

3. Přednáška: Metody sdružených směrů:

Odstranění nevýhod metody největšího spádu \times Newtonovy metody.

Strategie volby "vhodných" směrů:

Definice (sdružené směry): Necht' $A \in \mathbb{R}^{n \times n}$ je symetrická, pozitivně definitní matice. Nenulové vektory x, y nazveme sdružené vzhledem k A (A -ortogonální), pokud platí $y^T A x = 0$.

Lemma: Je-li A symetrická pozitivně definitní a jsou-li nenulové vektory p_0, p_1, \dots, p_k A -ortogonální, pak jsou lineárně nezávislé.

Důkaz:

Pokud jsou směry lineárně závislé, potom $\sum_{i=0}^k \alpha_i p_i = 0$ a alespoň jedno α_i musí být nenulové.

$$\Rightarrow \alpha_0 p_0 + \alpha_1 p_1 + \dots + \alpha_j p_j + \dots + \alpha_k p_k = 0 \quad / p_j^T A \quad \forall j$$

$$\alpha_0 p_j^T A p_0 + \alpha_1 p_j^T A p_1 + \dots + \alpha_j p_j^T A p_j + \dots + \alpha_k p_j^T A p_k = 0$$

$$\Rightarrow \alpha_j p_j^T A p_j = 0 \quad \forall j$$

A je symetrická pozitivně definitní, tj. $p_j^T A p_j > 0, \forall j$.

$$\Rightarrow \alpha_j = 0, \forall j \rightarrow \text{spor}$$

- Mohu minimalizovat v jednotlivých směrech.
- Necht' p_0, p_1, \dots, p_{n-1} je n nenulových A -ortogonálních vektorů, potom

$$x^* = \alpha_0 p_0 + \dots + \alpha_{n-1} p_{n-1},$$

n A -ortogonálních vektorů $\rightarrow n$ lineárně nezávislých vektorů \rightarrow báze prostoru $\mathbb{R}^n \rightarrow$ každý prvek prostoru lze napsat jako lineární kombinaci báze

$$\alpha_i = \frac{p_i^T A x^*}{p_i^T A p_i} = \frac{p_i^T b}{p_i^T A p_i},$$

$$x^* = \alpha_0 p_0 + \dots + \alpha_{n-1} p_{n-1} / p_0^T A \text{ zleva}$$

$$p_0^T A x^* = \alpha_0 p_0^T A p_0 + \alpha_0 p_0^T A p_0 + \dots + \alpha_{n-1} p_0^T A p_{n-1}$$

$$\alpha_0 = \frac{p_0^T A x^*}{p_0^T A p_0} = \frac{p_0^T b}{p_0^T A p_0}$$

⋮

$$\alpha_i = \frac{p_i^T b}{p_i^T A p_i}$$

$$x^* = \sum_{i=0}^{n-1} \left(\frac{p_i^T b}{p_i^T A p_i} \right) p_i.$$

Metody sdružených směrů:

Úloha:

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

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

$$f(x) = \frac{1}{2} x^T A x - x^T b,$$

kde $A \in \mathbb{R}^{n \times n}$ je symetrická pozitivně definitní matice.

Úloha: $Ax = b$, kde $A \in \mathbb{R}^{n \times n}$ je symetrická pozitivně definitní matice.

Věta: Necht p_0, p_1, \dots, p_{n-1} je n nenulových A -ortogonálních vektorů. Pro libovolné $x_0 \in \mathbb{R}^n$, posloupnost $\{x_k\}$, definovanou

$$x_{k+1} = x_k + \alpha_k p_k$$

s volbou

$$\alpha_k = -\frac{g_k^T p_k}{p_k^T A p_k},$$

kde

$$g_k = A x_k - b$$

konverguje k jednoznačnému řešení x^* . Řešení nalezne po nejvýše n krocích, tj. $x_n = x^*$.

Důkaz:

- p_0, p_1, \dots, p_{n-1} je n A -ortogonálních vektorů, tj. jsou lineárně nezávislé a tedy tvoří bázi prostoru \mathbb{R}^n . Tedy existuje $\tilde{\alpha}_i$ tak, že platí

$$x^* - x_0 = \sum_{i=0}^{n-1} \tilde{\alpha}_i p_i$$

$$p_k^T A(x^* - x_0) = \tilde{\alpha}_0 p_k^T A p_0 + \tilde{\alpha}_1 p_k^T A p_1 + \dots + \tilde{\alpha}_k p_k^T A p_k + \dots + \tilde{\alpha}_{n-1} p_k^T A p_{n-1}$$

$$\tilde{\alpha}_k = \frac{p_k^T A(x^* - x_0)}{p_k^T A p_k}$$

- Metoda splňující předpoklady věty generuje následující posloupnost:

$$x_k = x_{k-1} + \alpha_{k-1}p_{k-1} = x_{k-2} + \alpha_{k-2}p_{k-2} + \alpha_{k-1}p_{k-1} = \dots = x_0 + \alpha_0p_0 + \dots + \alpha_{k-1}p_{k-1}$$

$$x_k - x_0 = \alpha_0p_0 + \dots + \alpha_{k-1}p_{k-1} / p_k^T A \text{ zleva}$$

$$p_k^T A(x_k - x_0) = \alpha_0 p_k^T A p_0 + \dots + \alpha_{k-1} p_k^T A p_{k-1} = 0 \rightarrow p_k^T A x_k = p_k^T A x_0$$

$$\Rightarrow p_k^T A(x^* - x_0) = p_k^T A(x^* - x_k) = p_k^T (b - Ax_k) = -p_k^T g_k$$

- Pro koeficienty α_k platí:

$$\Rightarrow \alpha_k = -\frac{p_k^T g_k}{p_k^T A p_k} = \frac{p_k^T A(x^* - x_0)}{p_k^T A p_k} = \tilde{\alpha}_k$$

- Metoda spočítá rozklad:

$$x_n - x_0 = \sum_{i=0}^{n-1} \alpha_i p_i = \sum_{i=0}^{n-1} \tilde{\alpha}_i p_i = x^* - x_0 \rightarrow x_n = x^*$$

Příklady 5.m

1. Úloha pro diagonální matici A :

$$A = \begin{bmatrix} 2 & 0 \\ 0 & 4 \end{bmatrix}, \quad b = \begin{bmatrix} 0 \\ 0 \end{bmatrix}.$$

$$f(x) = \frac{1}{2}[x, y] \begin{bmatrix} 2 & 0 \\ 0 & 4 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = x^2 + 2y^2$$

Minimalizujeme ve směru souřadných os, tj. $d = e$, najdeme odpovídající složku minima a po n -krocích získáme přesné řešení.

2. Úloha pro symetrickou pozitivně definitní matici A :

$$A = \begin{bmatrix} 2 & 1 \\ 1 & 4 \end{bmatrix}, \quad b = \begin{bmatrix} 0 \\ 0 \end{bmatrix}.$$

$$f(x) = \frac{1}{2}[x, y] \begin{bmatrix} 2 & 1 \\ 1 & 4 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = x^2 + xy + 2y^2$$

Minimalizace ve směru os nebude fungovat.

Myšlenka: Převést úlohu se symetrickou pozitivně definitní maticí A na diagonální matici.

$$\hat{A} = S^T A S, \quad S = [p_0 | p_1 | \dots | p_{n-1}]$$

S je množina A -ortogonálních vektorů \rightarrow lineárně nezávislé vektory \rightarrow báze, regulární matice $\rightarrow \hat{A}$ bude diagonální matice.

Označíme $S\hat{x} = x$, tj. \hat{x} souřadnice vektoru x v nové bázi.

Dále označíme $\hat{b} = S^T b$.

$$\begin{aligned} f(x) &= \frac{1}{2} x^T A x - b^T x \\ \Rightarrow f(S\hat{x}) &= \frac{1}{2} (S\hat{x})^T A (S\hat{x}) - b^T (S\hat{x}) = \frac{1}{2} \hat{x}^T S^T A S \hat{x} - (S^T b)^T \hat{x} \\ \hat{f}(\hat{x}) &= \frac{1}{2} \hat{x}^T \hat{A} \hat{x} - \hat{b}^T \hat{x} \end{aligned}$$

Tj. mohu hledat minimum n po sobě jdoucích minimalizací ve směrech e_i , které odpovídají minimalizaci ve směrech p_i v původní úloze, $p_i = S e_i$.

Věta: Necht' p_0, \dots, p_{n-1} je n nenulových A -ortogonálních vektorů. Pro libovolné $x_0 \in \mathbb{R}^n$, posloupnost $\{x_k\}$, definovanou

$$x_{k+1} = x_k + \alpha_k p_k$$

s volbou

$$\alpha_k = -\frac{g_k^T p_k}{p_k^T A p_k},$$

kde

$$g_k = A x_k - b$$

minimalizuje $f(x)$ přes lineární varietu $x_0 + \mathcal{S}_k$, kde

$$\mathcal{S}_k \equiv \text{span}\{p_0, \dots, p_{k-1}\},$$

tj.

$$f(x_k) = \min_{x \in x_0 + \mathcal{S}_k} f(x).$$

Důkaz:

Minimum $f(x)$ a $\|x^* - x\|_A^2$ je ve stejném bodě, tj. x_k minimalizuje $f(x)$ přes lineární varietu $x_0 + \mathcal{S}_k \Leftrightarrow x_k$ minimalizuje $\|x^* - x\|_A^2$ přes lineární varietu $x_0 + \mathcal{S}_k$.

$\|x^* - x_k\|_A$ je minimální $\Leftrightarrow x^* - x_k \perp_A \mathcal{S}_k \Leftrightarrow A(x^* - x_k) \perp \mathcal{S}_k \Leftrightarrow g_k \perp \mathcal{S}_k \rightarrow$ stačí dokázat, že příslušné gradienty jsou kolmé k \mathcal{S}_k (indukcí).

1. $k = 1$:

$$g_1 = A x_1 - b$$

$$x_1 = x_0 + \alpha_0 p_0$$

$$\mathcal{S}_1 = \text{span}\{p_0\}$$

$$\begin{aligned}
g_1^T p_0 &= (A(x_0 + \alpha_0 p_0) - b)^T p_0 = (Ax_0 + \alpha_0 A p_0 - b)^T p_0 = x_0^T A^T p_0 + \alpha_0 p_0^T A p_0 - b^T p_0 = \\
&= (Ax_0 - b)^T p_0 - \frac{g_0^T p_0}{p_0^T A p_0} p_0^T A p_0 = 0 \\
&\Rightarrow g_1 \perp S_1
\end{aligned}$$

2. Předpokládáme, že platí $g_k \perp S_k$ a dokazujeme platnost $g_{k+1} \perp S_{k+1}$.

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

$$S_k = \text{span}\{p_0, p_1, \dots, p_{k-1}\}, \quad S_{k+1} = \text{span}\{p_0, p_1, \dots, p_k\}$$

$$g_{k+1} = g_k + \alpha_k A p_k / p_i^T \quad i < k \quad \rightarrow \quad g_{k+1} \perp S_k ?$$

$$p_i^T g_{k+1} = p_i^T g_k + \alpha_k p_i^T A p_k = 0 \rightarrow \quad g_{k+1} \perp S_k !$$

$$g_{k+1} = g_k + \alpha_k A p_k / p_k^T \quad \rightarrow \quad g_{k+1} \perp S_{k+1} ?$$

$$p_k^T g_{k+1} = p_k^T g_k + \alpha_k p_k^T A p_k = p_k^T g_k - \frac{g_k^T p_k}{p_k^T A p_k} p_k^T A p_k = 0 \rightarrow \quad g_{k+1} \perp S_{k+1} !$$

Metoda sdružených gradientů:

- Kontrétní volba směrových vektorů:

- krok k :

- p_0, \dots, p_k jsou A -ortogonální,
- x_0, \dots, x_k ,
- gradienty (rezidua) g_0, \dots, g_k ,

- krok $k + 1$:

$$- x_{k+1} = x_k + \alpha_k p_k, \quad \alpha_k = -\frac{g_k^T p_k}{p_k^T A p_k},$$

$$- g_{k+1} = g_k + \alpha_k A p_k,$$

- jak sestrojít p_{k+1} ? Použijeme $-g_{k+1}$, tj. směr největšího spádu, a jeho A -ortogonální projekci na S_k , tj.

$$p_{k+1} = -g_{k+1} + \sum_{j=0}^k c_j p_j,$$

kde c_j určíme tak, aby vektor p_{k+1} byl A -ortogonální ke všem předchozím, tj.

$$c_j = \frac{g_{k+1}^T A p_j}{p_j^T A p_j}, \quad j = 0, \dots, k.$$

Gramm-Schmidtův ortogonalizační proces:

g_0, \dots, g_n jsou lineárně nezávislé
hledám p_0, \dots, p_n tak, aby byly A-ortogonální

$$\begin{aligned}p_0 &= -g_0 \\p_{k+1} &= -g_{k+1} + c_0 p_0 + \dots + c_k p_k \quad /p_0^T A \quad /p_1^T A \quad \dots \\p_0^T A p_{k+1} &= -p_0^T A g_{k+1} + c_0 p_0^T A p_0 + \dots + c_k p_0^T A p_k \\c_0 &= \frac{p_0^T A g_{k+1}}{p_0^T A p_0}, \quad c_1 = \frac{p_1^T A g_{k+1}}{p_1^T A p_1}, \quad \dots \quad c_k = \frac{p_k^T A g_{k+1}}{p_k^T A p_k}\end{aligned}$$

Algoritmus (základní):

- Dáno A, b, x_0 ,
- $g_0 = Ax_0 - b, p_0 = -g_0$,
- Pro $k = 0, \dots, n$:

$$\begin{aligned}\alpha_k &= -\frac{g_k^T p_k}{p_k^T A p_k} = \frac{g_k^T g_k}{p_k^T A p_k}, \\x_{k+1} &= x_k + \alpha_k p_k, \\g_{k+1} &= g_k + \alpha_k A p_k, \\\beta_k &= \frac{g_{k+1}^T A p_k}{p_k^T A p_k} = \frac{g_{k+1}^T g_{k+1}}{g_k^T g_k}, \\p_{k+1} &= -g_{k+1} + \beta_k p_k.\end{aligned}$$

Poznámky:

- Probíhá minimalizace v jednotlivých směrech a zároveň A-ortogonalizace dalšího směru vůči všem předchozím.
- Pokud nejsme v řešení, platí $g_{k+1} \neq 0$, dále platí $g_{k+1} \perp S_{k+1}$ a tedy vektory $g_{k+1}, p_0, p_1, \dots, p_k$ jsou lineárně nezávislé $\Rightarrow p_{k+1} \neq 0 \Rightarrow$ lze pokračovat v algoritmu.
- Díky volbě p_k a g_k platí, že g_k je lineární kombinací p_0, \dots, p_k a tedy $g_k \in S_{k+1}$. Protože $g_{k+1} \perp S_{k+1}$ potom je g_{k+1} kolmý na všechny g_0, \dots, g_k , tj. gradienty jsou vzájemně ortogonální.
- $g_{j+1} = g_j + \alpha_j A p_j, g_{j+1} \in S_{j+2}, g_j \in S_{j+1} \subseteq S_{j+2} \Rightarrow A p_j \in S_{j+2} \Rightarrow$ platí, že $c_j = \frac{g_{k+1}^T A p_j}{p_j^T A p_j} = 0$ pro $j < k$ tj. $c_k = \beta_k = \frac{g_{k+1}^T A p_k}{p_k^T A p_k} \neq 0$.
- $g_k^T p_k = g_k^T (-g_k + \beta_{k-1} p_{k-1}) = -\|g_k\|^2 < 0 \rightarrow p_k$ je spádový směr.

-
-


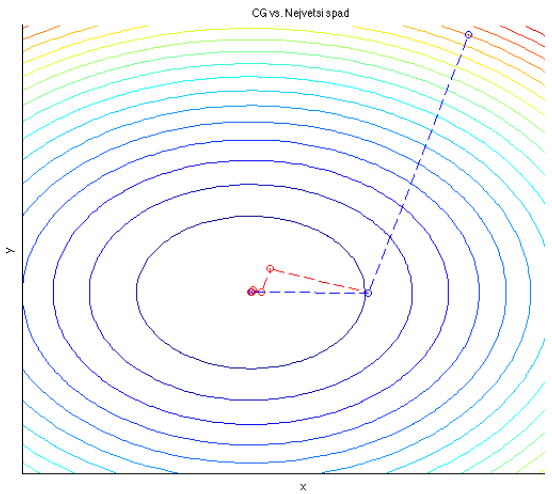
$$\alpha_k = -\frac{g_k^T p_k}{p_k^T A p_k} = -\frac{g_k^T (-g_k + \beta_{k-1} p_{k-1})}{p_k^T A p_k} = \frac{g_k^T g_k}{p_k^T A p_k}, \quad g_k \perp S_k$$

$$\beta_k = \frac{g_{k+1}^T A p_k}{p_k^T A p_k} = \frac{g_{k+1}^T A p_k}{p_k^T A p_k} \frac{g_k^T g_k}{g_k^T g_k} = \frac{g_k^T g_k}{p_k^T A p_k} \frac{g_{k+1}^T A p_k}{g_k^T g_k} = \frac{\alpha_k}{\alpha_k} \frac{g_{k+1}^T (g_{k+1} - g_k)}{g_k^T g_k} = \frac{g_{k+1}^T g_{k+1}}{g_k^T g_k}$$

$$g_{k+1} = g_k + \alpha_k A p_k \rightarrow A p_k = \frac{g_{k+1} - g_k}{\alpha_k}$$

$$g_{k+1}^T g_k = 0$$

Priklady5_CG.m



Konvergence:

- Konvergence pro kvadratickou funkci $f(x)$ v n krocích (v exaktní aritmetice).

$$p_0 = -g_0,$$

$$p_1 = -g_1 + c_0 p_0 = -g_1 - c_0 g_0,$$

$$p_2 = -g_2 + c_1 p_1 = -g_2 - c_1 (g_1 + c_0 g_0),$$

...

$$p_{k-1} = -g_{k-1} + c_{k-1} p_{k-1} = -g_{k-1} - c_{k-1} (c_{k-1} g_{k-2} + C_{k-3} g_{k-3} + \dots + C_0 g_0),$$

$$p_k = -g_k + c_k p_k = g_k + C^{k-1} g_{k-1} + C^{k-2} g_{k-2} + C^{k-3} g_{k-3} + \dots + C^0 g_0.$$

$g_0,$

$$g_1 = g_0 + \alpha_0 A p_0 = g_0 - \alpha_0 A g_0,$$

$$\begin{aligned} g_2 &= g_1 + \alpha_1 A p_1 = g_0 - \alpha_0 A g_0 - \alpha_1 A (g_1 - c_1 g_0) = g_0 - \alpha_0 A g_0 - \alpha_1 A ((g_0 - \alpha_0 A g_0) - c_1 g_0) = \\ &= a_0 g_0 + a_1 A g_0 + a_2 A^2 g_0, \end{aligned}$$

...

$$\begin{aligned} g_{k-1} &= -g_{k-1} + \alpha_{k-1} A p_{k-1} = -g_{k-1} - c_{k-1} (c_{k-1} g_{k-2} + C_{k-3} g_{k-3} + \dots + C_0 g_0) = \\ &= b_0 g_0 + b_1 A g_0 + \dots + b_{k-2} A^{k-2} g_0, \end{aligned}$$

$$g_k = -g_k + \alpha_k A p_k = d_0 g_0 + d_1 A g_0 + \dots + d_{k-1} A^{k-1} g_0 + d_k A^k g_0$$

•

$$\begin{aligned} x_{k+1} &= x_k + \alpha_k p_k = x_{k-1} + \alpha_{k-1} p_{k-1} + \alpha_k p_k = \dots = x_0 + \alpha_0 p_0 + \dots + \alpha_{k-1} p_{k-1} + \alpha_k p_k \\ &= x_0 + f_0 g_0 + f_1 g_1 + \dots + f_{k-1} g_{k-1} + f_k g_k \\ &= x_0 + \gamma_0 g_0 + \gamma_1 A g_0 + \dots + \gamma_{k-1} A^{k-1} g_0 + \gamma_k A^k g_0 = x_0 + q(A) g_0. \end{aligned}$$

• $q(A)$ je polynom stupně nejvýše k .

$$\begin{aligned} g_0 &= A x_0 - b = A x_0 - A x^* = A(x_0 - x^*) = A e_0, \\ e_{k+1} &\equiv (x^* - x_{k+1}) = (x^* - x_0) - (x_{k+1} - x_0) = e_0 - q(A) g_0 = e_0 - A q(A) e_0 = \\ &= p(A) e_0. \end{aligned}$$

• $p(A) = 1 - A q(A)$ je polynom stupně nejvýše $k + 1$.

• Polynomy třídy π_k : $p(z) = 1 - z q(z)$.

• Polynom $p(A)$ generovaný metodou sdruženým směřů minimalizuje A -normu chyby:

$$\|e_{k+1}\|_A = \min_{p \in \pi_k} \|p(A) e_0\|_A \leq \min_{p \in \pi_k} p(A) \|e_0\|_A.$$

$$\frac{\|e_{k+1}\|_A}{\|e_0\|_A} \leq \min_{p \in \pi_k} \|p(A)\|.$$

• Spektrální rozklad matice A : $\Lambda = \text{diag}(\lambda, \dots, \lambda_n)$ je matice z vlastních čísel, $V = [v_1 | v_2 | \dots | v_n]$ matice vlastních vektorů (je ortogonální: $V^T V = I$).

$$\begin{aligned} A &= V^T \Lambda V, \\ A^2 &= (V^T \Lambda V)(V^T \Lambda V) = V^T \Lambda^2 V, \end{aligned}$$

...

$$\begin{aligned} p(A) &= 1 - A q(A) = 1 - \gamma_0 A + \gamma_1 A^2 + \dots + \gamma_{k-1} A^{k-1} + \gamma_k A^k = \\ &= V^T V - \gamma_0 V^T \Lambda V - \gamma_1 V^T \Lambda^2 V + \dots + \gamma_{k-1} V^T \Lambda^{k-1} V + \gamma_k V^T \Lambda^k V \\ &= V^T (1 - \gamma_0 \Lambda - \gamma_1 \Lambda^2 + \dots + \gamma_{k-1} \Lambda^{k-1} + \gamma_k \Lambda^k) V = V^T p(\Lambda) V. \end{aligned}$$

$$\|p(A)\| = \|V^T p(\Lambda) V\| \leq \|V^T\| \|p(\Lambda)\| \|V\| = \|p(\Lambda)\|,$$

$$\min_{p \in \pi_k} \|p(A)\| = \min_{p \in \pi_k} \|p(\Lambda)\| = \min_{p \in \pi_k} \max_{i=1, \dots, n} |p(\lambda_i)| \leq \min_{p \in \pi_k} \max_{\lambda \in \langle \lambda_1, \lambda_n \rangle} |p(\lambda)|.$$

- Min-max úloha na diskretní množině bodů - spektra matice A , převedeme na spojitou úlohu
- Řešení pomocí vhodných Čebyševových polynomů (posunuté a normované).
-

$$\frac{\|e_{k+1}\|_A}{\|e_0\|_A} \leq 2 \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k,$$

kde $\kappa(A) = \|A\| \|A^{-1}\| = \frac{\lambda_n}{\lambda_1}$ je číslo podmíněnosti.

Obecná úloha:

- Pro nekvadratickou funkci $f(x)$: $g_k \leftrightarrow \nabla f(x)$, $A \leftrightarrow H(x_k)$ a využijeme stejné vztahy jako u kvadratické funkce.
- Numerický výpočet $\nabla f(x_k)$, obecně nekonverguje v n krocích.
- Výpočet $H(x_k)$ problematický v každém kroku.
- Problematické jsou koeficienty

$$\alpha_k = \frac{g_k^T p_k}{p_k^T H(x_k) p_k}, \quad \beta_k = \frac{g_{k+1}^T H(x_k) p_k}{p_k^T H(x_k) p_k}.$$

- α_k pomocí Line search

- **Fletcher-Reevesova varianta:** $\beta_k = \frac{g_{k+1}^T g_{k+1}}{g_k^T g_k}$.
- **Polak-Ribiereova varianta:** $\beta_k = \frac{(g_{k+1} - g_k)^T g_{k+1}}{g_k^T g_k}$, $\beta_k^+ = \max\{\beta_k, 0\}$.
- **Hestenes-Stiefelova varianta:** $\beta_k = \frac{(g_{k+1} - g_k)^T g_{k+1}}{(g_{k+1} - g_k)^T p_k}$.
- Doporučen restart směrů: 1 krok ve směru největšího spádu.
- Směry nemusí být spádové.

- Musí být vazba na kvadratické úlohy: pro kvadratickou funkci $f(x)$ a exaktní Line search se všechny obecné metody musí redukovat na metodu sdružených směrů.
- Příklad5_CGnelin.m

- Prikłady5_CGnelin2.m

Konvergence:

Věta: Uvažujme CG algoritmus (Fletcher-Reevesova varianta) s volbou kroku α , která splňuje silné wolfeho podmínky s $0 < c_1 < c_2 < \frac{1}{2}$. Necht' $f \in \mathbb{C}(\Omega)$ je otevřená množina obsahující vrtevníkovou oblast $\Gamma_{f(x_0)} \equiv \{x : f(x) \leq f(x_0)\}$ a $\nabla f(x)$ je Lipschitzovsky spojitý na Ω . Potom platí

$$\liminf_{k \rightarrow \infty} \|\nabla f(x_k)\| = 0.$$

- Podobná věta není pro Polak-Ribierovu variantu sdružených směrů.
- V praxi je PR varianta lepší než FR.
- PR varianta se může cyklit a řešení nenalézt i za použití ideálního Line-search.