a_i \leq 0 \leq a_j$. Ako je $a_i = 0$, x_0 je rješenje. Ako je $a_j = 0$, y_0 je rješenje. Neka je $z_0 = \frac{x_0+y_0}{2}$ i $r_k(z_0) = \delta(z_0)$

- Ako je $a_k > 0$, zamjenimo y_0 sa z_0 i j sa k.
- Ako je $a_k < 0$, zamjenimo x_0 sa z_0 i i sa k.

Postupak staje kad je razlika $y_0 - x_0$ manja od nekog unaprijed zadanog ϵ.

Primjer 5. *Na* Slici 9. *prikazan je iterativni postupak metode traženja za sustav iz primjera* 3 *s početnim aproksimacijama* $x_0 = -2$, $y_0 = 4$.

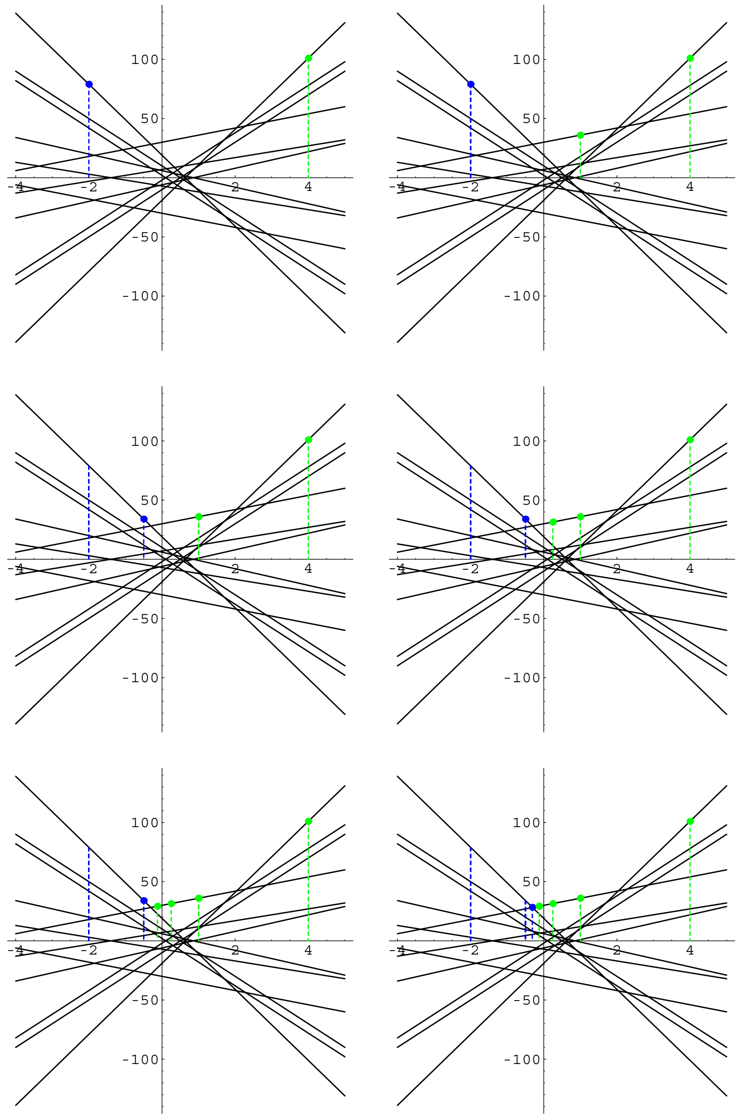

Slika 9. Iterativni postupak metode pretraživanja

References

[1] E. W. Cheney, *Intoduction to Approximation Theory*, AMS, Providence, Rhode Island, 1998.

[2] D. Jukić, *Minimizacija najvećeg apsolutnog odstupanja*, Osječka matematička škola **1**(2001) pp 118.

[3] C. T. KELLEY, *Iterative Methods for Optimization*, SIAM, Philadelphia, 1999.

[4] N. M. KORNEENKO, H. MARTINI, *Hyperplane approximation and related topics*, in: *New Trends in Discrete and Computational Geometry*, (J. Pach, Ed.), Springer-Verlag, Berlin, 1993.

[5] R. SCITOVSKI, *Problemi najmanjih kvadrata. Financijska matematika*, Ekonomski fakultet, Elektrotehnički fakultet, Osijek, 1993.

[6] R. SCITOVSKI, *Numerička matematika*, Elektrotehnički fakultet, Osijek, 1999.

[7] M. R. OSBORNE, *Finite Algorithms in Optimization and Data Analysis*, Wiley, Chichester, 1985.

[8] A. SCHÖBEL, *Locating Lines and Hyperplanes: Theory and Algorithms*, Springer Verlag, Berlin, 1999.

[9] H. SPÄTH, *Mathematical Algorithms for Linear Regression*, Academic Press, 1992.

[10] G. A. WATSON, *Approximation Theory and Numerical Methods*, Wiley, Chichester, 1980.