



UNIVERZITET U NOVOM SADU
PRIRODNO–MATEMATIČKI FAKULTET
DEPARTMAN ZA MATEMATIKU I INFORMATIKU



Zoran Ovcin

**Kvazi Njutnovi postupci
za probleme stohastičkog
programiranja**

Novi Sad, 2016. godina

Problem matematičkog programiranja

Naći $x^* \in X \subseteq \mathbb{R}^n$ za koje važi

$$f(x^*) = \min_{x \in X} f(x), \text{ gde } f : X \rightarrow \mathbb{R}.$$

Postupci rešavanja za probleme bez ograničenja ($X = \mathbb{R}^n$)

- Egzaktni
- Iterativni (dato $x_0 \in \mathbb{R}^n$, $x_{k+1} = x_k + a_k p_k$, $a_k \in \mathbb{R}$)

Oblast poverenja

Linijsko pretraživanje

Izbor pravca

$$x_{k+1} = x_k + a_k p_k \quad (f_k := f(x_k), \nabla f_k := \nabla f(x_k), \nabla^2 f_k := \nabla^2 f(x_k))$$

$$\text{(Tejlor)} \quad f(x + p) = f(x) + \nabla f(x)^T p + \frac{1}{2} p^T \nabla^2 f(x) p$$

- Pravac najbržjeg opadanja

$$f_{k+1} - f_k \approx \nabla f_k^T p_k = \|p_k\| \|\nabla f_k\| \cos \phi, \cos \phi = -1 \rightsquigarrow p_k := -\nabla f_k$$

- Njutnov pravac

$$f(x_k + p) \approx f_k + \nabla f_k^T p + \frac{1}{2} p^T \nabla^2 f_k p \rightarrow \min \rightsquigarrow p_k := -(\nabla^2 f_k)^{-1} \nabla f_k$$

- Kvazi Njutnovi pravci $B_k \approx \nabla^2 f_k \rightsquigarrow p_k = -B_k^{-1} \nabla f_k$

$$B_{k+1} s_k = y_k, \text{ gde je } s_k = x_{k+1} - x_k, y_k = \nabla f_{k+1} - \nabla f_k$$

SR1

$$B_{k+1} = B_k + \frac{(y_k - B_k s_k)(y_k - B_k s_k)^T}{(y_k - B_k s_k)^T s_k}$$

BFGS

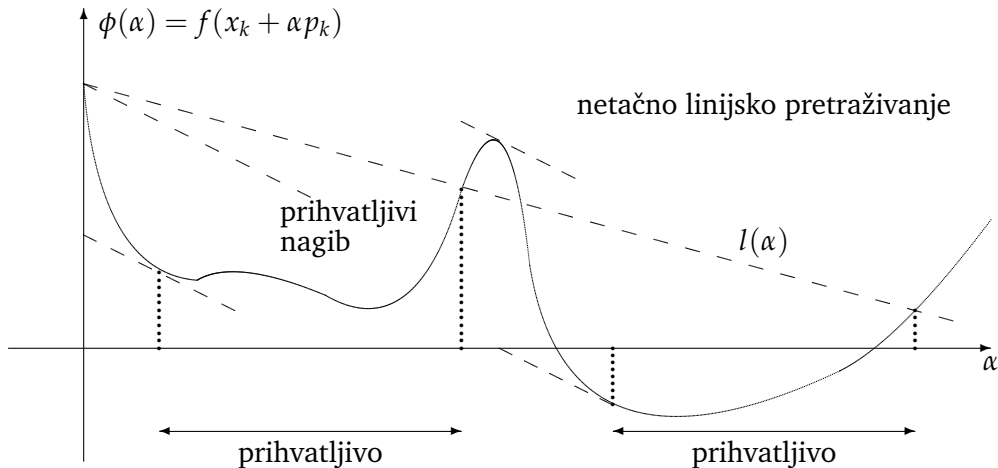
$$B_{k+1} = B_k - \frac{B_k s_k s_k^T B_k^T}{s_k^T B_k s_k} + \frac{y_k y_k^T}{y_k^T s_k}$$

BFGS sa $H_k = B_k^{-1}$

$$H_{k+1} = (I - \rho_k s_k y_k^T) H_k (I - \rho_k y_k s_k^T) + \rho_k s_k s_k^T, \text{ gde je } \rho_k = \frac{1}{y_k^T s_k}$$

Linijsko pretraživanje

$$x_{k+1} = x_k + a_k p_k, \quad a_k := \arg \min_{\alpha} f(x_k + \alpha p_k)$$



Wolfe uslovi

$$f(x_k + \alpha p_k) \leq f(x_k) + c_1 \alpha \nabla f_k^T p_k = l(\alpha), \text{ za neko } c_1 \in (0, 1).$$

$$\nabla f(x_k + \alpha p_k)^T p_k \geq c_2 \alpha \nabla f_k^T p_k, \text{ za neko } c_2 \in (c_1, 1).$$

Teorema (Zoutendijk, [9]). *Neka je iterativni niz $\{x_k\}$ definisan iteracijom $x_{k+1} = x_k + \alpha_k p_k$ sa opadajućim pravcima p_k i neka α_k zadovoljava Wolfe uslove.*

Neka je f ograničena odole na \mathbb{R}^n i neprekidno diferencijabilna na otvorenom skupu \mathcal{N} koji sadrži skup $\mathcal{L} = \{x : f(x) \leq f(x_0)\}$, gde je x_0 data početna iteracija.

Neka je, dalje, gradijent ∇f Lipšic neprekidan nad \mathcal{N} , odnosno:

$$\forall x, \tilde{x} \in \mathcal{N}, \|\nabla f(x) - \nabla f(\tilde{x})\| \leq L \|x - \tilde{x}\|, \text{ za neko } L > 0.$$

Onda

$$\sum_{k \geq 0} \cos^2 \theta_k \|\nabla f(x_k)\|^2 < \infty, \text{ gde je } \theta_k = \angle(p_k, -\nabla f_k), \cos \theta_k = \frac{-\nabla f_k^T p_k}{\|\nabla f_k\| \|p_k\|}.$$

Posledica

$$\lim_{k \rightarrow \infty} \cos^2 \theta_k \|\nabla f_k\|^2 = 0. \quad \text{Ako } \cos \theta_k \geq \delta, \text{ za neko } \delta > 0 \Rightarrow \lim_{k \rightarrow \infty} \|\nabla f(x_k)\| = 0.$$

Algoritmi linijskog pretraživanja

Algoritam 1 Backtracking Line Search

Input: $\bar{\alpha} > 0, 0 < \rho_{lo} < \rho_{hi} < 1, c \in (0, \frac{1}{2})$

Output: α koje zadovoljava Wolfe uslove

$\alpha := \bar{\alpha};$

while $f(x_k + \alpha p_k) > f(x_k) + c\alpha \nabla f_k^T p_k$ **do**

 choose $\rho \in [\rho_{lo}, \rho_{hi}]$;

$\alpha := \rho\alpha;$

end while

return

Algoritam 2 Line Search sa kubnom interpolacijom (nije naveden)

Input: $x_0 \in \mathbb{R}^n, f_0 \in \mathbb{R} (= \hat{f}(x_0)), f(\cdot) : \mathbb{R}^n \rightarrow \mathbb{R}, g_0 \in \mathbb{R}^n (= \hat{g}(x_0)), p \in \mathbb{R}^n, \lambda_{\min} \in \mathbb{R}^+,$
 $maxfcalcls \in \mathbb{Z}^+$

Output: $x_1, f_1, retcode \in \mathbb{Z}^+, \lambda \in \mathbb{R}^+, fcalcls \in \mathbb{Z}^+$

Metode stohastičke optimizacije

Slučajni šum $\zeta(x)$ je slučajna promenljiva nad prostorom verovatnoće (Ω, \mathcal{F}, P) .

$$F(x) = f(x) + \zeta(x), f : \mathbb{R}^n \rightarrow \mathbb{R}$$

Slučajni šum $\epsilon(x)$ je slučajni vektor nad prostorom verovatnoće (Ω, \mathcal{F}, P) .

$$G(x) = g(x) + \epsilon(x), g(x) : \mathbb{R}^n \rightarrow \mathbb{R}^n$$

Posmatraćemo probleme

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

$$g(x) = 0,$$

najčešće za $g = \nabla f$.

Stohastička aproksimacija (SA)

Dato x_0 i niz $\{a_k\}, k = 0, 1, \dots$ tipa $\frac{1}{k}$, odnosno, koji zadovoljava

$$a_k > 0, k = 0, 1, \dots, \sum_{k=0}^{\infty} a_k = \infty, \sum_{k=0}^{\infty} a_k^2 < \infty.$$

Definišemo

$$x_{k+1} = x_k - a_k G_k, k = 0, 1, 2, \dots, G_k = G(x_k) = g(x_k) + \epsilon_k(x_k),$$

koji konvergira ka x^* , rešenju $g(x) = 0$.

Praktičan izbor (Spall [11])

$$a_k = \frac{a}{(k+1+A)^\alpha}, a > 0, \alpha \in (0.5, 1], A \geq 0.$$

FDSA

$$\hat{G}_k^i = \frac{F(x_k + c_k e_i) - F(x_k)}{c_k}, i = 1, 2, \dots, n, c_k = \frac{c}{(k+1)^\gamma}, c > 0, \gamma > 0.$$

SPSA

$$\hat{G}_k = \frac{F(x_k + c_k \Delta_k) - F(x_k - c_k \Delta_k)}{2c_k} [\Delta_{k,1}^{-1}, \Delta_{k,2}^{-1}, \dots, \Delta_{k,n}^{-1}]^T,$$

gde su $\Delta_{k,i}$, $i = 1, 2, \dots, n$ nezavisne slučajne promenljive sa istom, dozvoljenom raspodelom.

Na primer $\Delta : \begin{pmatrix} -1 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$.

$$\frac{\text{broj računanja funkcije } F \text{ FDSA postupkom}}{\text{broj računanja funkcije } F \text{ SPSA postupkom}} \rightarrow \frac{1}{n}.$$

SPALL, J. *Introduction to Stochastic Search and Optimization: Estimation, Simulation, and Control*. Wiley Series in Discrete Mathematics and Optimization. Wiley, 2005

Kvazi Njutnove metode u stohastičkoj optimizaciji

ASP

$$x_{k+1} = x_k - a_k \bar{\bar{H}}_k^{-1} G_k, \quad \bar{\bar{H}}_k = \psi_k(\bar{H}_k)$$
$$\bar{H}_k = \frac{k}{k+1} \bar{H}_{k-1} + \frac{1}{k+1} \hat{H}_k, \quad k = 0, 1, \dots$$

2SG

$$\hat{H}_k = \frac{1}{2} \left[\frac{\delta G_k^T}{2c_k \Delta_k} + \left(\frac{\delta G_k^T}{2c_k \Delta_k} \right)^T \right],$$

gde je

$$\delta G_k = G_k(x_k + c_k \Delta_k) - G_k(x_k - c_k \Delta_k),$$

DSLS Descent Stochastic Line Search

KREJIĆ, N., LUŽANIN, Z., AND STOJKOVSKA, I. A gradient method for unconstrained optimization in noisy environment. *Appl. Numer. Math.* 70 (Aug. 2013), 1–21

KREJIĆ, N., LUŽANIN, Z., OVCIN, Z., AND STOJKOVSKA, I. Descent direction method with line search for unconstrained optimization in noisy environment. *Optimization Methods and Software* 30, 6 (2015), 1164–1184

Linijsko pretraživanje

- veći koraci koji brže vode ka rešenju
- nije potrebno podešavanje parametara

SA koraci

- dokazana konvergencija
- bez računanja funkcije cilja

DSLS

- x_k daleko od rešenja koriste se LS koraci
- u blizini rešenja koriste se SA koraci

Dokazana konvergencija sa SA koracima i opadajućim pravcima.

Dokazana dobra definisanost DSLS.

Algoritam 3 DSLS

Ulaz: $x_0 \in \mathbb{R}^n$, $c_1 \in (0, 1)$, $C, \underline{\delta}(C) > 0$ i $\{a_k\} \in \mathbb{R}$ tipa $\frac{1}{k}$.

Postavi $k = 0$, $phase = 1$.

Korak 1 Odaberi opadajući pravac ($G_k^T d_k < 0$).

Korak 2 Odaberi korak a_k .

Korak 3 Odredi novu iteraciju $x_{k+1} = x_k + a_k d_k$.

Korak 4 Postavi $k = k + 1$ pređi na korak 1.

Algoritam 4 Korak 2 Odaberi korak a_k .

Korak 2.1 Ako $phase = 1$ pređi na korak 2.2, inače pređi na korak 2.3

Korak 2.2 Ako $\|G_k\| \geq C$ odaberi $a_k > \underline{\delta}(C)$ tako da zadovoljava prvi Wolfe uslov, pređi na korak 3. Inače postavi $phase = 2$ i pređi na korak 2.3.

Korak 2.3 Odaberi a_k iz predefinisano ulaza a_k .

Dokazana skoro sigurna konvergencija DSLS.

Konvergencija po opadajućim pravcima sa SA koracima

Zadato $x_0 \in \mathbb{R}^n$, formiramo iterativni niz $x_{k+1} = x_k + a_k d_k$, $k = 0, 1, \dots$

- C1 Niz dužina koraka $\{a_k\}$ je tipa $\frac{1}{k}$
- C2 Niz šumova sa generisanim sigma algebrama $(\epsilon_k, \mathcal{F}_k)$ je niz martingal razlika za neopadajući niz sigma algeabri \mathcal{F}_k takav da važi $E(\epsilon_k | \mathcal{F}_{k-1}) = 0$, $E(\|\epsilon_k\|^2) < \infty$.
- C3 Funkcija g i uslovni drugi momenat realizovanog šuma su ograničeni:
 $\|g(x)\|^2 + E(\|\epsilon_k\|^2 | \mathcal{F}_{k-1}) < c(1 + v(x))$, $k = 0, 1, \dots$, za neko $c > 0$.
- C4 Za sve pravce d_k , $k = 0, 1, \dots$ važi $(x_k - x^*)^T E[d_k | \mathcal{F}_k] \leq -c_2 \|x_k - x^*\|$ skoro sigurno, za neko $c_2 > 0$.
- C5 Postoji $c_3 > 0$ tako da za sve $k = 0, 1, \dots$ važi $\|d_k\| \leq c_3 \|G_k\|$ skoro sigurno.

Teorema. *Ako su zadovoljeni uslovi C1 - C5, onda niz x_k konvergira ka x^* , rešenju problema minimizacije.*

Dobra definisanost DSLS algoritma

C6 Gradijent $g(x) = \nabla f(x)$ je Lipšic neprekidan, to jest, postoji $L > 0$ tako da

$$\|g(x) - g(y)\| \leq L\|x - y\| \quad \text{za sve } x, y \in \mathbb{R}^n.$$

C7 Realizacije šuma su ograničene i postoji $M > 0$ takvo da

$$\|\xi_k(x)\| \leq M, \|\varepsilon_k(x)\| \leq M \text{ skoro sigurno}$$

za sve $k = 0, 1, \dots$ i $x \in D$.

C8 Postoji $\delta > 0$ takvo da za sve $k = 0, 1, \dots$ $G_k^T d_k \leq -\delta \|G_k\| \|d_k\|$ skoro sigurno.

C9 Postoji $\underline{\Delta} \in (0, \Delta)$ takvo da za sve $k = 0, 1, \dots$ važi $\|d_k\| \geq \underline{\Delta}$ skoro sigurno.

Teorema. Neka važe pretpostavke C5 - C8 i neka $C \geq \frac{M+2\sqrt{2ML}+1}{\delta(1-c_1)}$. Onda skoro sigurno postoji $\delta(C) > 0$ kojim je algoritam DSLS dobro definisan.

Skoro sigurna konvergencija

Teorema. *Neka važe pretpostavke C6 - C9. Neka je*

$$C \geq \max\left\{\frac{2M+1}{\underline{\alpha}c_1\underline{\delta}\underline{\Delta}}, \frac{M+2\sqrt{2ML}+1}{\delta(1-c_1)}\right\},$$

$$\underline{\alpha} = \frac{\delta(1-c_1)(2\sqrt{2ML}+1)}{2Lc_3(M+2\sqrt{2ML}+1)}.$$

Neka je $\{x_k\}$ niz generisan Algoritmom DSLS. Neka je $\{x_j\}, j \in J$ podniz za koji važi

$$\|G_j\| \geq C.$$

Onda je $\{x_j\}$ skoro sigurno konačan.

Posledica

Ako važe pretpostavke C1 - C9, i uslov prethodne teoreme, onda iterativni niz generisan Algoritmom DSLS konvergira skoro sigurno ka rešenju problema minimizacije.

Fiksni Njutnov metod za model ekvilibriumuma

Problem: $F(x, W) = 0$, $x \in \mathbb{R}^n$, za vektor parametara W , $F(\cdot, W) : \mathbb{R}^n \rightarrow \mathbb{R}^n$.

Algoritam 5 FNM

Korak 0 Neka je dato $x^0 \in \mathbb{R}^n$ i (w^1, \dots, w^N) . Izračunati srednju vrednost $\bar{w} = \sum_{i=1}^N w^i / N$ i rešiti $F(x, \bar{w}) = 0$ Njutnovom metodom. Označimo rešenje $x^{\bar{w}}$ i definišimo $A = F'(x^{\bar{w}}, \bar{w})$.

Korak 1 Za $i = 1, \dots, N$

Korak 1i Postavi $x^{i,0} = x^{\bar{w}}$

Korak 2i Ponavljaj do konvergencije

$$As^{i,k} = -F(x^{i,k}, w^i), x^{i,k+1} = x^{i,k} + s^{i,k}, k = k + 1$$

Korak 3i Postavi $x^{i*} = x^{i,k}$

KREJIĆ, N., LUŽANIN, Z., AND OVCIN, Z. Stochastic Newton-like methods for computing equilibria in general equilibrium models. *Computational & Applied Mathematics* 30 (00 2011), 127 – 149

Dokazana konvergencija FNM.

Teorema o konvergenciji

D1 Za sve $w \in \bar{\Omega}$ postoji $x^{w*} \in D$ za koje je $F(x^{w*}, w) = 0$.

D2 Za sve $w \in \bar{\Omega}$ matrica Jakobijana $F'(x^{w*}, w)$ je nesingularna.

D3 Za sve $x, y \in D$ i $w \in \bar{\Omega}$ postoji $\gamma > 0$ za koje je $\|F'(x, w) - F'(y, w)\| \leq \gamma \|x - y\|$.

D4 Za sve $w_1, w_2 \in \bar{\Omega}$ i $x \in D$ postoji $\gamma_W > 0$ za koje je $\|F'(x, w_i) - F'(x, w_j)\| \leq \gamma_W \|w_i - w_j\|$.

Teorema. Neka F zadovoljava pretpostavke D1 - D4 i za $\epsilon_W = \text{diam}(\bar{\Omega})$ i $M = \|F'(x^{\bar{w}}, \bar{w})^{-1}\|$ postoji $\delta > 0$ takvo da je $\alpha = M(\gamma\delta + \gamma_W\epsilon_W) < 1$ i da je

$$\|F'(x^{\bar{w}}, \bar{w})^{-1}F(x^{\bar{w}}, w^i)\| \leq \delta(1 - \alpha),$$

onda za sve $w^i \in \bar{\Omega}$ niz $\{x^{w^i, k}\}_{k=0}^{\infty}, i = 1, 2, \dots, N$ definisan u Koraku 1 Algoritma FNM konvergira linearno ka rešenju $F(x, w^i) = 0$.

Modeli ekvilibriuma

Maksimizuje se funkcija korisnosti

$$x^j(\pi) = \arg \max_{\pi x \leq \pi \omega^j} u^j(x), \quad j = 1, 2, \dots, m.$$

Posmatramo tri slučaja funkcije korisnosti za koje su maksimumi

- Cobb-Douglas: $x_i^j(\pi) = \frac{\pi \cdot \omega^j}{\pi_i} a_i^j, \quad i = 1, 2, \dots, n$
- fiksne proporcije: $x_i^j(\pi) = \frac{\pi_i \cdot \omega^j}{\pi \cdot a^j} a_i^j, \quad i = 1, 2, \dots, n$
- CES: $x_i^j(\pi) = \frac{\pi \cdot \omega^j}{\pi_i^{b^j} \sum_{k=1}^n \pi_k^{1-b^j} a_k^j} a_i^j, \quad i = 1, 2, \dots, n.$

Funkcija viškova je $\zeta(\pi) = \sum_{j=1}^m x^j(\pi) - \sum_{j=1}^m \omega^j$, za početno zaduženje $\omega^j, j = 1, 2, \dots, m.$

Ekvilibrium je pozitivno π^* za koje je $\zeta(\pi^*) = 0.$

- Model prostornog ekvilibriuma.

Numerički rezultati

Implementacija DSLS

$$F_k = F(x_k) = \frac{1}{p} \sum_{i=1}^p F(x_k, \xi_{ki}), \quad G_k = \nabla F(x_k) = \frac{1}{p} \sum_{i=1}^p G(x_k, \varepsilon_{ki})$$

Linesearch vraća *retcode*:

- 0 = nađena zadovoljavajuća dužina α
- 1 = korak kraći od α_{\min}
- 2 = potrošena kvota *maxfcalc*
- 3 = greška zaokruživanja ili šum

U formulama za ažuriranje pravca SR1 i BFGS

$$\delta_k = x_{k+1} - x_k, \quad \Delta_k = G_{k+1} - G_k.$$

U stohastičkom okruženju: $\Delta_k = G(x_{k+1}, \varepsilon_{k+1}) - G(x_k, \varepsilon_k)$

Pošto raspoložemo šumom, uzimamo: $\Delta_k = G(x_{k+1}, \varepsilon_k) - G(x_k, \varepsilon_k)$.

Algoritam 6 DSLS

Input: $x_0 \in \mathbb{R}^n$, $F : \mathbb{R}^n \rightarrow \mathbb{R}$, $G : \mathbb{R}^n \rightarrow \mathbb{R}^n$, $itnlimit \in \mathbb{Z}$, $maxfcalcls \in \mathbb{Z}$, $gradtol \in \mathbb{R}$

Output: $y \in \mathbb{R}^n$, $G_y \in \mathbb{R}^n$, $termcode \in \mathbb{Z}$

...

for $itncount := 1$ **to** $itnlimit$ **do**

$d := -B^{-1}G_x$;

if $\neg near$ **then**

$[y, F_y, retcode, \lambda, fcalcls] := \text{Line Search}(x, F_x, F(\cdot), G_x, -G_x, maxfcalcls)$;

if $retcode = 2$ **then**

$\triangleright fcalcls \geq maxfcalcls$

$near := true$; $\lambda := \frac{a}{(itncount + 1 + A)^\alpha}$;

else

if $(retcode = 1) \parallel (retcode = 3)$ **then** $\lambda := \lambda_{\text{minfix}}$; **end if**

end if

else

$\lambda := \frac{a}{(itncount + 1 + A)^\alpha}$;

end if

end for

...

Testiranje DSLS

Testirano na 44 test problema.

MORÉ, J., GARBOW, B., AND HILLSTROM, K. Testing unconstrained optimization software. *ACM Trans. Math. Softw.* 7, 1 (Mar. 1981), 17–41

BURKHARDT, J. Test_opt, 2011. http://people.sc.fsu.edu/~jburkardt/m_src/test_opt/test_opt.h

Opšti iterativni postupak $x_{k+1} = x_k + \alpha_k d_k$,

$$d_k = -B_k^{-1} G_k.$$

Za potupak najbržeg opadanja G koristimo $B_k = I$, testiramo i SR1 pravce i BFGS pravce.

Testiramo DSLS algoritam (kraće LS) i SA algoritam koji koristi predefinisane pravce

$$a_k = \frac{a}{(k + 1 + A)^\alpha}, \quad k = 0, 1, \dots$$

sa $a = 1$, $A = 0$, $\alpha = 0.602$, k redni broj iteracije.

Kada to iskombinujemo, imamo 6 različitih algoritama. Označavaćemo ih:

SA-G	SA-BFGS	SA-SR1
LS-G	LS-BFGS	LS-SR1

Tri veličine šuma: $\sigma = 1, \sigma = 0.2$ i $\sigma = 0.04$.

$N = 50$ nezavisnih iterativnih postupaka sa istom početnom tačkom
 $itnlimit = \infty, maxfcalc = 200n$, gde je n dimenzija problema.

Računanje gradijenta se broji kao n računanja funkcije cilja.

$maxfcalcls = 4, p = 3$

Izlazni kriterijum je $gradtol = \min\{\sqrt{n}\sigma, 1\}$ ili $maxfcalc \geq 200n$.

$\|G_{end}\| \leq gradtol \rightsquigarrow$ postupak uspešan. Broj uspešnih = $Nconv$.

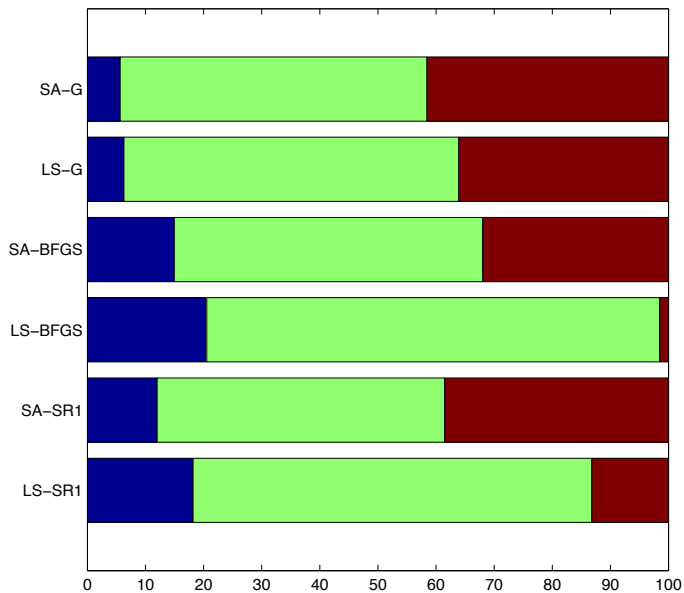
$\|G_{end}\| > 200\sqrt{n} \rightsquigarrow$ postupak divergirao. Broj koji su divergirali = $Ndiv$.

$fcalc \geq maxfcalc \rightsquigarrow$ postupak delimično uspešan. Broj delimično uspešnih = $Npar$.


DOLAN, E. D., AND MORÉ, J. J. Benchmarking optimization software with performance profiles. *Mathematical programming* 91, 2 (2002), 201–213

$$fc_{ij} = \frac{1}{|Ncon_{ij} \cup Npar_{ij}|} \sum_{r \in Ncon_{ij} \cup Npar_{ij}} \frac{fcalc_{ij}^r}{n_j},$$


Procenti broja uspešnih, delimično uspešnih i divergentnih



$\sigma = 1$





$\sigma = 0.2$




$\sigma = 0.04$

Performance profiles







Testiranje FNM

Cobb-Douglas

$$u^1(\pi) = \pi_1^{a_1^1} \pi_2^{1-a_1^1}.$$

$$u^2(\pi) = \min \left\{ \frac{\pi_1}{a_1^2}, \frac{\pi_2}{a_2^2} \right\}.$$

$$\xi_1(\pi) = a_1^1 \frac{3\pi_1 + \pi_2}{\pi_1} + a_1^2 \frac{\pi_1 + 2\pi_2}{a_1^2 \pi_1 + a_2^2 \pi_2} - 4$$

$$\xi_2(\pi) = (1 - a_1^1) \frac{3\pi_1 + \pi_2}{\pi_2} + a_2^2 \frac{\pi_1 + 2\pi_2}{a_1^2 \pi_1 + a_2^2 \pi_2} - 3.$$

Početna vrednost Njutnovog iterativnog postupka (NM) i FNM je $\pi_0 = (0.1, 0.9)$ za sve vrednosti uzorka. Izlazni kriterijum za oba algoritma NM i FNM je $\|\bar{\xi}\| < \epsilon = 10^{-6}$.

Za vrednost parametara $a_1^1 = 0.4$, $a_1^2 = 2$, $a_2^2 = 3$, NM daje rešenje u 6 iteracija.

Potom kreiramo uzorak od $N = 500$ vrednosti za parametre, sa normalnim raspodelama: $a_1^1 : \mathcal{N}(0.4, 0.05)$, $a_1^2 : \mathcal{N}(2.0, 0.05)$, $a_2^2 : \mathcal{N}(3.0, 0.05)$.

	NM	FNM
broj iteracija	2954	4553
broj izračunavanja funkcije	2954	4553
broj izračunavanja Jacobijana	2954	6
CPU vreme	0.156	0.098

Tabela 1: Rešavanje ekvilibriuma za neoklasičnu ekonomiju, Cobb-Douglass sa 2 robe i 2 agenta, veličine uzorka parametara $N = 500$

Za veće dimenzije problema prednost FNM u odnosu na NM u korišćenju CPU vremena je očiglednija.

	NM iter	NM CPU	FNM iter	FNM CPU
$m = 4, n = 3$	2134	0.773	3156	0.555
$m = 8, n = 6$	2893	1.383	3200	0.606
$m = 16, n = 12$	3072	3.554	3949	0.959
$m = 32, n = 24$	2514	14.592	4144	1.988

Tabela 2: Primer 2

Hvala na pažnji!

Literatura

- [1] BLUM, J. R. Approximation methods which converge with probability one. *Ann. Math. Statist.* 25, 2 (06 1954), 382–386.
- [2] BLUM, J. R. Multidimensional stochastic approximation methods. *Ann. Math. Statist.* 25, 4 (12 1954), 737–744.
- [3] BURKHARDT, J. Test_opt, 2011. http://people.sc.fsu.edu/~jburkardt/m_src/test_opt/test_opt.html.
- [4] DOLAN, E. D., AND MORÉ, J. J. Benchmarking optimization software with performance profiles. *Mathematical programming* 91, 2 (2002), 201–213.
- [5] KREJIĆ, N., LUŽANIN, Z., AND OVCIN, Z. Stochastic Newton-like methods for computing equilibria in general equilibrium models. *Computational & Applied Mathematics* 30 (00 2011), 127 – 149.
- [6] KREJIĆ, N., LUŽANIN, Z., OVCIN, Z., AND STOJKOVSKA, I. Descent direction method with line search for unconstrained optimization in noisy environment. *Optimization Methods and Software* 30, 6 (2015), 1164–1184.

- [7] KREJIĆ, N., LUŽANIN, Z., AND STOJKOVSKA, I. A gradient method for unconstrained optimization in noisy environment. *Appl. Numer. Math.* 70 (Aug. 2013), 1–21.
- [8] MORÉ, J., GARBOW, B., AND HILLSTROM, K. Testing unconstrained optimization software. *ACM Trans. Math. Softw.* 7, 1 (Mar. 1981), 17–41.
- [9] NOCEDAL, J., AND WRIGHT, S. J. *Numerical Optimization*. Springer Series in Operations Research and Financial Engineering. Springer, 2006.
- [10] ROBBINS, H., AND MONRO, S. A stochastic approximation method. *The Annals of Mathematical Statistics* 22, 3 (09 1951), 400–407.
- [11] SPALL, J. *Introduction to Stochastic Search and Optimization: Estimation, Simulation, and Control*. Wiley Series in Discrete Mathematics and Optimization. Wiley, 2005.