

# Modifikace metody BFGS s omezenou pamětí, založené na myšlence sdružených směrů \*

Jan Vlček, Ladislav Lukšan

ICS ASCR Praha 8, L. Lukšan také TU Liberec

J. Vlček, L. Lukšan: *A conjugate directions approach to improve the limited-memory BFGS method*, Report V-1120, ICS ASCR, Prague 2011.

\*Tato práce vznikla s podporou RVO: 67985807

## 1. ÚVOD

**Předmět práce:** úprava metody BFGS s omezenou pamětí (L-BFGS) pro nepodmíněnou minimalizaci pomocí vektorových korekcí, které využívají hodnot z předchozí iterace.

**Běžně** – takové korekce se odvozují z interpolačních metod.

**Zde** – korekce odvozené z myšlenky **sdružených směrů** (podobný přístup lze najít ve zprávě Hu, Storey 1991).

Pro kvadratické účelové funkce je zlepšení konvergence **nejlepší možné** v jistém smyslu.

Metoda L-BFGS (Liu, Nocedal 1989) patří mezi **metody s proměnnou metrikou** typu **line search** - **kvazinewtonovské metody** pro efektivní lokální minimalizaci diferencovatelných funkcí  $f: \mathcal{R}^N \rightarrow \mathcal{R}$ , založené na **lokálním kvadratickém modelu**

$$Q(d) = \frac{1}{2}d^T B d + g^T d, \quad g = \nabla f(x), \quad d = -Hg \dots \text{směrový vektor},$$

$B = H^{-1}$  ... aproximace **Hessovy matice** funkce  $f$  v bodě  $x$ .

Zvolíme  $x_0 \in \mathcal{R}^N$ . **Iterace**  $x_{k+1} \triangleq x_+$  se generuje:  $x_+ = x + td$ ,  $k > 0$ ,  $t > 0$  ... **délka kroku**, splňující (slabé) **Wolfeovy podmínky**

$$f(x_+) - f(x) \leq \varepsilon_1 t g^T d, \quad g_+^T d \geq \varepsilon_2 g^T d, \quad 0 < \varepsilon_1 < \frac{1}{2}, \quad \varepsilon_1 < \varepsilon_2 < 1.$$

**Matice** se konstruují iteračně, obvykle  $H_0 = I$ , další  $H_+$  spd, blízko k  $H$  a splňující kvazinewtonovskou podmínku

$$H_+ y = s, \quad y = g_+ - g, \quad s = x_+ - x.$$

Metoda **BFGS** (1970) patří mezi nejefektivnější metody s proměnnou metrikou; aktualizaci lze psát ve tvaru

$$H_+ = \frac{1}{b} s s^T + V H V^T, \quad V = I - \frac{1}{b} s y^T, \quad b = s^T y,$$

na němž je právě **L-BFGS** – metoda BFGS s omezenou pamětí, adaptace metody BFGS pro velký počet proměnných, založena; neukládají se  $N \times N$  matice  $H$ , jen max  $m$  dvojic vektorů  $s, y$  ( $m \geq 1$  je parametr), směrový vektor  $d = -H g$  se počítá Strangovými rekurencemi (Nocedal 1980).

## Vektorové korekce

Uvažujeme korigované vektory

$$\bar{s}_0 = s_0, \quad \bar{y}_0 = y_0, \quad \bar{s}_k = s_k - \alpha_k \bar{s}_{k-1}, \quad \bar{y}_k = y_k - \beta_k \bar{y}_{k-1},$$

$k > 0$ , s takovými  $\alpha_k, \beta_k \in \mathcal{R}$ , aby  $\bar{s}_k^T \bar{y}_k > 0$ .

**Korigovaný směrový vektor:**  $-\bar{H}_k g_k$  místo  $-H_k g_k$ , kde  $\bar{H}_0 = I$   
a matici  $\bar{H}_{k+1}$  získáme tak, že počáteční matici

$$(s_k^T y_k / y_k^T y_k) I$$

opakovaně aktualizujeme užitím aktualizace BFGS s korigovanými vektory  $\bar{s}_i, \bar{y}_i$  místo  $s_i, y_i$ ,  $i \in [\max(k-m+1, 0), k]$ ,  $k \geq 0$ .

## 2. KORIGOVANÁ AKTUALIZACE BFGS

Abychom zjistili, jak volba  $\alpha_k, \beta_k$  ovlivní matici  $\bar{H}_{k+1}$ , budeme vyšetřovat **vliv parametrů**  $\alpha, \beta$  na vlastnosti aktualizace

$$(*) \quad \bar{H}_+ = \frac{1}{\bar{b}} \bar{s} \bar{s}^T + \bar{V} \bar{H} \bar{V}^T, \quad \bar{V} = I - \frac{1}{\bar{b}} \bar{s} \bar{y}^T, \quad \bar{b} = \bar{s}^T \bar{y} > 0$$

pro **libovolnou** spd matici  $\bar{H}$  splňující  $\bar{H} \bar{y}_- = \bar{s}_-$  (zde  $\bar{H} \neq \bar{H}_k$ ).

Je-li (\*) poslední z aktualizací, které vytvářejí matici  $\bar{H}_{k+1}$ , je  $\bar{H} \bar{y}_- = \bar{s}_-$  vždy splněno pro  $m > 1$  (QNP s předchozími vektory).

Podmínky konjugovanosti  $\bar{s}, \bar{s}_-$  vzhledem k  $\bar{B} = \bar{H}^{-1}, \bar{B}_+ = \bar{H}_+^{-1}$ :

$$\bar{s}_-^T \bar{B}_+ \bar{s} = \bar{s}_-^T \bar{B} \bar{s} = 0.$$

Protože  $\bar{B}_+ \bar{s} = \bar{y}, \bar{B} \bar{s}_- = \bar{y}_-$ , lze psát:  $\bar{s}_-^T \bar{y} = \bar{s}^T \bar{y}_- = 0 \Rightarrow \alpha, \beta$ .

**Jinak:** kromě QNP  $\bar{H}_+ \bar{y} = \bar{s}$  je splněna i podmínka pro  $\bar{y}_-, \bar{s}_-$ :

**Lemma 1.** Buď  $\bar{H}$  lib. spd matice s  $\bar{H} \bar{y}_- = \bar{s}_-, \bar{H}_+$  z (\*) a vektory  $\bar{s}, \bar{H} \bar{y}$  lineárně nezávislé. Pak  $\bar{s}_-^T \bar{B}_+ \bar{s} = \bar{s}_-^T \bar{B} \bar{s} = 0 \Leftrightarrow \bar{H}_+ \bar{y}_- = \bar{s}_-$ .

Tato formulace konjugovanosti umožňuje **odlišit** role  $\bar{s}_-^T \bar{y}_-, \bar{s}_-^T \bar{y}$ :

**Lemma 2.** Buď  $\bar{H}$  lib. spd matice s  $\bar{H} \bar{y}_- = \bar{s}_-$  a  $\bar{H}_+$  z (\*). Pak

$$\bar{b}(\bar{H}_+ \bar{y}_- - \bar{s}_-)^T \bar{B}_+ (\bar{H}_+ \bar{y}_- - \bar{s}_-) = (\bar{s}_-^T \bar{y} - \bar{s}_-^T \bar{y}_-)^2 + \omega (\bar{s}_-^T \bar{y}_-)^2,$$

kde  $\omega = \bar{y}^T \bar{H} \bar{y} / \bar{b} - \bar{b} / \bar{s}_-^T \bar{B} \bar{s} \geq 0$ ,  $\omega = 0$  jen při závislosti  $\bar{s}, \bar{H} \bar{y}$ .

$\omega$  může být velké, proto by mělo hlavně být  $0 = \bar{s}_-^T \bar{y}_- = s^T \bar{y}_- - \alpha \bar{b}_-$ ,  
má-li být  $\bar{H}_+ \bar{y}_- \approx \bar{s}_- \Rightarrow \alpha = s^T \bar{y}_- / \bar{b}_-$  ... užito všude v dalším.

Pro  $\beta$  je **základní volba**  $\beta_Z = \bar{s}_-^T \bar{y} / \bar{b}_- \Rightarrow \bar{s}_-^T \bar{y} = 0, \bar{H}_+ \bar{y}_- = \bar{s}_-$   
 podle lemmatu 2. Tato hodnota má další **zajímavé vlastnosti**:

**Věta 1.** Buď  $\bar{H}$  lib. spd matice s  $\bar{H} \bar{y}_- = \bar{s}_-$  a  $\bar{H}_+$  z (\*). Je-li  $\alpha = s^T \bar{y}_- / \bar{b}_-$ , pak  $\bar{s}_-^T \bar{y}_- = 0, \bar{b} = b - \alpha \beta_Z \bar{b}_-$  a volba  $\beta = \beta_Z$  **minimalizuje** jak  $\bar{y}^T \bar{H} \bar{y}$  tak  $\text{cond}(\bar{H}^{1/2} \bar{B}_+ \bar{H}^{1/2})$  jako funkce  $\beta$ .

**Věta 2.** Buď  $\bar{H}_-$  lib. spd matice,  $\bar{H}$  aktualizace (\*) matice  $\bar{H}_-$  s  $\bar{s}_-, \bar{y}_-, \bar{b}_- > 0$  místo  $\bar{s}, \bar{y}, \bar{b}, \bar{H}_+$  spd,  $\bar{H}_+ \bar{y}_- = \bar{s}_-, W = \bar{B}_+^{1/2} \bar{H} \bar{B}_+^{1/2}$  a  $W_- = \bar{B}_+^{1/2} \bar{H}_- \bar{B}_+^{1/2}$ . Pak (Frobeniovy maticové normy)

$$\|I - W_-\|_F^2 - \|I - W\|_F^2 = \|W - W_-\|_F^2 \geq (\bar{y}_-^T \bar{H}_- \bar{y}_- / \bar{b}_- - 1)^2.$$

$\Rightarrow$  matice  $\bar{H}_+$  je k  $\bar{H}$  v jistém smyslu **vždy blíže, než k  $\bar{H}_-$ .**



Ačkoliv volba  $\beta_Z$  dává dobré výsledky, není vždy nejlepší. Mělo by také být  $\beta \approx \alpha$ , má-li být přibližně splněna i **QNP s nekorigovanými** vektory  $s, y$  (L3). Často je lepší  $\pm\sqrt{\beta_Z\alpha}$  – výhodné pro **globální konvergenci** – dále, navíc zajímavé vlastnosti (L4).

**Lemma 3.** Buď  $\bar{H}$  lib. spd matice s  $\bar{H}\bar{y}_- = \bar{s}_-$  a  $\bar{H}_+$  z (\*). Je-li  $\alpha = s^T\bar{y}_-/\bar{b}_-$ , pak

$$(\bar{H}_+y - s)^T\bar{B}_+(\bar{H}_+y - s) = \bar{b}_- \left[ \frac{(s^T\bar{y}_-)^2}{\bar{b}\bar{b}_-}(\beta - \beta_Z)^2 + (\beta - \alpha)^2 \right].$$

**Lemma 4.** Buď  $\bar{H}$  lib. spd matice s  $\bar{H}\bar{y}_- = \bar{s}_-$  a  $\bar{H}_+$  z (\*). Je-li  $\alpha = s^T\bar{y}_-/\bar{b}_-$ ,  $\beta^2 = \beta_Z\alpha = \bar{s}_-^T y s^T\bar{y}_-/\bar{b}_-^2$ , pak  $y^T(\bar{H}_+y - s) = 0$ .

### 3. VÝSLEDKY PRO KVADRATICKÉ FUNKCE

Zde předpokládáme  $\beta = \alpha$ , aby  $\bar{y}_k = G\bar{s}_k$ ,  $G \dots$  Hessova matice. Věta říká, že zlepšení konvergence pomocí korekcí  $s$ ,  $y$  je v jistém smyslu **nejlepší možné:** (Frobeniova maticová norma)

**Věta 3.** Buď  $\bar{H}$  lib. spd matice s  $\bar{H}\bar{y}_- = \bar{s}_-$ ,  $\bar{H}_+$  z (\*) a  $f$  kvadratická funkce  $f(x) = \frac{1}{2}(x - x^*)^T G(x - x^*)$  se spd maticí  $G$ ,  $x^* \in \mathcal{R}^N$ . Jsou-li vektory  $s$ ,  $\bar{s}_-$  lineárně nezávislé, pak je vždy  $\bar{b} > 0$  a volba  $\alpha = \hat{\alpha} = s^T \bar{y}_- / \bar{b}_- = \bar{s}_-^T y / \bar{b}_-$  implikuje  $\bar{H}_+ y = s$  a *minimalizuje* hodnoty  $\bar{b}$ ,  $\|G^{1/2} \bar{H}_+ G^{1/2} - I\|_F$  jako funkce  $\alpha$ .

L-BFGS s přesnými LS generuje konjugované směrové vektory a zachovává  $m$  QNP. Podobně i zde pro jednotkové kroky:

**Věta 4.** Buď  $x_0, x^* \in \mathcal{R}^N$ ,  $\bar{k} > 0$ ,  $m \geq 1$ ,  $f$  kvadratická funkce  $f(x) = \frac{1}{2}(x - x^*)^T G(x - x^*)$  se spd maticí  $G$  a pro  $0 \leq k \leq \bar{k}$  buďte iterace  $x_{k+1} = x_k + s_k$  generovány metodou  $s_k = -t_k \bar{H}_k g_k$ ,  $t_k > 0$ ,  $g_k = \nabla f(x_k)$ , s těmito maticemi  $\bar{H}_k$ :  $\bar{H}_0 = I$  a matice  $\bar{H}_{k+1}$ ,  $0 \leq k < \bar{k}$ , jsou dány opakovanou BFGS aktualizací s vektory  $(\bar{s}_{k-\tilde{m}}, \bar{y}_{k-\tilde{m}}), \dots, (\bar{s}_k, \bar{y}_k)$  a počáteční maticí  $(s_k^T y_k / y_k^T y_k)I$ , kde  $\tilde{m} = \min(k, m - 1)$ ,  $y_k = g_{k+1} - g_k$ , a veličiny  $\bar{s}_j, \bar{y}_j, \bar{b}_j, j \geq 0$ , jsou formálně definovány  $\bar{s}_0 = s_0, \bar{y}_0 = y_0, \bar{s}_{j+1} = s_{j+1} - \alpha_{j+1} \bar{s}_j, \bar{y}_{j+1} = y_{j+1} - \alpha_{j+1} \bar{y}_j, \alpha_{j+1} = s_{j+1}^T \bar{y}_j / \bar{b}_j, \bar{b}_j = \bar{s}_j^T \bar{y}_j$ .

Je-li každý generovaný vektor  $s_k$  lineárně nezávislý na  $\bar{s}_{k-1}$ ,  $0 < k \leq \bar{k}$ , je metoda dobře definována. Je-li navíc  $t_{k+1} = 1$  pro nějaké  $k, 0 \leq k < \bar{k}$ , platí

$$\bar{H}_{k+i} \bar{y}_k = \bar{s}_k, \bar{s}_k^T G \bar{s}_{k+i} = 0, \bar{s}_k^T g_{k+i+1} = 0, i \in [1, \min(\tilde{m} + 1, \bar{k} - k)].$$

## 4. IMPLEMENTACE

Podle předchozí teorie bychom měli korigovat, kdykoliv se účelová funkce blíží **kvadratické**. Jako **míru odchylky** lze vzít např.  $|s_k^T y_{k-1} - s_{k-1}^T y_k|$  (0 pro kvadratické funkce). Zde bereme

$$\delta = |s_k^T \bar{y}_{k-1} - \bar{s}_{k-1}^T y_k| = \bar{b}_{k-1} |\alpha_k - \beta_k|$$

– snáze použitelné, velmi podobné výsledky. Nekorigujeme, je-li  $\delta \geq \bar{b}_{k-1}^2 / b_k$ , mají-li čísla  $s_k^T \bar{y}_{k-1}$ ,  $\bar{s}_{k-1}^T y_k$  různá znaménka nebo je-li  $\bar{b}_k \leq 10^{-6} b_k$ .

Za těchto podmínek je  $0 \leq \beta_Z \alpha \leq b / \bar{b}_-$  (V1:  $\bar{b} = b - \alpha \beta_Z \bar{b}_-$ )  
 $\Rightarrow$  volba  $\beta = \pm \sqrt{\beta_Z \alpha}$  výhodná pro **globální konvergenci**; navíc je obvykle pro  $\bar{b}_k > 10^{-2} b_k$  lepší.

Ostatní úpravy nevýznamné, jen pro globální konvergenci.

## Algoritmus 4.1

**Data:** Počet  $m$  BFGS aktualizací na iteraci, parametry pro určení délky kroku  $\varepsilon_1, \varepsilon_2, 0 < \varepsilon_1 < \frac{1}{2}, \varepsilon_1 < \varepsilon_2 < 1$  a korekční parametr  $\Delta > 1$ .

**Krok 0: Inicializace.** Definujeme startovací bod  $x_0 \in \mathcal{R}^N$ , matici  $\bar{H}_0 = I$ , směrový vektor  $d_0 = -g_0$  a čítač iterací  $k = 0$ .

**Krok 1: Jednorozměrná minimalizace.** Vypočteme  $x_{k+1} = x_k + t_k d_k$  (WP),  $s_k = x_{k+1} - x_k$ ,  $g_{k+1} = \nabla f(x_{k+1})$ ,  $y_k = g_{k+1} - g_k$  a  $b_k = s_k^T y_k$ . Pro  $k=0$  položíme  $\bar{s}_k = s_k$ ,  $\bar{y}_k = y_k$  a přejdeme na krok 4.

**Krok 2: Příprava korekce.** Položíme  $\alpha_k = s_k^T \bar{y}_{k-1} / \bar{b}_{k-1}$ ,  $\beta_k = \bar{s}_{k-1}^T y_k / \bar{b}_{k-1}$ .

Je-li  $\alpha_k \beta_k \leq 0$  nebo  $\bar{b}_k \leq 10^{-6} b_k$  nebo  $|\alpha_k - \beta_k| \geq \bar{b}_{k-1} / b_k$ , položíme

$\alpha_k = \beta_k = 0$  a přejdeme na krok 3. Je-li  $|\beta_k|^2 > 4b_k / \bar{b}_{k-1}$  nebo

$\bar{b}_k > 10^{-2} b_k$ , nahradíme  $\beta_k$  číslem  $\beta_k \sqrt{\alpha_k / \beta_k}$ .

**Krok 3: Korekce.** Položíme  $\bar{s}_k = s_k - \alpha_k \bar{s}_{k-1}$ ,  $\bar{y}_k = y_k - \beta_k \bar{y}_{k-1}$ .

**Krok 4: Definice aktualizací.** Buď  $\tilde{m} = \min(k, m-1)$ . Je-li  $|\bar{s}_{k-\tilde{m}}| / |s_{k-\tilde{m}}| > \Delta$  nebo  $|\bar{y}_{k-\tilde{m}}| / |y_{k-\tilde{m}}| > \Delta$ , položíme  $\bar{s}_{k-\tilde{m}} = s_{k-\tilde{m}}$ ,  $\bar{y}_{k-\tilde{m}} = y_{k-\tilde{m}}$  a  $\bar{b}_{k-\tilde{m}} = b_{k-\tilde{m}}$ . Definujeme matici  $\bar{H}_{k+1}$  opakovanou aktualizací BFGS s vektory  $(\bar{s}_{k-\tilde{m}}, \bar{y}_{k-\tilde{m}}), \dots, (\bar{s}_k, \bar{y}_k)$  a počáteční maticí  $(s_k^T y_k / y_k^T y_k) I$ .

**Krok 5: Směrový vektor.** Vypočteme  $d_{k+1} = -\bar{H}_{k+1} g_{k+1}$  pomocí Strangových rekurencí, položíme  $k := k+1$  a přejdeme na krok 1.

## 5. GLOBÁLNÍ KONVERGENCE

**Předpoklad 1.** Účelová funkce  $f: \mathcal{R}^N \rightarrow \mathcal{R}$  je **zdola omezená** a **stejněměrně konvexní** a má **omezené druhé derivace** (tj.  $0 < \underline{G} \leq \underline{\lambda}(G(x)) \leq \bar{\lambda}(G(x)) \leq \bar{G} < \infty$ ,  $x \in \mathcal{R}^N$ , kde  $\underline{\lambda}(G(x))$ ,  $\bar{\lambda}(G(x))$  jsou nejmenší a největší vlastní čísla Hessovy matice  $G(x)$ ).

**Věta 5.** Nechť účelová funkce  $f$  splňuje předpoklad 1. Pak algoritmus 4.1 generuje posloupnost  $\{g_k\}$ , která buď terminuje s  $g_k = 0$  pro nějaké  $k$ , nebo platí  $\lim_{k \rightarrow \infty} |g_k| = 0$ .

## 6. NUMERICKÉ VÝSLEDKY

Porovnáme počty vyčíslení a doby výpočtu pro 3 kolekce úloh: **test 11** (Lukšan et al. 2010, 55 úloh,  $N = 1000-5000$  -upravená CUTE, Bongartz et al. 1995), **test 12** (Andrei 2008, 73 úloh,  $N = 5000$ ) a **test 25** (Lukšan et al. 2010, 68 úloh,  $N = 10\,000$ ).

**Parametry:**  $m = 5$ , přesnost  $\|g(x^*)\|_\infty \leq 10^{-6}$ ,  
 $\Delta = 100$ ,  $\varepsilon_1 = 10^{-4}$ ,  $\varepsilon_2 = 0.8$ .

Porovnáváme s **metodami:** L-BFGS a metoda z PANM 15.

**Výsledky** jsou uvedeny v tabulce 1, kde 'NFE' je celkový počet vyčíslení hodnot funkcí a rovněž gradientů pro všechny úlohy a 'Čas' celková doba výpočtu ve vteřinách.

Metoda	Test 11		Test 12		Test 25	
	NFE	Čas	NFE	Čas	NFE	Čas
L-BFGS	80539	32.50	43648	46.17	462104	519.40
Algorithm 4.1	64395	30.20	34472	37.57	296321	381.08
Alg. PANM 15	80328	34.52	43182	56.67	512880	649.15

Tabulka 1. Porovnání s L-BFGS a metodou z PANM 15.



Pro lepší znázornění efektivity a spolehlivosti porovnáme metody u testu 25 i pomocí **výkonnostních profilů** (Dolan, Moré 2002):

$$\pi_M(\tau) = \frac{\text{počet úloh s } \dots \log_2(\tau_{\hat{U},M}) \leq \tau}{\text{celkový počet úloh}},$$

kde

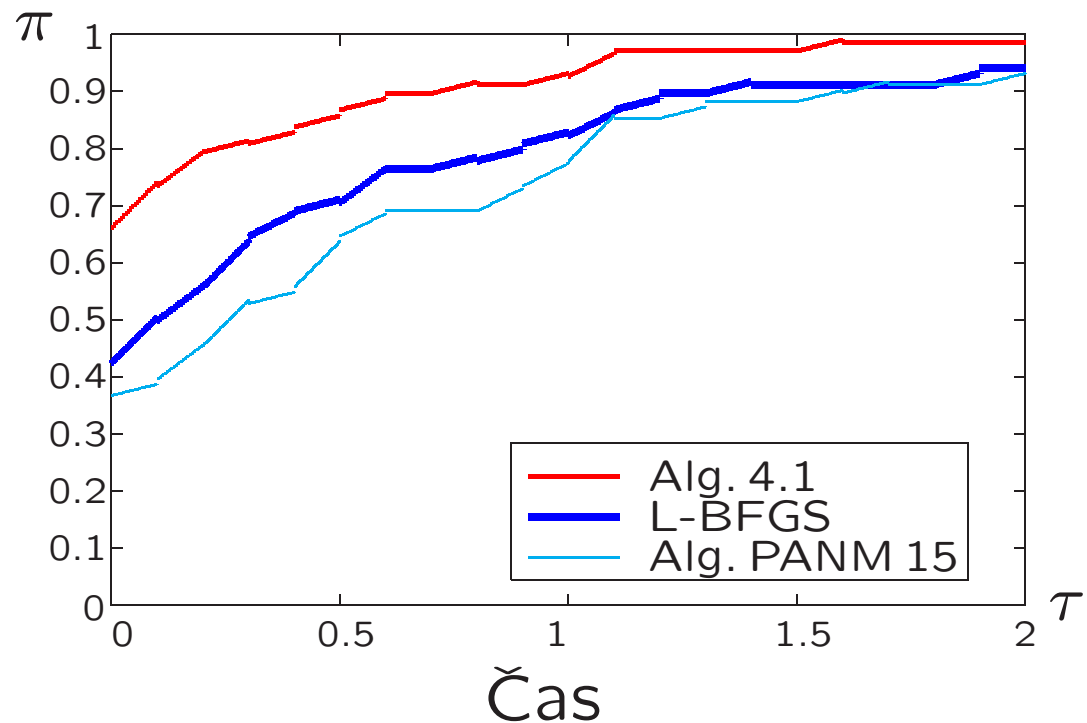
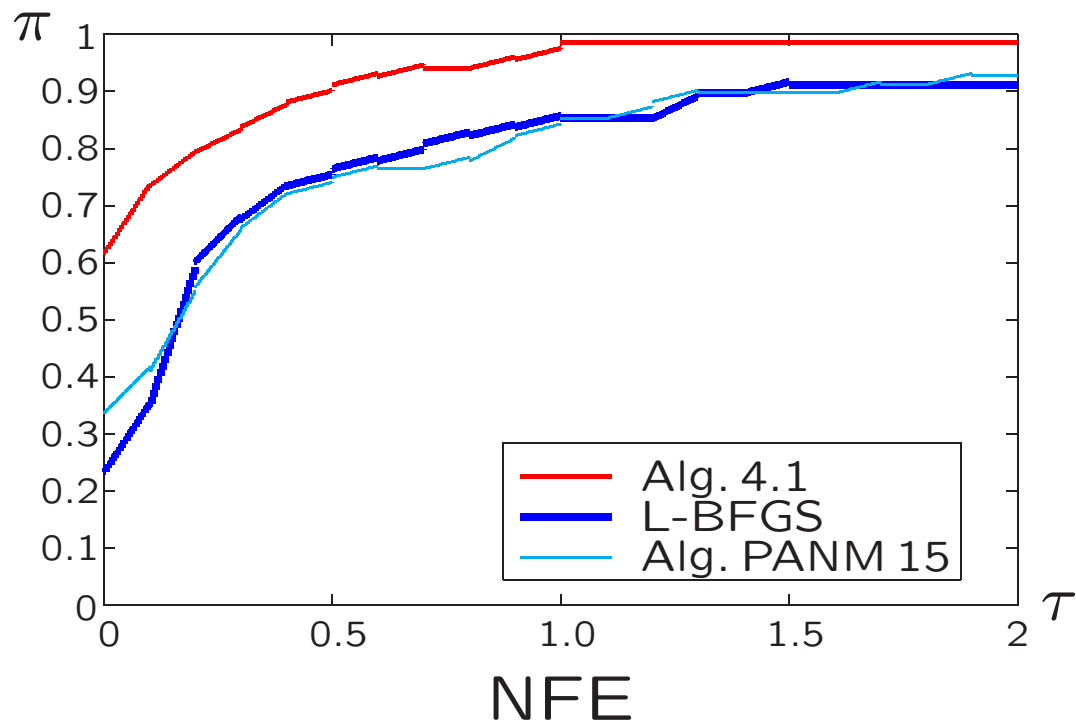
$$\tau_{\hat{U},M} = P_{\hat{U},M} / \min_M P_{\hat{U},M},$$

resp.

$$\tau_{\hat{U},M} = \infty \dots \text{když metoda } M \text{ **selže** při řešení úlohy } \hat{U},$$

$P_{\hat{U},M}$  je počet funkčních vyčíslení | čas potřebný k vyřešení úlohy  $\hat{U}$  metodou  $M$ ,  $\tau \geq 0$ .

Hodnota  $\pi_M(0)$  dává procentní počet úloh, kdy je metoda  $M$  nejlepší a  $\pi_M(\tau)$  pro  $\tau$  velká je procentní počet úloh, které metoda  $M$  vyřeší; čím výše je křivka, tím lepší metodě odpovídá.



Obrázek 1 (Test 25, 68 úloh,  $m = 5$ ,  $N = 10\,000$ ).

# Literatura

- [1] N. Andrei, *An unconstrained optimization test functions collection*, Advanced Modeling and Optimization, 10 (2008) 147-161.
- [2] I. Bongartz, A.R. Conn, N. Gould, P.L. Toint: *CUTE: constrained and unconstrained testing environment*, ACM Transactions on Mathematical Software 21 (1995), 123-160.
- [3] E.D.Dolan, J.J.Moré: *Benchmarking optimization software with performance profiles*, Mathematical Programming 91 (2002) 201-213.
- [4] Y.F.Hu, C.Storey: *Motivating Quasi-Newton Updates by Preconditioned Conjugate Gradient Methods*, Math. Report A 150, Department of Mathematical Sciences, Loughborough University of Technology, England, 1991.
- [5] D.C. Liu, J. Nocedal: *On the limited memory BFGS method for large scale optimization*, Math. Programming 45 (1989) 503-528.
- [6] L. Lukšan, C. Matonoha, J. Vlček: *Sparse test problems for unconstrained optimization*, Report V-1064, Praha, ICS ASCR, 2010.
- [7] L. Lukšan, C. Matonoha, J. Vlček: *Modified CUTE problems for sparse unconstrained optimization*, Report V-1081, Prague, ICS AS CR, 2010.
- [8] J. Nocedal: *Updating quasi-Newton matrices with limited storage*, Math. Comp. 35 (1980) 773-782.

DĚKUJI ZA POZORNOST !