

## 2. Přednáška: Line search

Úloha:

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

kde  $x \in \mathbb{R}^n$ ,  $n \geq 1$  a  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  je dvakrát spojitě diferencovatelná.

**Iterační algoritmy:**

- Začínám v  $x_0$  a vytvářím posloupnost iterací  $\{x_k\}_{k=1}^{\infty}$  tak, aby minimum bylo aproximováno s dostatečnou přesností, ideálně končila v přesném řešení.
- K posunutí z  $x_k$  do  $x_{k+1}$ , aby  $f(x_{k+1}) < f(x_k)$  mohu použít informace o  $x_0, \dots, x_{k-1}$  a jejich funkčních hodnotách.
- 2 základní strategie, jak se posunout z  $x_k$  do  $x_{k+1}$ : Line search, trust region.

**Line search algoritmus:**

Dáno  $x_0$ , interval  $(a, b)$ ,  $\varepsilon$  atd. a pro  $k = 0, 1, 2, \dots$ :

- 1) najdi směr  $p_k \in \mathbb{R}^n$  - spádový směr,
- 2) najdi  $\alpha_k$  tak, aby  $x_k + \alpha_k p_k$  bylo "lepší" než  $x_k$  (ideálně minimální - exaktní line search, dostatečně malé - aproximace),
- 3) polož  $x_{k+1} = x_k + \alpha_k p_k$ .

Příklad3.m

ad 1) viz další přednášky,

ad 2) hledání minima jednodimenzionální funkce  $\phi(\alpha) = f(x_k + \alpha p_k)$ , tj. řeším úlohu:

$$\min_{\alpha > 0} \phi(\alpha).$$

## Jednodimenzionální minimalizace:

### Definice: Unimodální funkce

Funkce  $\phi : \mathbb{R} \rightarrow \mathbb{R}$  je unimodální na intervalu  $\langle a, b \rangle$ , jestliže existuje  $c \in \langle a, b \rangle$  takové, že  $\phi$  je klesající na  $\langle a, c \rangle$  a rostoucí na  $\langle c, b \rangle$ .

### Věta: Pozice minima

Nechť  $\phi$  je unimodální v  $\langle a, b \rangle$  a nabývá svého minima v  $\alpha^* \in \langle a, b \rangle$ . Pak pro libovolné  $x$  a  $y$ , kde  $a \leq x < y \leq b$  platí následující tvrzení:

- Je-li  $\phi(x) < \phi(y)$ , pak  $\alpha^* < y$ .
- Je-li  $\phi(x) > \phi(y)$ , pak  $\alpha^* > x$ .
- Je-li  $\phi(x) = \phi(y)$ , pak  $x < \alpha^* < y$ .

### Algoritmus:

Za předpokladu unimodální funkce  $\phi$  a pomocí výše uvedené věty generuji posloupnost zmenšujících se intervalů obsahujících řešení  $\alpha^*$  (intervaly neurčitosti):

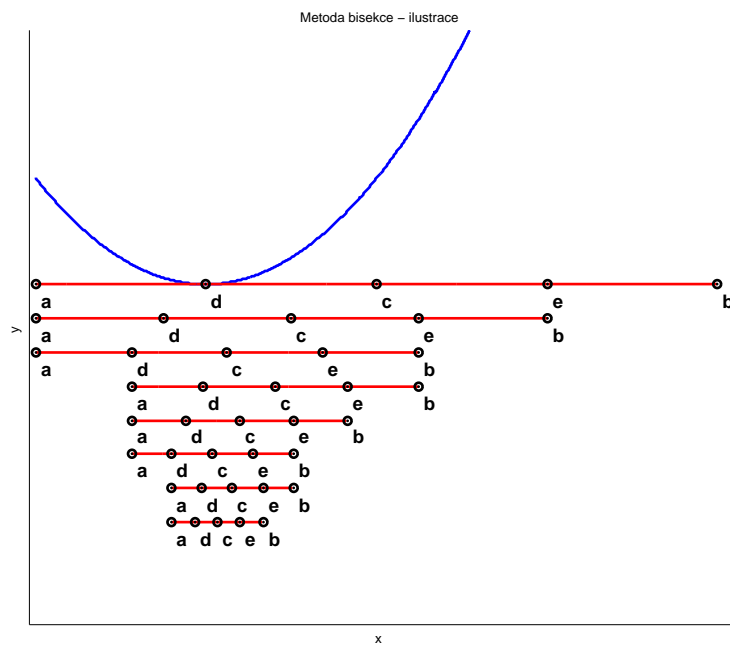
$$\langle a, b \rangle = I_0 \supset I_1 \supset \dots \supset I_{k-1} \supset I_k = \langle a_k, b_k \rangle,$$

$\Delta_k \equiv b_k - a_k$  značí délku  $k$ -tého intervalu. Požaduji co nejmenší vyhodnocování funkce  $\phi$ , co největší redukci intervalů, jednoduchost.

## Metody:

- **Metoda bisekce:**

- dělení intervalu  $(a, b)$  na poloviny,
- jednoduché, drahé - hodně vyhodnocování  $\phi$ ,
- více možností,
- Prikklady3\_bisekce.m



- **Fibonacciho metoda:**

- Fibonacciho posloupnost:  $F_0 = F_1 = 1$ ,  $F_k = F_{k-1} + F_{k-2}$ ,  $k = 2, \dots, N$

$$1, 1, 2, 3, 5, 8, 13, 21, 34, 55, 89, \dots$$

- Příklad3\_fibonacci.m

- optimální, dělení intervalu  $(a, b)$  v poměru fibonacciho čísel  $\frac{F_{N-1}}{F_N} > \frac{1}{2}$ ,

- když chceme zpřesnit, musíme začít od začátku (nová volba  $N$ ),

- 

$$\Delta_0 = b_0 - a_0,$$

$$c_0 = b_0 - \frac{F_{N-1}}{F_N} \Delta_0,$$

$$d_0 = a_0 + \frac{F_{N-1}}{F_N} \Delta_0,$$

$$c_0 = a_0 + \frac{F_{N-2}}{F_N} \Delta_0,$$


$$\Delta_1 = b_1 - a_1 = \frac{F_{N-1}}{F_N} \Delta_0,$$

$$c_1 = b_1 - \frac{F_{N-2}}{F_N} \Delta_1,$$

$$d_1 = a_1 + \frac{F_{N-2}}{F_N} \Delta_1,$$

- nový bod je umístěn v daném intervalu symetricky s již existujícím bodem

$$\Delta_k = \frac{F_{N-k}}{F_N} \Delta_0.$$

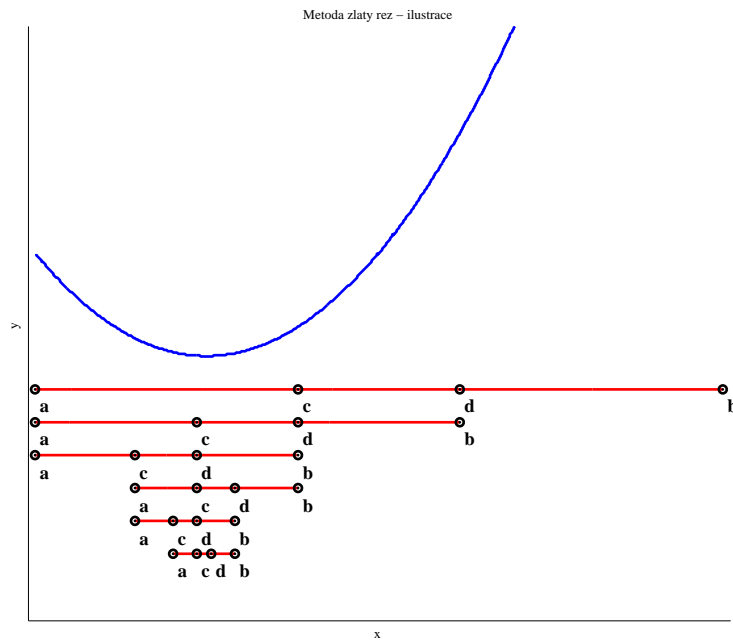


• **Metoda zlatého řezu:**

- optimální,
- zafixujeme zkracování intervalu na jedné hodnotě:

$$\xi = \lim_{N \rightarrow \infty} \frac{F_{N-1}}{F_N},$$

- platí  $\xi = \frac{\sqrt{5}-1}{2}$  - zlatý řez,
- $\Delta_k = \xi^k \Delta_0$ ,
- Prikklady3\_zlatyrez.m



• **Newtonova metoda:**

- Nechť  $\phi(x)$  je hladká funkce, unimodální na intervalu  $(a, b)$ .
- Aproximujeme  $\phi(x)$  pomocí kvadratické funkce  $q(x)$ , která se bude shodovat v následujících parametrech:

$$\phi(x_k) = q(x_k), \quad \phi'(x_k) = q'(x_k), \quad \phi''(x_k) = q''(x_k)$$

⇒ Taylorův polynom 2. řádu


$$\phi(x) \approx q(x) = \phi(x_k) + \phi'(x_k)(x - x_k) + \frac{\phi''(x_k)}{2}(x - x_k)^2$$

- $x_{k+1}$  je bod minima funkce  $q(x)$ .
- Nutná podmínka extrému:

$$q'(x) = \phi'(x_k) + \phi''(x_k)(x - x_k) = 0,$$

Stacionární bod:  $x = x_k - \frac{\phi'(x_k)}{\phi''(x_k)}$ .

- Protože jde o kvadratickou funkci, je stacionární bod i lokálním minimem (zároveň i globálním minimem)
- ⇒ iterační předpis  $x_{k+1} = x_k - \frac{\phi'(x_k)}{\phi''(x_k)}$ .
- Příklad3\_newton.m



• **Interpolace pomocí kvadratické funkce:**

- trojice bodů  $[x_1, \phi(x_1)]$ ,  $[x_2, \phi(x_2)]$ ,  $[x_3, \phi(x_3)]$
- interpolace kvadratickou funkcí (např. Lagrangeův interpolační polynom), nepotřebují derivace:

$$\phi(x) \approx q(x) = \phi(x_1) \frac{(x - x_2)(x - x_3)}{(x_1 - x_2)(x_1 - x_3)} + \phi(x_2) \frac{(x - x_1)(x - x_3)}{(x_2 - x_1)(x_2 - x_3)} + \phi(x_3) \frac{(x - x_1)(x - x_2)}{(x_3 - x_1)(x_3 - x_2)}$$

- $x_4$  je bodem minima funkce  $q(x)$ .
- Vyberu novou trojici bodů porovnáním funkčních hodnot  $\phi(x_1)$ ,  $\phi(x_2)$ ,  $\phi(x_3)$ ,  $\phi(x_4) \Rightarrow (x_2, x_4, x_3)$  nebo  $(x_1, x_2, x_4)$ .

- **Testování dostatečného poklesu:**

- Dilema přesnost  $\times$  výpočetní čas.
- Použití minimalizační metody (viz výše), ale zastavím hledání řešení, pokud interval neurčitosti splňuje podmínku:


$$|\alpha^* - \bar{\alpha}| \leq c\bar{\alpha},$$

kde  $\alpha^*$  je přesné řešení,  $\bar{\alpha}$  je aktuální řešení,  $|\alpha^* - \bar{\alpha}|$  délka intervalu neurčitosti.

- Spokojím se s dostatečným poklesem.

**Přímka udávající pokles:**

- $x_k, p_k$  spádový směr  $\phi'(0) = \text{grad}^T f(x_k)p_k < 0$ .
- Chci zvolit  $\alpha$  tak, aby  $\phi(\alpha) \equiv f(x_k + \alpha p_k)$  dostatečně pokleslo a  $\alpha$  nebylo ani malé ani velké.
- Přímka udávající pokles: pro dané  $\varepsilon \in (0, 1)$ :  $l(\alpha) \equiv \phi(0) + \varepsilon\phi'(0)\alpha$ .
- Pro všechna  $\alpha$  taková, že  $\phi(\alpha) < l(\alpha)$  platí  $f(x_k + \alpha p_k) = \phi(\alpha) < \phi(0) = f(x_k)$ .





**Armijův test (podmínka):**

- Pokud bude  $\alpha$  malé i pokles může být malý.
- Volba tak, aby například dvojnásobné (desetinásobné)  $\alpha$  už nesplnilo podmínku  $\phi(\alpha) < l(\alpha)$ , tj. zvol  $\eta$  ( $\eta = 2$ ) a najdi  $\alpha$  tak, aby

$$\phi(\alpha) \leq \phi(0) + \varepsilon\phi'(0)\alpha \tag{1}$$

^

$$\phi(\eta\alpha) > \phi(0) + \varepsilon\phi'(0)\alpha. \tag{2}$$

- Pseudo-algoritmus:
  - Start: volím  $\varepsilon$  (v praxi volíme malé,  $10^{-4}$ ),  $\eta$ ,  $\alpha \dots$
  - Pokud je splněna (1), prováděj  $\alpha = \eta\alpha$  dokud není splněna (2).
  - Pokud není splněna (1), prováděj  $\alpha = \frac{\alpha}{\eta}$ , dokud není splněna (1).
- Interval přípustných hodnot  $\alpha$  nemusí obsahovat minimum funkce  $\phi(\alpha)$ .
- Příklad3\_pokles.m

**Goldsteinův test (podmínka):**

- Zvolím  $\varepsilon \in (0, \frac{1}{2})$  tak, aby

$$\phi(\alpha) \leq \phi(0) + \varepsilon\phi'(0)\alpha. \quad (3)$$

- Aby  $\alpha$  nebylo příliš malé, musí ležet nad jinou přímkou, tj.

$$\phi(\alpha) \geq \phi(0) + (1 - \varepsilon)\phi'(0)\alpha. \quad (4)$$

- Interval přípustných hodnot  $\alpha$  nemusí obsahovat minimum funkce  $\phi(\alpha)$ .
- Příklad3\_goldstein.m

**Wolfeho test (podmínka):**

- Zvolím  $\varepsilon \in (0, \frac{1}{2})$  tak, aby

$$\phi(\alpha) \leq \phi(0) + \varepsilon\phi'(0)\alpha. \quad (5)$$

- Dám požadavek na sklon: pokud jsem blízko minima  $\phi(\alpha)$  má menší sklon než  $\phi(0)$ .
- Wolfeho podmínka: (5) a

$$\phi(\alpha)' \geq (1 - \varepsilon)\phi'(0). \quad (6)$$

- Silná Wolfeho podmínka: (5) a

$$|\phi(\alpha)'| \leq (1 - \varepsilon)|\phi'(0)|. \quad (7)$$

- Nemusím se omezovat jen jedním  $\varepsilon$ .
- Alternativa: pro  $0 < c_1 < c_2 < 1$

$$\phi(\alpha) \leq \phi(0) + c_1\phi'(0)\alpha,$$

$$\phi'(\alpha) \geq c_2\phi'(0),$$

$$|\phi(\alpha)| \leq c_2|\phi'(0)|.$$

- Wolfeho test zaručí jak dostatečný pokles  $\phi(\alpha)$ , tak dostatečný nárůst  $\phi'(\alpha)$  vzhledem k  $\alpha = 0$ .
- Příklad3\_wolfe.m

### Konvergence algoritmů typu Line-search:

- Body  $x_k$  nalezené Line-search algoritmem obecně nemusí konvergovat k přesnému řešení  $x^*$ .
- Konvergenci lze chápat v různém smyslu:  
 $\lim_{k \rightarrow \infty} x_k = x^*$  nebo  $\lim_{k \rightarrow \infty} \|\nabla f(x_k)\| = 0$ .
- Označme  $\cos \theta_k = \frac{-p_k^T \nabla f_k}{\|\nabla f_k\| \|p_k\|}$ ,  $\theta_k \dots$  úhel svírající zvolený spádový směr a směr největšího spádu.
- Lipchitzovská spojitost  $\nabla f(x)$  na  $\Omega$ : existuje konstanta  $L > 0$  taková, že

$$\|\nabla f(x) - \nabla f(y)\| \leq L\|x - y\|, \quad \forall x, y \in \Omega.$$

- Vrstevnicová oblast  $\Gamma_{f(x_0)} \equiv \{x : f(x) \leq f(x_0)\}$ .

**Věta:** Nechť  $x_0 \in \mathbb{R}^n$  je počáteční přiblížení a nechť  $f \in \mathbf{C}^1(\Omega)$ , kde  $\Omega$  je otevřená množina obsahující vrstevnicovou oblast  $\Gamma_{f(x_0)}$ . Dále nechť  $\nabla f$  je Lipschitzovsky spojitý na  $\Omega$ . Uvažujme algoritmus Line-search, tj. iterace  $x_{k+1} = x_k + \alpha_k p_k$ , kde  $p_k$  je spádový směr a  $\alpha_k$  splňuje Wolfeho podmínky. Potom

$$\sum_{k \geq 0} \cos^2(\theta_k) \|\nabla f(x_k)\|^2 < \infty$$

a tato podmínka implikuje

$$\cos^2(\theta_k) \|\nabla f(x_k)\|^2 \rightarrow 0 \quad \text{pro } k \rightarrow \infty.$$

**Definice:** Řekneme, že konvergentní posloupnost  $\{x_k\}$  konverguje k  $x^*$  rychlostí řádu  $p$ , pokud existují čísla  $0 < c < 1$  a  $k_0 > 0$  taková, že platí

$$\frac{\|\epsilon_{k+1}\|}{\|\epsilon_k\|^p} \leq c, \quad \forall k \geq k_0.$$

Kde  $\epsilon_k \equiv x_k - x^*$ .

Pro  $p = 1$  mluvíme o lineární rychlosti konvergence,

pro  $p = 2$  mluvíme o kvadratické rychlosti konvergence.

Pokud platí

$$\frac{\|\epsilon_{k+1}\|}{\|\epsilon_k\|} \leq a_k,$$

kde  $\{a_k\}$  je posloupnost nezáporných čísel,  $a_k \rightarrow 0^+$  pro  $k \rightarrow \infty$ , hovoříme o superlineární konvergenci.

# Základní spádové metody

Úloha:

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

kde  $x \in \mathbb{R}^n$ ,  $n \geq 1$  a  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ .

**Iterační algoritmy:**

- Začínám v  $x_0$  a vytvářím posloupnost iterací  $\{x_k\}_{k=0}^{\infty}$ , tak, aby minimum bylo aproximováno s dostatečnou přesností, ideálně končila v přesném řešení.
- K posunutí z  $x_k$  do  $x_{k+1}$ , aby  $f(x_{k+1}) < f(x_k)$  mohu použít informace o  $x_0, \dots, x_{k-1}$  a jejich funkčních hodnotách.

**Line search algoritmus:**

Dáno  $x_0$ , interval  $(a, b)$ ,  $\varepsilon$  atd. a pro  $k = 0, 1, 2, \dots$ :

- 1) najdi spádový směr  $p_k \in \mathbb{R}^n$ , tj.  $\nabla^T f(x_k)p_k < 0$ , směr  $p_k$  NESMÍ být kolmý k  $\nabla f(x_k)$ .
- 2) najdi  $\alpha_k$  tak, aby  $x_k + \alpha_k p_k$  bylo "lepší" než  $x_k$ ,
- 3) polož  $x_{k+1} = x_k + \alpha_k p_k$ .

**Metoda největšího spádu:**

- $f \in C^1(\mathbb{R}^n)$ , směr  $p_k = -g_k = -\nabla f(x_k)$ .
- Globálně konvergentní,  $\theta_k = \pi$ ,  $\forall k$ , v praxi pomalá.
- Důležitá z teoretického hlediska.

**Kvadratická funkce  $f$ :**

- Předpokládejme funkci  $f$  ve tvaru  $f(x) = \frac{1}{2}x^T Ax - x^T b$ , kde  $A$  je symetrická pozitivně definitní matice.
- Gradient:  $g_k = Ax_k - b$ .
- Stacionární bod  $Ax_k = b$  - soustava lineárních algebraických rovnic.
- Hessova matice  $H_k = A$  je pozitivně definitní  $\rightarrow$  ostře konvexní funkce, tj. stacionární bod je globální minimum.

- Zvolme  $f_1(x) = \frac{1}{2}\|x - x^*\|_A^2$ , potom  $f(x) = f_1(x) - \frac{1}{2}x^{*T}Ax^* \rightarrow f(x)$  a  $f_1(x)$  se liší jen o konstantu  $\rightarrow$  mají stejné lokální minimum, stejný gradient.

$$\begin{aligned} f_1(x) &= \frac{1}{2}\|x - x^*\|_A^2 = \frac{1}{2}(x - x^*)^T A(x - x^*) = \frac{1}{2}(x^T Ax - x^{*T} Ax - x^T Ax^* + x^{*T} Ax^*) = \\ &= \frac{1}{2}x^T Ax - x^T Ax^* + \frac{1}{2}x^{*T} Ax^* = \frac{1}{2}x^T Ax - x^T b + \frac{1}{2}x^{*T} Ax^*. \end{aligned}$$

- Dáno  $x_0$ ,  $x_{k+1} = x_k - \alpha_k g_k$ , kde  $g_k = Ax_k - b$  a  $\alpha_k = \frac{g_k^T g_k}{g_k^T A g_k}$  (exaktní line-search).

$$\begin{aligned} \phi(\alpha) &= f(x_k - \alpha g_k) = \frac{1}{2}(x_k - \alpha g_k)^T A(x_k - \alpha g_k) - (x_k - \alpha g_k)^T b = \frac{1}{2}x_k^T Ax_k - \frac{1}{2}\alpha g_k^T Ax_k - \\ &- \frac{1}{2}\alpha x_k^T A g_k + \frac{1}{2}\alpha^2 g_k^T A g_k - x_k^T b + \alpha g_k^T b = \frac{1}{2}x_k^T Ax_k - \alpha g_k^T Ax_k + \alpha g_k^T b - x_k^T b + \frac{1}{2}\alpha^2 g_k^T A g_k. \end{aligned}$$

$$\frac{d\phi(\alpha)}{d\alpha} = -g_k^T Ax_k + g_k^T b + \alpha g_k^T A g_k = 0$$

$$g_k^T (b - Ax_k) + \alpha g_k^T A g_k = 0$$

$$\alpha g_k^T A g_k = g_k^T g_k \quad \Rightarrow \quad \alpha = \frac{g_k^T g_k}{g_k^T A g_k}.$$

- Gradient lze počítat rekurzivně:  $g_{k+1} = g_k - \alpha_k A g_k$ .

$$g_{k+1} = Ax_{k+1} - b = A(x_k - \alpha_k g_k) - b = Ax_k - \alpha_k A g_k - b = g_k - \alpha_k A g_k.$$

- Příklady4.m

### Rychlost konvergence:

- $\|x_{k+1} - x^*\|_A^2 = \left(1 - \frac{(g_k^T g_k)^2}{(g_k^T A g_k)(g_k^T A^{-1} g_k)}\right) \|x_k - x^*\|_A^2 \dots$  špatně se interpretuje.

- Důkaz:

$$\|x_{k+1} - x^*\|_A^2 = (1 - c)\|x_k - x^*\|_A^2 = \|x_k - x^*\|_A^2 - c\|x_k - x^*\|_A^2$$

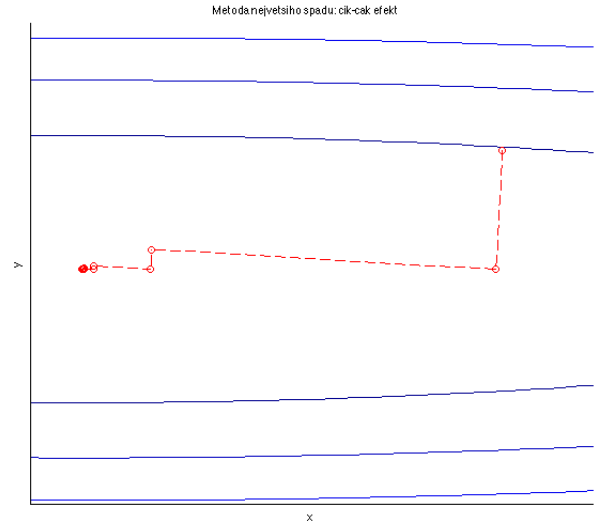

$$\|x_k - x^*\|_A^2 - \|x_{k+1} - x^*\|_A^2 = c\|x_k - x^*\|_A^2$$

1.  $x_{k+1} = x_k - \alpha_k g_k$

2.  $\alpha_k = \frac{g_k^T g_k}{g_k^T A g_k}$

3.  $g_k = Ax_k - b = A(x_k - x^*)$

4.  $\|x_k - x^*\|_A^2 = \|x_k - A^{-1}b\|_A^2 = (x_k - A^{-1}b)^T A(x_k - A^{-1}b) = x_k^T Ax_k - b^T A^{-1}Ax_k - x_k^T AA^{-1}b + b^T A^{-1}AA^{-1}b = (Ax_k - b)^T A^{-1}(Ax_k - b) = g_k^T A^{-1}g_k$



$$\begin{aligned} \|x_k - x^*\|_A^2 - \|x_{k+1} - x^*\|_A^2 &= (x_k - x^*)^T A(x_k - x^*) - (x_{k+1} - x^*)^T A(x_{k+1} - x^*) = \\ &= x_k^T A x_k - x^{*T} A x_k - x_k^T A x^* + x^{*T} A x^* - x_{k+1}^T A x_{k+1} + x^{*T} A x_{k+1} + x_{k+1}^T A x^* - x^{*T} A x^* = \dots \end{aligned}$$

$$\begin{aligned} x_{k+1}^T A x_{k+1} &= (x_k - \alpha_k g_k)^T A(x_k - \alpha_k g_k) = x_k^T A x_k - \alpha_k g_k^T A x_k - \alpha_k x_k^T A g_k + \alpha_k^2 g_k^T A g_k \\ x^{*T} A x_{k+1} + x_{k+1}^T A x^* &= 2x^{*T} A x_{k+1} = 2x^{*T} A(x_k - \alpha_k g_k) = 2x^{*T} A x_k - 2\alpha_k x^{*T} A g_k \\ -x^{*T} A x_k - x_k^T A x^* &= -2x^{*T} A x_k \end{aligned}$$

$$\begin{aligned} \dots &= x_k^T A x_k - 2x^{*T} A x_k - x_k^T A x^* + \alpha_k g_k^T A x_k + \alpha_k x_k^T A g_k - \alpha_k^2 g_k^T A g_k + 2x^{*T} A x_k - 2\alpha_k x^{*T} A g_k = \\ &= 2\alpha_k g_k^T A(x_k - x^*) - \alpha_k^2 g_k^T A g_k = \frac{2g_k^T g_k}{g_k^T A g_k} g_k^T g_k - \frac{(g_k^T g_k)^2}{(g_k^T A g_k)^2} \cdot g_k^T A g_k = \frac{(g_k^T g_k)^2}{(g_k^T A g_k)} \|x_k - x^*\|_A^2 = \\ &= \frac{(g_k^T g_k)^2}{(g_k^T A g_k)(g_k^T A^{-1} g_k)} \|x_k - x^*\|_A^2 \end{aligned}$$

- $c \in (0, 1) \rightarrow 1 - c < 1$

**Věta:** Necht' je funkce  $f(x)$  ostře konvexní ( $A$  je symetrická, pozitivně definitní) a aplikujeme metodu největšího spádu, tj.  $x_{k+1} = x_k - \alpha_k g_k$ , kde  $\alpha_k = \frac{g_k^T g_k}{g_k^T A g_k}$ , potom pro chybu platí:

$$\|x_{k+1} - x^*\|_A^2 \leq \left( \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} \right)^2 \|x_k - x^*\|_A^2,$$

kde  $0 < \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$ , jsou vlastní čísla matice  $A$ .

- Lineární rychlost konvergence.
- Kantorovičova nerovnost: Nechť  $A \in \mathbb{R}^{n \times n}$  je symetrická pozitivně definitní matice, potom pro všechna netriviální  $x$  platí

$$\frac{(x^T x)^2}{(x^T A x)(x^T A^{-1} x)} \geq \frac{4\lambda_1 \lambda_n}{(\lambda_1 + \lambda_n)^2}.$$

- $c = \left(\frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1}\right)^2 = \left(\frac{\kappa - 1}{\kappa + 1}\right)^2$ ,  $\kappa = \frac{\lambda_n}{\lambda_1}$  je číslo podmíněnosti matice  $A$ .
  - $\kappa = \text{cond}(A) \approx 800 \rightarrow$  dobrá podmíněnost matice  $A$
  - $c = \left(\frac{799}{801}\right)^2 = 0.995 \rightarrow$  pomalá konvergence
  - čím menší je  $c$ , tj.  $\lambda_1 \approx \lambda_n$  (například  $A = kI \rightarrow \lambda_1 = \dots = \lambda_n = 1$ ), potom jsou hladiny podobné kružnicím  $\rightarrow$  rychlá konvergence
  - čím větší  $c$ , potom se hladiny protahují do elips a čím protaženější elipsy, tím horší cik-cak efekt.
- Příklad4.m

### Nekvadratická funkce $f$ :

- Podobné použití, problém gradient a line-search.
- V blízkosti minima funkce  $f(x)$  se začne blížit kvadratické funkci (Taylorův polynom).
- Konverguje lineárně s faktorem  $c$  a  $\lambda_1, \lambda_n$  jsou vlastní čísla Hessovy matice  $H(x_k) = \nabla^2 f(x_k)$ .

### Newtonova metoda:

- $f$  aproximujeme lokálně kvadratickou funkcí, minimum je další aproximace.
- Taylorův polynom v bodě  $x_k$ :

$$f(x) \approx q(x) = f(x_k) + \nabla f(x_k)^T (x - x_k) + \frac{1}{2} (x - x_k)^T H(x_k) (x - x_k).$$

- Stacionární bod:

$$\nabla q(x) = \nabla f(x_k) + H(x_k)(x - x_k) = 0,$$

$$x = x_{k+1} = x_k - H(x_k)^{-1} \nabla f(x_k).$$

- Vyřešit  $H(x_k)d_k = -g_k$ ,  $x_{k+1} = x_k + d_k$  - čistá Newtonova metoda.
- V každém kroku se řeší soustava lineárních algebraických rovnic.
- V blízkosti řešení, nebo pokud je  $f(x)$  ostře konvexní, potom  $H(x_k)$  je pozitivně definitní.

**Věta:** Nechť  $f(x) \in \mathbf{C}^2(\mathbb{R}^n)$  a  $\nabla^2 f(x) = H(x)$  je Lipschitzovsky spojitá v okolí řešení  $x^*$ . Předpokládejme Newtonovu iterační metodu  $x_{k+1} = x_k + p_k$ , kde  $p_k = -H^{-1}(x_k)g_k$ , potom

a) pokud je  $x_0$  blízko řešení  $x^*$ , potom posloupnost Newtonových iterací konverguje k řešení,

b) rychlost konvergence posloupnosti  $\{x_k\}$  je kvadratická,

c) posloupnost  $\{\|\nabla f_k\|\}$  konverguje k nule kvadraticky.

- Základní Newtonova metoda není vhodná pro praktické výpočty.
- $H_k$  nemusí být symetrická pozitivně definitní a i pokud je, nemusí iterace konvergovat ( $x_0$  je daleko od  $x^*$ ).



### Line search:

- Pokud  $H_k$  je symetrická pozitivně definitní a  $d_k = -H_k^{-1}g_k$ , potom  $g_k^T d_k = -g_k^T H_k^{-1}g_k < 0 \rightarrow d_k$  je spádový směr.
- $x_{k+1} = x_k - \alpha_k H_k^{-1}g_k$ , minimalizace ve směru blízko řešení, tj,  $\alpha_k \approx 1$ .
- Prikklady4\_Newton.m

Obecně lze uvažovat třídu algoritmů

$$x_{k+1} = x_k - \alpha_k M_k g_k,$$

kde  $M_k \in \mathbb{R}^{n \times n}$ , pokud  $M_k = I \rightarrow$  metoda největšího spádu, pro  $M_k = H_k^{-1} \rightarrow$  Newtonova metoda. Nejlépe pokud  $M_k$  je symetrická pozitivně definitní  $\rightarrow$  zajistím spádovost směru  $p_k = -M_k g_k$ .

- $g_k^T p_k < 0 \rightarrow -g_k^T M_k g_k < 0$  pokud  $M_k$  je SPD