



## Kapitola 5. SLAR - gradientní metody

### Metody na řešení SLAR

- přímé (GEM, metoda LU-rozkladu) ✓
- iterační (Jacobiova m., Gauss-Seidelova m., metoda SOR) ✓
- gradientní

### Motivace

Uvažujme kvadratickou funkci reálné proměnné  $x$ :

$$f(x) = \frac{1}{2}ax^2 - bx + c, \quad a > 0.$$

Nutná a postačující podmínka minima funkce ( $f'(x) = 0$ ) má tvar

$$ax = b.$$

To znamená, že místo řešení lineární rovnice můžeme řešit úlohu najít minimum konvexní kvadratické funkce  $f(x)$  (obě úlohy mají stejná řešení).

Uvědomme si, že v případě funkce více proměnných je třeba splnit další podmínky kladené na matici soustavy  $\mathbf{A}$ , abychom zaručili konvexnost příslušné kvadratické funkce.

Uvažujeme soustavu (kde matice  $\mathbf{A}$  je symetrická, pozitivně definitní)

$$\mathbf{Ax} = \mathbf{b}$$

Dále uvažujeme kvadratickou formu, tzv. **energetický funkcionál**

$$F(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{Ax} - \mathbf{b}^T \mathbf{x}.$$

Platí

$$\text{grad } F(\mathbf{x}) = \mathbf{Ax} - \mathbf{b}.$$

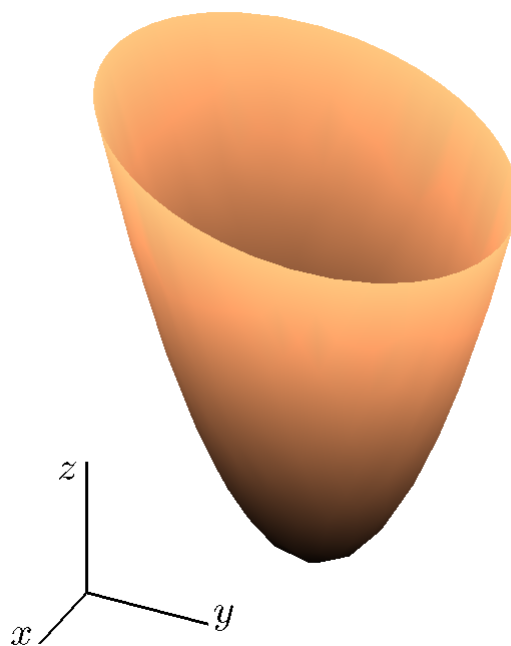
Funkce  $F(\mathbf{x})$  je konvexní a kvadratická  $\Rightarrow F(\mathbf{x})$  má globální minimum a pro bod minima  $\tilde{\mathbf{x}}$  platí

$$\text{grad } F(\tilde{\mathbf{x}}) = \mathbf{A}\tilde{\mathbf{x}} - \mathbf{b} = \mathbf{0}.$$

Bod minima  $\tilde{\mathbf{x}}$  je tedy řešením soustavy  $\mathbf{Ax} = \mathbf{b}$ .

Poznámka: Úlohy najít bod minima funkce  $F$  a řešit soustavu  $\mathbf{Ax} = \mathbf{b}$  jsou ekvivalentní.


Poznámka: V případě soustavy 2 rovnic si lze udělat geometrickou představu, neboť pro  $\mathbf{x} \in \mathbb{R}^2$  je grafem funkce  $F(\mathbf{x})$  eliptický paraboloid, jehož vrstevnice jsou elipsy. Minima  $F(\mathbf{x})$  se nabývá ve vrcholu paraboloidu.



### Příklad 1

Uvažujme velmi jednoduchou soustavu  $\mathbf{Ax} = \mathbf{b}$ , kde

$$\mathbf{A} = \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 25 \\ 8 \end{bmatrix}, \quad \mathbf{x}^* = \begin{bmatrix} 1 \\ 0,5 \end{bmatrix}.$$



Odpovídající kvadratická funkce je

$$F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{Ax} - \mathbf{b}^T \mathbf{x} = \frac{1}{2} \begin{bmatrix} x & y \end{bmatrix} \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} - \begin{bmatrix} 25 & 8 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \frac{1}{2} (25x^2 + 16y^2) - 25x - 8y.$$

Vrstevnice (hladiny):

$$F(\mathbf{x}) = c$$

$$\frac{1}{2} (25x^2 + 16y^2) - 25x - 8y = c$$


$$25x^2 + 16y^2 - 50x - 16y = 2c$$

$$25(x-1)^2 - 25 + 16\left(y - \frac{1}{2}\right)^2 - 4 = 2c$$

$$25(x-1)^2 + 16\left(y - \frac{1}{2}\right)^2 = 2c + 29$$


např. pro  $c = \frac{371}{2}$ :

$$\frac{(x-1)^2}{4^2} + \frac{(y-\frac{1}{2})^2}{5^2} = \frac{2c+29}{400} = 1$$



Řezy svislou rovinou  $y = px + q$

$$\begin{aligned} F(x) &= \frac{1}{2}(25x^2 + 16y^2) - 25x - 8y = \frac{1}{2}(25x^2 + 16(px + q)^2) - 25x - 8(px + q) = \\ &= \frac{1}{2}(25x^2 + 16(p^2x^2 + 2pqx + q^2)) - 25x - 8(px + q) = \\ &= \underbrace{\left(\frac{25}{2} + \frac{16}{2}p^2\right)}_{>0} x^2 + (16pq - 25 - 8p)x + 8q^2 - 8q \end{aligned}$$




### Princip


Stejně jako u každé iterační metody nejprve zvolíme počáteční aproximaci řešení  $x^{(0)}$ .

Princip gradientních metod spočívá v tom, že zvolíme směr a v tomto směru se budeme chtít co nejvíce přiblížit k přesnému řešení. Gradientní metoda je tedy určena volbou směrů, ve kterých minimalizujeme funkci  $F$ .

Během jedné iterace se pohybujeme po povrchu grafu funkce  $F(x)$  tak, abychom se dostali na nižší vrstevnici.



V případě soustavy dvou rovnic získáme promítnutím grafu funkce  $F(\mathbf{x})$  do roviny proměnných  $x_1, x_2$  systém soustředných elips - hladin (vrstevnic).



### Metoda největšího spádu

Metodu největšího spádu získáme, pokud budeme za směrové vektory volit směry největšího spádu, tj. vektory


$$\mathbf{d}^{(k)} = -\text{grad } F(\mathbf{x}^{(k)}) = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}.$$

Iterační formuli volíme ve tvaru

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t^{(k)} \cdot \mathbf{d}^{(k)},$$

v každém kroku metody určíme směr největšího spádu  $\mathbf{d}^{(k)}$  a provedeme jednorozměrnou minimalizaci v tomto směru, tj.

$$\min_{t>0} F(\mathbf{x}^{(k)} + t \mathbf{d}^{(k)}).$$



Minimalizovanou funkci proměnné  $t$  označíme  $\Psi(t)$ .

Potom platí:

$$\begin{aligned} \underbrace{F(\mathbf{x}^{(k)} + t \mathbf{d}^{(k)})}_{\Psi(t)} &= \frac{1}{2} (\mathbf{x}^{(k)} + t \mathbf{d}^{(k)})^T \mathbf{A} (\mathbf{x}^{(k)} + t \mathbf{d}^{(k)}) - \mathbf{b}^T (\mathbf{x}^{(k)} + t \mathbf{d}^{(k)}) = \\ &= \frac{1}{2} \mathbf{x}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} + \frac{1}{2} t \mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \frac{1}{2} t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} + \frac{1}{2} t^2 \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{x}^{(k)} - t \mathbf{b}^T \mathbf{d}^{(k)} \end{aligned}$$

$$\frac{d\Psi(t)}{dt} = \frac{1}{2} \mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \frac{1}{2} \mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} + t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{d}^{(k)}$$

Poznámka: První 2 členy, tj.  $\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}$  a  $\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)}$  jsou skaláry a jsou si pro symetrickou matici  $\mathbf{A}$  rovny.

$$\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} = (\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)})^T = (\mathbf{A} \mathbf{x}^{(k)})^T \mathbf{d}^{(k)} = \mathbf{x}^{(k)T} \mathbf{A}^T \mathbf{d}^{(k)}$$



$$\frac{d\Psi(t)}{dt} = t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \underbrace{\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{d}^{(k)}}_{\underbrace{(\mathbf{x}^{(k)T} \mathbf{A} - \mathbf{b}^T) \mathbf{d}^{(k)}}_{-\mathbf{d}^{(k)T}}}$$

$$\frac{d\Psi(t)}{dt} = t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \underbrace{\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{b}^T \mathbf{d}^{(k)}}_{\underbrace{(\mathbf{x}^{(k)T} \mathbf{A} - \mathbf{b}^T) \mathbf{d}^{(k)}}_{-\mathbf{d}^{(k)T}}}$$

$$\frac{d\Psi(t)}{dt} = t \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} - \mathbf{d}^{(k)T} \mathbf{d}^{(k)} = 0$$

$$t^{(k)} = \frac{\mathbf{d}^{(k)T} \mathbf{d}^{(k)}}{\mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}}$$

Poznámka:

Pokud by matice  $\mathbf{A}$  nesplňovala podmínku symetrie, jaký výsledek by nám dala metoda největšího spádu?

$$\text{grad } F(\mathbf{x}) = \mathbf{0}$$

$$\text{grad } F(\mathbf{x}) = \text{grad} \left( \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{b}^T \mathbf{x} \right) = \frac{1}{2} (\mathbf{x}^T \mathbf{A})^T + \frac{1}{2} \mathbf{A} \mathbf{x} - \mathbf{b} = \frac{1}{2} \mathbf{A}^T \mathbf{x} + \frac{1}{2} \mathbf{A} \mathbf{x} - \mathbf{b} = \mathbf{0}$$

$$\Rightarrow \frac{1}{2} (\mathbf{A}^T + \mathbf{A}) \mathbf{x} = \mathbf{b}$$

Algoritmus metody největšího spádu

1. volba  $\mathbf{x}^{(0)}, \varepsilon$
2. výpočet směru spádu  $\mathbf{d}^{(k)} = \mathbf{b} - \mathbf{A} \mathbf{x}^{(k)}$
3. výpočet koeficientu  $t^{(k)} = \frac{\mathbf{d}^{(k)T} \mathbf{d}^{(k)}}{\mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}}$
4. výpočet nové iterace  $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t^{(k)} \mathbf{d}^{(k)}$
5.  $k = k + 1$  a zpět na 2) pokud  $\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\| > \varepsilon$

Poznámka: Abychom ušetřili operace násobení matice a vektoru, určíme  $\mathbf{d}^{(k+1)}$  takto:

$$\mathbf{d}^{(k+1)} = \mathbf{b} - \mathbf{A} \mathbf{x}^{(k+1)} = \mathbf{b} - \mathbf{A} (\mathbf{x}^{(k)} + t^{(k)} \mathbf{d}^{(k)}) = \mathbf{d}^{(k)} - t^{(k)} \underbrace{\mathbf{A} \mathbf{d}^{(k)}}_{(*)}$$

(\*) toto se počítalo v kroku 3 v předchozí

iteraci



**Věta:** Metoda největšího spádu konverguje (pro symetrickou, pozitivně definitní matici  $\mathbf{A}$ ) pro libovolnou volbu počáteční aproximace  $\mathbf{x}^{(0)}$  k přesnému řešení soustavy  $\mathbf{Ax} = \mathbf{b}$ .

Důkaz:

Konvergenci dokážeme v normě  $\|\cdot\|_{\mathbf{A}} = \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$  (tzv. energetická norma).

$\|\cdot\|_{\mathbf{A}}$  je s euklidovskou normou  $\|\cdot\|_2$  ekvivalentní, tj. z toho již plyne i konvergence v  $\|\cdot\|_2 = \sqrt{\mathbf{x}^T \mathbf{x}}$

(Definice:  $X$  ... lineární prostor,  $\|\cdot\|_1$  a  $\|\cdot\|_2$  ... normy na  $X$ ;

$\|\cdot\|_1$  a  $\|\cdot\|_2$  jsou ekvivalentní, existují-li čísla  $c, C > 0$ :  $\forall \mathbf{x} \in X \quad c\|\mathbf{x}\|_1 \leq \|\mathbf{x}\|_2 \leq C\|\mathbf{x}\|_1$ )

tj. má platit

$$c^2 \mathbf{x}^T \mathbf{x} \leq \mathbf{x}^T \mathbf{A} \mathbf{x} \leq C^2 \mathbf{x}^T \mathbf{x}$$

$$\mathbf{x}^T (c^2 \mathbf{I}) \mathbf{x} \leq \mathbf{x}^T \mathbf{A} \mathbf{x} \leq \mathbf{x}^T (C^2 \mathbf{I}) \mathbf{x}$$

$$\text{platí pro } c = |\lambda_{\min}|, C = |\lambda_{\max}|$$

$\mathbf{x}^*$  ... přesné řešení  $\mathbf{Ax} = \mathbf{b}$

$\mathbf{e}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}^*$  ... chyba  $k$ -té iterace

Odvoďme nejprve vztah pro energetickou normu chyby  $k$ -té iterace.

$$F(\mathbf{x}^{(k)}) - F(\mathbf{x}^*) = F(\mathbf{x}^* + \mathbf{e}^{(k)}) - F(\mathbf{x}^*) = \dots \quad (*)$$

Obecně pro 2 body  $\mathbf{x}, \mathbf{x} + t\mathbf{d}$  platí:

$$\begin{aligned} F(\mathbf{x} + t\mathbf{d}) - F(\mathbf{x}) &= \frac{1}{2}(\mathbf{x} + t\mathbf{d})^T \mathbf{A}(\mathbf{x} + t\mathbf{d}) - \mathbf{b}^T(\mathbf{x} + t\mathbf{d}) - \frac{1}{2}\mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} = \\ &= t\mathbf{x}^T \mathbf{A} \mathbf{d} + \frac{1}{2}t^2 \mathbf{d}^T \mathbf{A} \mathbf{d} - t\mathbf{b}^T \mathbf{d} = \\ &= \underline{t\mathbf{d}^T(\mathbf{A}\mathbf{x} - \mathbf{b})} + \frac{1}{2}t^2 \mathbf{d}^T \mathbf{A} \mathbf{d} \end{aligned}$$

Pro náš případ  $\mathbf{x} = \mathbf{x}^*, t = 1, \mathbf{d} = \mathbf{e}^{(k)}$

$$\dots = F(\mathbf{x}^* + \mathbf{e}^{(k)}) - F(\mathbf{x}^*) = \frac{1}{2}\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} = \|\mathbf{e}^{(k)}\|_{\mathbf{A}}^2 \quad (**)$$

$$(*) + (**) \Rightarrow \boxed{F(\mathbf{x}^{(k)}) - F(\mathbf{x}^*) = \frac{1}{2}\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} \quad (***)$$

$$(***) \Rightarrow F(\mathbf{x}^{(k+1)}) - F(\mathbf{x}^*) = \frac{1}{2}\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} \quad (****)$$

Odečtením (\*\*\*\*) a (\*\*\*) dostaneme



$$F(\mathbf{x}^{(k+1)}) - F(\mathbf{x}^{(k)}) = \frac{1}{2} \mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} - \frac{1}{2} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} \quad (\clubsuit)$$

kde iterace  $\mathbf{x}^{(k+1)}$  je vypočtena metodou největšího spádu, tj.

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t^{(k)} \mathbf{r}^{(k)}.$$

Pro výraz na levé straně opět použijeme **zvýrazněný vztah** pro hodnoty  $\mathbf{x} = \mathbf{x}^{(k)}$ ,  $t = t^{(k)}$ ,  $\mathbf{d} = \mathbf{r}^{(k)}$

$$F(\mathbf{x}^{(k)} + t^{(k)} \mathbf{r}^{(k)}) - F(\mathbf{x}^{(k)}) = t^{(k)} \mathbf{r}^{(k)T} \left( \underbrace{\mathbf{A} \mathbf{x}^{(k)} - \mathbf{b}}_{-\mathbf{r}^{(k)}} \right) + \frac{1}{2} t^{(k)2} \mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)} =$$

$$\left( t^{(k)} \text{ jsme počítali podle vztahu } t^{(k)} = \frac{\mathbf{r}^{(k)T} \mathbf{r}^{(k)}}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} \right)$$

$$= -\frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} + \frac{1}{2} \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{(\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)})^2} \mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)} = -\frac{1}{2} \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} \quad (\spadesuit)$$

Porovnáním ( $\spadesuit$ ) a ( $\clubsuit$ ) dostaneme

$$-\frac{1}{2} \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)}} = \frac{1}{2} \mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} - \frac{1}{2} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} \quad (\heartsuit)$$

Nyní poslední rovnici

- vynásobíme 2
- poslední člen převedeme na druhou stranu
- a vydělíme jím rovnici

Dostaneme

$$\frac{\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)}}{\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} = 1 - \frac{(\mathbf{r}^{(k)T} \mathbf{r}^{(k)})^2}{\mathbf{r}^{(k)T} \mathbf{A} \mathbf{r}^{(k)} \underbrace{\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}}_{= \mathbf{r}^{(k)}}} \quad (\diamondsuit)$$

Platí  $\mathbf{A} \mathbf{e}^{(k)} = \mathbf{r}^{(k)}$ , protože  $\mathbf{A} \mathbf{x}^* - \mathbf{b} = \mathbf{0}$  a  $\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{A} \mathbf{x}^{(k)}$

$$\mathbf{r}^{(k)} = \mathbf{b} - \underbrace{\mathbf{A} \mathbf{x}^{(k)}}_{\mathbf{A}(\mathbf{x}^* - \mathbf{x}^{(k)})} = \mathbf{A}(\mathbf{x}^* - \mathbf{x}^{(k)}) = \mathbf{A} \mathbf{e}^{(k)}$$

Dále z  $\mathbf{A} \mathbf{e}^{(k)} = \mathbf{r}^{(k)}$  plyne  $\mathbf{e}^{(k)} = \mathbf{A}^{-1} \mathbf{r}^{(k)}$  a tedy odhad

$$\|\mathbf{e}^{(k)}\| \leq \|\mathbf{A}^{-1}\| \cdot \|\mathbf{r}^{(k)}\|$$

Pro ( $\diamondsuit$ ) dostáváme odhad:

$$\frac{\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)}}{\mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)}} \leq 1 - \frac{\|\mathbf{r}^{(k)}\|^4}{\|\mathbf{A}\| \cdot \|\mathbf{r}^{(k)}\|^2 \cdot \|\mathbf{A}^{-1}\| \cdot \|\mathbf{r}^{(k)}\|^2} = 1 - \frac{1}{\|\mathbf{A}\| \cdot \|\mathbf{A}^{-1}\|} = \mathbf{q} < 1$$

Tj.

$$\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} \leq \mathbf{q} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} \quad \forall k \quad (\blacksquare)$$

$$\mathbf{e}^{(k+1)T} \mathbf{A} \mathbf{e}^{(k+1)} \leq \mathbf{q} \mathbf{e}^{(k)T} \mathbf{A} \mathbf{e}^{(k)} \quad \forall k$$



Důkaz:

Jde o to odhadnout  $q$  v (■).

$$\|e^{(k+1)}\|_A^2 \leq q \|e^{(k)}\|_A^2 \quad \Rightarrow \quad \|e^{(k)}\|_A^2 \leq q^k \|e^{(0)}\|_A^2$$

$$q = 1 - \frac{1}{\underbrace{\|A\|}_{= \lambda_{max}} \cdot \underbrace{\|A^{-1}\|}_{= \frac{1}{\lambda_{min}}}} = 1 - \frac{1}{\kappa(A)} = \frac{\kappa(A) - 1}{\kappa(A)} \leq \sqrt{\frac{\kappa(A) - 1}{\kappa(A) + 1}}$$


Důkaz poslední nerovnosti:

$$\begin{aligned} \frac{(\kappa(A) - 1)^2}{\kappa^2(A)} &\leq \frac{\kappa(A) - 1}{\kappa(A) + 1} \quad / : (\kappa(A) - 1) \\ \frac{\kappa(A) - 1}{\kappa^2(A)} &\leq \frac{1}{\kappa(A) + 1} \quad / \cdot \kappa^2(A)(\kappa(A) + 1) \\ \kappa^2(A) - 1 &\leq \kappa^2(A) \quad \dots OK \end{aligned}$$


## Geometrický význam metody největšího spádu



Metoda největšho spadu



$k$	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	4.7425	1.0321
2	5.5081	4.1902
3	4.2240	4.5015
4	4.4549	5.4541
5	4.0676	5.5480



**Vlastnost reziduí**

Všimněme si faktu, že vždy po sobě jdoucí iterace směru spádu, tj.  $\mathbf{d}^{(k)}$  a  $\mathbf{d}^{(k+1)}$  jsou na sebe kolmé.

Cvičení: Ukažte, že platí  $\mathbf{d}^{(k)T} \mathbf{d}^{(k+1)} = 0$ .

$$\begin{aligned}
 \mathbf{d}^{(k)T} \mathbf{d}^{(k+1)} &= \mathbf{d}^{(k)T} (\mathbf{b} - \mathbf{A}\mathbf{x}^{(k+1)}) = \\
 &= \mathbf{d}^{(k)T} (\mathbf{b} - \mathbf{A}(\mathbf{x}^{(k)} + t^{(k)}\mathbf{d}^{(k)})) = \\
 &= \mathbf{d}^{(k)T} (\mathbf{b} - \mathbf{A}\mathbf{x}^{(k)} - t^{(k)}\mathbf{A}\mathbf{d}^{(k)}) = \\
 &= \mathbf{d}^{(k)T} (\mathbf{d}^{(k)} - t^{(k)}\mathbf{A}\mathbf{d}^{(k)}) = \\
 &= \mathbf{d}^{(k)T} \mathbf{d}^{(k)} - t^{(k)} \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} = \\
 &= \mathbf{d}^{(k)T} \mathbf{d}^{(k)} - \frac{\mathbf{d}^{(k)T} \mathbf{d}^{(k)}}{\mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}} \mathbf{d}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} = \\
 &= \mathbf{d}^{(k)T} \mathbf{d}^{(k)} - \mathbf{d}^{(k)T} \mathbf{d}^{(k)} = 0
 \end{aligned}$$

Poznámka:

V případě, že budou hladiny (elipsy) „velmi protáhlé“, bude obecně metoda největšího spádu konvergovat velmi pomalu, nastane tzv. **cik-cak efekt**.

Na druhou stranu, pokud budou hladiny (elipsy) „skoro kružnice“, bude metoda největšího spádu konvergovat velmi rychle.

Nevýhodu cik-cak efektu odstraní nová metoda, tzv. **metoda sdružených gradientů**, která využívá důmyslnější volby směrů minimalizace, a sice tak, aby se neopakovali, jak k tomu docházelo u metody největšího spádu.

**Příklad 1** - pokračování

Uvažovali jsme jednoduchou soustavu  $\mathbf{A}\mathbf{x} = \mathbf{b}$ , kde

$$\mathbf{A} = \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 25 \\ 8 \end{bmatrix}, \quad \mathbf{x}^* = \begin{bmatrix} 1 \\ 0,5 \end{bmatrix}.$$

Jedna z vrstevnic měla tvar

$$\frac{(x-1)^2}{4^2} + \frac{(y-\frac{1}{2})^2}{5^2} = 1$$

poměr poloos:

$$\sqrt{\lambda_2} = \sqrt{16} \rightarrow 4 : 5 \leftarrow \sqrt{25} = \sqrt{\lambda_1}$$

$$\sqrt{\lambda_2} : \sqrt{\lambda_1}$$


Poznámka:

- Pro případ  $\lambda_2 \gg \lambda_1$  získáme protáhlé elipsy
- Pro případ  $\lambda_2 \approx \lambda_1$  získáme skoro kružnice

## Příklad 2

Pomocí metody největšího spádu řešte soustavu  $\mathbf{Ax} = \mathbf{b}$ , kde

$$\mathbf{A} = \begin{bmatrix} 3 & 0 \\ 0 & 200 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} -8 \\ 2 \end{bmatrix}, \quad \text{počáteční iterace } \mathbf{x}^{(0)} = \begin{bmatrix} 27 \\ 0,6 \end{bmatrix}.$$



$k$	$x^{(k)}$	$y^{(k)}$
0	27.000000	0.600000
1	26.307758	-0.317804
2	25.139940	0.563008
3	24.491101	-0.297251
4	23.396504	0.528335
5	22.788346	-0.277987
$\vdots$	$\vdots$	$\vdots$
250	-2.657606	0.010180

vlastní čísla matice  $\mathbf{A}$ :

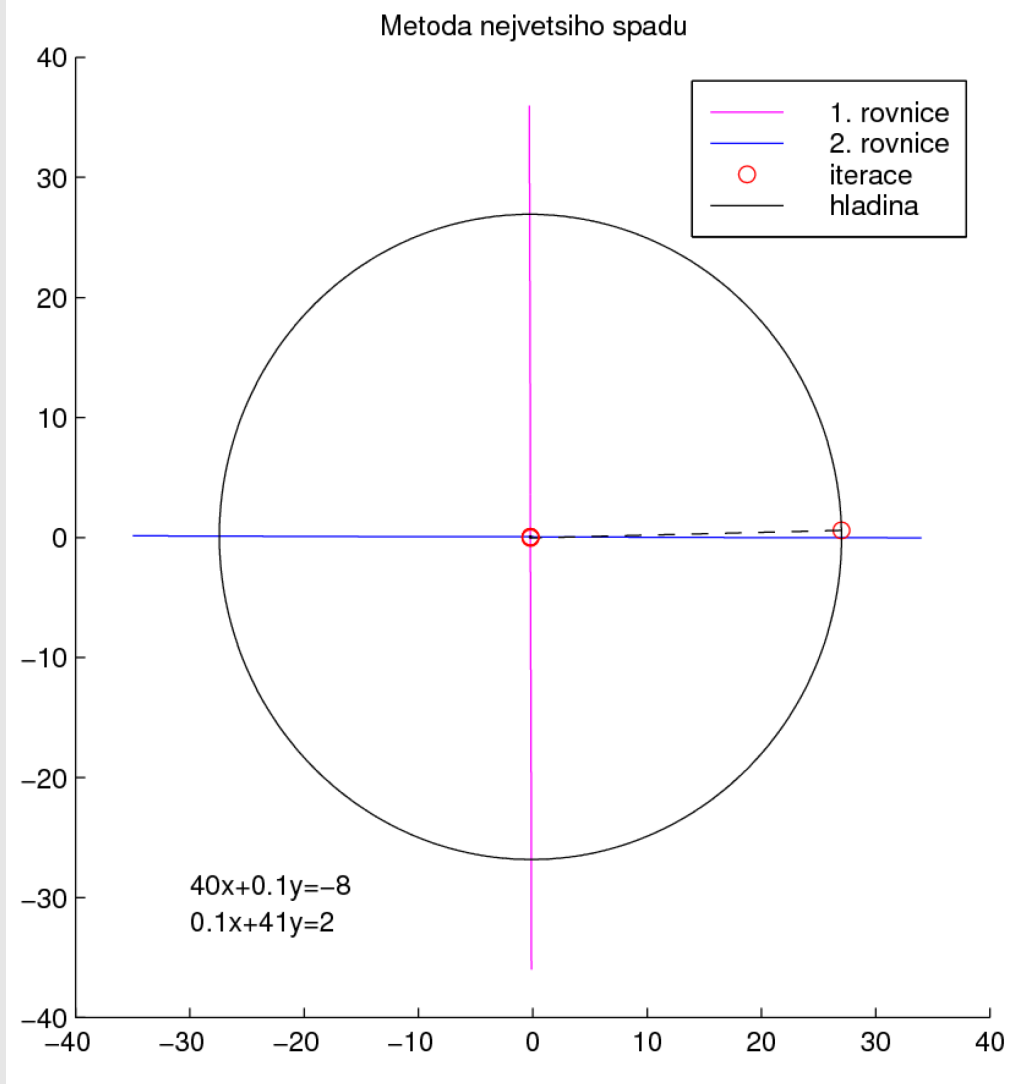
$$\lambda_1 = 3 \quad \text{a} \quad \lambda_2 = 200$$

přesné řešení soustavy je  $\mathbf{x}^* = \begin{bmatrix} -\frac{8}{3} \\ \frac{1}{100} \end{bmatrix}$

## Příklad 3

Pomocí metody největšího spádu řešte soustavu  $\mathbf{Ax} = \mathbf{b}$ , kde

$$\mathbf{A} = \begin{bmatrix} 40 & 0,1 \\ 0,1 & 41 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} -8 \\ 2 \end{bmatrix}, \quad \text{počáteční iterace } \mathbf{x}^{(0)} = \begin{bmatrix} 27 \\ 0,6 \end{bmatrix}.$$



$k$	$x^{(k)}$	$y^{(k)}$
0	27.000000	0.600000
1	-0.197972	-0.032418
2	-0.199872	0.049274
3	-0.200123	0.049268

vlastní čísla matice  $A$ :

$$\lambda_1 \doteq 39,99 \text{ a } \lambda_2 \doteq 41,01$$

přesné řešení soustavy  $x^*$  se s  $x^{(3)}$  shoduje na 6 desetinných míst

Poznámky k rychlosti konvergence:

$$\|x^{(k)} - x^*\|_A = \left( \frac{\kappa(A) - 1}{\kappa(A) + 1} \right)^k \|x^{(0)} - x^*\|_A$$

- Je-li  $\kappa(A) \gg 1$ , tj.  $\lambda_{max} \gg \lambda_{min}$ , pak metoda největšího spádu konverguje pomalu

$$\frac{\kappa(A) - 1}{\kappa(A) + 1} = \frac{\kappa(A) - 1 + 1 - 1}{\kappa(A) + 1} = 1 - \frac{2}{\underbrace{\kappa(A) + 1}_{\rightarrow \infty \text{ pro } \kappa(A) \rightarrow \infty}} \approx 1$$

- Je-li  $\kappa(A) \approx 1$ , tj.  $\lambda_{max} \approx \lambda_{min}$ , pak metoda největšího spádu konverguje rychle



$$\frac{\kappa(\mathbf{A}) - 1}{\kappa(\mathbf{A}) + 1} = 1 - \frac{2}{\underbrace{\kappa(\mathbf{A}) + 1}_{\approx 2}} \approx 0$$

- Pokud jsou vrstevnice sféry (v  $\mathbb{R}^2$  kružnice), potom metoda největšího spádu nalezne řešení (přesné) v jednom kroku.

### Poznámka:

Směr, ve kterém provádíme minimalizaci v rámci jednoho kroku metody, můžeme volit i jinak než směr největšího spádu.

Obecně označme používané směry  $\mathbf{s}^{(k)}$ .

Novou iteraci hledáme ve tvaru

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t \mathbf{s}^{(k)}$$

Koeficient  $t$  získáme z jednorozměrné minimalizace

$$\min_{t>0} \underbrace{F(\mathbf{x}^{(k)} + t \mathbf{s}^{(k)})}_{\Phi(t)}$$

$$\Phi(t) = \frac{1}{2}(\mathbf{x}^{(k)} + t \mathbf{s}^{(k)})^T \mathbf{A}(\mathbf{x}^{(k)} + t \mathbf{s}^{(k)}) - \mathbf{b}^T(\mathbf{x}^{(k)} + t \mathbf{s}^{(k)})$$

$$\begin{aligned} \frac{d\Phi(t)}{dt} &= t \mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(k)} + \underbrace{\mathbf{x}^{(k)T} \mathbf{A} \mathbf{s}^{(k)} - \mathbf{b}^T \mathbf{s}^{(k)}}_{\underbrace{(\mathbf{x}^{(k)T} \mathbf{A} - \mathbf{b}^T)}_{(\mathbf{A} \mathbf{x}^{(k)} - \mathbf{b})^T}} \mathbf{s}^{(k)} \\ &= -\mathbf{r}^{(k)} \text{ (reziduum)} \end{aligned}$$

$$t^{(k)} = \frac{\mathbf{r}^{(k)T} \mathbf{s}^{(k)}}{\mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(k)}}$$

Volíme-li za vektory  $\mathbf{s}^{(k)}$  postupně jednotkové vektory souřadných os, získáme Gauss-Seidelovu metodu !!!

Pokud na vektor  $\mathbf{x}$  aplikujeme 1 iteraci gradientní metody se směrovým vektorem  $\mathbf{e}_i = [0, \dots, 0, 1, 0, \dots, 0]^T$  (na  $i$ -té pozici 1, jinak 0), dostaneme:

$$\mathbf{x} := \mathbf{x} + \frac{\mathbf{r}^T \mathbf{e}_i}{\mathbf{e}_i^T \mathbf{A} \mathbf{e}_i} \mathbf{e}_i. \quad (\bullet)$$

Platí:  $\mathbf{e}_i^T \mathbf{A}$  ...  $i$ -tý řádek matice  $\mathbf{A}$

$\mathbf{e}_i^T \mathbf{A} \mathbf{e}_i$  ... diagonální prvek  $a_{ii}$  matice  $\mathbf{A}$

$\mathbf{r} = \mathbf{b} - \mathbf{A} \mathbf{x}$  ... reziduum

$\mathbf{r}^T \mathbf{e}_i = r_i$  ...  $i$ -tá složka vektoru  $\mathbf{r}$

$$r_i = b_i - \sum_{j=1}^n a_{ij} x_j$$

Vztah  $(\bullet)$  zvětší  $i$ -tou složku vektoru  $\mathbf{x}$  o hodnotu  $r_i$ , tj.



$$x_i := x_i + \frac{1}{a_{ii}} \underbrace{\left( b_i - \sum_{j=1}^n a_{ij} x_j \right)}_{= r_i},$$

$$x_i := \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j - \sum_{j=i+1}^n a_{ij} x_j \right).$$

Script v MATLABu

```
function [vysledky_gs,vysledky_gm]=gs_gm(A,b,x0,iteraci);

%*****
%           Porovnani Gauss-Seidelovy metody a
%           gradientni metody, kde za smery volime
%           jednotkove vektory souradnych os
%*****

n=size(A,1);

%*****
% Gauss-Seidelova metoda
%*****

x=x0;
vysledky_gs=x';
D=diag(diag(A)); L=tril(A)-D; U=triu(A)-D;
H=-(L+D)\U;
g=(L+D)\b;

for i=1:iteraci
    x=H*x+g;
    vysledky_gs=[vysledky_gs;x'];
end

%*****
% Gradientni metoda
%*****

x=x0;
vysledky_gm=x';

for i=1:iteraci
    for j=1:n
        s=zeros(n,1);
        s(j)=1;
        r=-A*x+b;
        t=(r'*s)/(s'*A*s);
        x=x+t*s;
    end;
    vysledky_gm=[vysledky_gm;x'];
end
```





## Úvaha

Při vhodné volbě směrových vektorů  $\mathbf{s}^{(k)}$  je možné dojít do přesného řešení za konečný počet kroků  $\leq n$ . Musí existovat  $n$  vektorů  $\mathbf{s}^{(k)}$  tak, že

$$\mathbf{x}^* - \mathbf{x}^{(0)} = \sum_{k=1}^n t^{(k)} \mathbf{s}^{(k)} \quad (*)$$

Jak volit směry  $\mathbf{s}^{(k)}$ ?

- Zkusíme takto: nechť  $\mathbf{s}^{(k)}$  tvoří bázi (ortogonální)  $n$ -rozměrného euklidovského prostoru, potom vynásobením (\*) skalárně s  $\mathbf{s}^{(k)}$  a úpravou získáme


$$\mathbf{s}^{(k)T} (\mathbf{x}^* - \mathbf{x}^{(0)}) = t^{(k)} \mathbf{s}^{(k)T} \mathbf{s}^{(k)}$$

$$t^{(k)} = \frac{\mathbf{s}^{(k)T} (\mathbf{x}^* - \mathbf{x}^{(0)})}{\mathbf{s}^{(k)T} \mathbf{s}^{(k)}} \quad \dots \text{nešikovné !, obsahuje přesné řešení}$$

- je třeba zvolit lepší strategii volby vektorů  $\mathbf{s}^{(k)}$

Definice  $\mathbf{x}^{(k)}$  je **optimální vzhledem ke směru**  $\mathbf{s} \neq \mathbf{0}$ , jestliže

$$F(\mathbf{x}^{(k)}) \leq F(\mathbf{x}^{(k)} + t\mathbf{s}) \quad \forall t \in \mathbb{R} \quad (*)$$



Poznámka: Je-li  $\mathbf{x}^{(k)}$  optimální vzhledem k libovolnému směru z vektorového prostoru  $V$ , říkáme, že je  $\mathbf{x}^{(k)}$  **optimální vzhledem k  $V$** .


Podle (\*) se minima nabývá pro  $t = 0$ , tzn. že derivace  $F$  podle  $t$  je v minimu ( $t = 0$ ) rovna 0:

$$\frac{\partial F}{\partial t} (\mathbf{x}^{(k)} + t\mathbf{s}) = t\mathbf{s}^T \mathbf{A}\mathbf{s} + \mathbf{s}^T (\mathbf{A}\mathbf{x}^{(k)} - \mathbf{b})$$

$$\frac{\partial F}{\partial \mathbf{x}}(\mathbf{x}^{(k)}) = \mathbf{s}^T \underbrace{(\mathbf{A}\mathbf{x}^{(k)} - \mathbf{b})}_{=\mathbf{r}^{(k)}} = 0$$

$$\mathbf{s} \perp \mathbf{r}^{(k)}$$

Poznámka: Iterace  $\mathbf{x}^{(k+1)}$  metody největšího spádu je optimální vzhledem k reziduu  $\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}$  ... směry, ve kterých minimalizujeme.



Naším cílem je, aby se i v dalších iteracích zachovávala optimalita k již použitým směrům.

To pro metodu největšího spádu bohužel neplatí.

Např. pro soustavu ve  $2D$  jsme ukazovali, že směry největšího spádu (reziduí) jsou na sebe kolmé,

$$\text{tj. } \mathbf{r}^{(k)} \perp \mathbf{r}^{(k+1)} \quad \text{a} \quad \mathbf{r}^{(k+1)} \perp \mathbf{r}^{(k+2)} \quad \Rightarrow \quad \boxed{\mathbf{r}^{(k)} \parallel \mathbf{r}^{(k+2)}} \quad !!!$$


$\Rightarrow \mathbf{x}^{(k+2)}$  je optimální vzhledem k  $\mathbf{r}^{(k+1)}$ , ale již není optimální vzhledem k  $\mathbf{r}^{(k)}$

Existují směry, které udržují optimalitu k předchozím?

Nechť

$$\boxed{\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{s}}$$

Předpokládejme, že  $\mathbf{x}^{(k)}$  je optimální vzhledem k  $\mathbf{v}$  (tj.  $\mathbf{r}^{(k)} \perp \mathbf{v}$ ).



Chceme-li, aby bylo i  $x^{(k+1)}$  optimální vzhledem k  $v$ , (tj.  $r^{(k+1)} \perp v$ ), musí platit:

$$0 = v^T r^{(k+1)} = v^T (b - Ax^{(k+1)}) = v^T (b - A(x^{(k)} + s)) = v^T \left( \underbrace{b - Ax^{(k)}}_{r^{(k)}} - As \right) = v^T (r^{(k)} - As) = -v^T As$$

### Závěr

Chceme-li zachovat optimalitu vzhledem ke všem použitým směrům, musí tyto směry splňovat podmínky tzv. **A-ortogonalita**, tj. pro 2 různé směry  $s$  a  $v$  musí platit:

$$v^T As = 0$$

Poznámka: Vektorům které jsou **A-ortogonální** se také říká **A-sdružené**.

### Metoda sdružených gradientů

Za směry, ve kterých minimalizujeme, budeme brát A-ortogonální vektory  $s^{(k)}$ .

Platí tedy:

$$s^{(k)T} A s^{(l)} = 0, \quad k \neq l$$

Chceme, aby platilo:

$$s^{(k)T} A \cdot / \quad x^* - x^{(0)} = \sum_{k=1}^n t^{(k)} s^{(k)} \quad (*)$$



$$\mathbf{s}^{(k)T} \underbrace{\mathbf{A}(\mathbf{x}^* - \mathbf{x}^{(0)})}_{\mathbf{Ax}^* - \mathbf{Ax}^{(0)}} = t^{(k)} \mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(k)}$$

$$\mathbf{Ax}^* - \mathbf{Ax}^{(0)} = \underbrace{\mathbf{Ax}^* - \mathbf{b}}_{=\mathbf{0}} - \underbrace{\mathbf{Ax}^{(0)} - \mathbf{b}}_{\mathbf{r}^{(0)}} + \mathbf{b}$$

$$t^{(k)} = \frac{\mathbf{s}^{(k)T} \mathbf{r}^{(0)}}{\mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(k)}}$$

### Strategie volby směrů

- Máme-li ortogonální bázi  $\mathbb{R}^n$ , lze z ní procesem  $A$ -ortogonalizace získat  $A$ -ortogonální bázi.
- Za ortogonální bázi budeme volit reziduové vektory.  
Aby proces ortogonalizace vedl k cíli, musíme zaručit, že reziduové vektory tvoří bázi.  
Ortogonalitu ukážeme vzápětí; může se stát, že se některé reziduum anulují.  
Potom ovšem iterační proces končí - dosáhli jsme přesného řešení.
- Provádíme tedy současně 2 procesy!
  - iterační proces
  - proces  $A$ -ortogonalizace
- Vektory reziduí budeme značit  $\mathbf{r}^{(k)}$ , získané sdružené směry označíme  $\mathbf{s}^{(k)}$ 
  - pro zadané  $\mathbf{x}^{(0)}$  určíme  $\mathbf{r}^{(0)} = \mathbf{b} - \mathbf{Ax}^{(0)}$
  - $\mathbf{s}^{(0)}$  položíme rovno  $\mathbf{r}^{(0)}$
  - určíme  $\mathbf{x}^{(1)}$  optimální vzhledem k  $\mathbf{s}^{(0)}$
  - určíme  $\mathbf{r}^{(1)}$
  - $\mathbf{s}^{(1)}$  určíme z  $\mathbf{r}^{(1)}$  tak, aby  $\mathbf{s}^{(1)T} \mathbf{A} \mathbf{s}^{(0)} = 0$
  - atd.

### Proces $A$ -ortogonalizace

$$\mathbf{s}^{(k)} = \mathbf{r}^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} \mathbf{s}^{(i)} \quad (\bullet\bullet)$$

(Při určení  $\mathbf{s}^{(k)}$  vyjdeme z  $\mathbf{r}^{(k)}$ . Přičítáme násobky předchozích  $\mathbf{s}^{(i)}$  tak, abychom zaručili  $A$ -ortogonalitu.)

Koeficienty  $\beta_{ki}$  volíme tak, aby

$$\mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(i)} = 0, \quad (i < k)$$

( $\bullet\bullet$ ) vynásobíme  $\mathbf{s}^{(i)T} \mathbf{A} \cdot /$

$$\underbrace{\mathbf{s}^{(i)T} \mathbf{A} \mathbf{s}^{(k)}}_{=0} = \mathbf{s}^{(i)T} \mathbf{A} \mathbf{r}^{(k)} + \beta_{ki} \mathbf{s}^{(i)T} \mathbf{A} \mathbf{s}^{(i)}$$

$$\Rightarrow \beta_{ki} = -\frac{\mathbf{s}^{(i)T} \mathbf{A} \mathbf{r}^{(k)}}{\mathbf{s}^{(i)T} \mathbf{A} \mathbf{s}^{(i)}}$$

Z vlastností  $A$ -ortogonalitě vyplývá řada skutečností.

**Věta 1** Platí

$$\begin{aligned} \mathbf{r}^{(k)T} \cdot \mathbf{s}^{(j)} &= \mathbf{r}^{(0)T} \cdot \mathbf{s}^{(j)} & k \leq j \\ \mathbf{r}^{(k)T} \cdot \mathbf{s}^{(j)} &= 0 & k > j \end{aligned}$$

Důkaz:

$$\begin{aligned} -\mathbf{b} \cdot / \quad \mathbf{A} \cdot / \quad \mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + t^{(k)} \mathbf{s}^{(k)} \\ \Rightarrow -\mathbf{r}^{(k+1)} &= -\mathbf{r}^{(k)} + t^{(k)} \mathbf{A} \mathbf{s}^{(k)} \\ \Rightarrow \mathbf{r}^{(k)} &= \mathbf{r}^{(0)} - \sum_{j=1}^{k-1} t^{(j)} \mathbf{A} \mathbf{s}^{(j)} \end{aligned}$$

vynásobíme skalárně s  $\mathbf{s}^{(j)}$

$$\mathbf{r}^{(k)T} \mathbf{s}^{(j)} = \mathbf{r}^{(0)T} \mathbf{s}^{(j)} - \underbrace{t^{(j)} \mathbf{s}^{(j)T} \mathbf{A} \mathbf{s}^{(j)}}_{(*)}$$

(\*) počítáme (viz dříve) takto

$$t^{(j)} = \frac{\mathbf{r}^{(0)T} \mathbf{s}^{(j)}}{\mathbf{s}^{(j)T} \mathbf{A} \mathbf{s}^{(j)}}$$

□

Důkaz:

vztah (••) vynásobíme skalárně s  $\mathbf{A} \mathbf{s}^{(j)}$

$$\begin{aligned} \mathbf{s}^{(k)} &= \mathbf{r}^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} \mathbf{s}^{(i)} & (\bullet\bullet) \\ \underbrace{\mathbf{s}^{(j)T} \mathbf{A} \mathbf{s}^{(k)}}_{= 0 \ (k < j)} &= \mathbf{s}^{(j)T} \mathbf{A} \mathbf{r}^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} \underbrace{\mathbf{s}^{(j)T} \mathbf{A} \mathbf{s}^{(i)}}_{= 0 \ (k \leq j)} \\ &\neq 0 \ (k = j) \end{aligned}$$

□

Důkaz:

Úplnou matematickou indukci ukážeme, že

$$\mathbf{r}^{(j)T} \mathbf{r}^{(k)} = 0 \quad \text{pro } j > k.$$

Platí

$$\mathbf{r}^{(k+1)} = \mathbf{b} - \mathbf{A} \mathbf{x}^{(k+1)} = \mathbf{b} - \mathbf{A}(\mathbf{x}^{(k)} + t^{(k)} \mathbf{r}^{(k)}) = \mathbf{r}^{(k)} - t^{(k)} \mathbf{A} \mathbf{r}^{(k)}$$

1.  $j = 1$   $\Rightarrow k = 0$

$$\mathbf{r}^{(1)T} \mathbf{r}^{(0)} = (\mathbf{r}^{(0)} + t^{(0)} \mathbf{A} \mathbf{s}^{(0)})^T \mathbf{r}^{(0)} = \mathbf{r}^{(0)T} \mathbf{r}^{(0)} + t^{(0)} \mathbf{s}^{(0)T} \mathbf{A} \mathbf{r}^{(0)} = \mathbf{r}^{(0)T} \mathbf{r}^{(0)} - \frac{\mathbf{r}^{(0)T} \mathbf{s}^{(0)}}{\mathbf{s}^{(0)T} \mathbf{A} \mathbf{s}^{(0)}} \mathbf{s}^{(0)T} \mathbf{A} \mathbf{r}^{(0)} = 0$$

$$(\mathbf{r}^{(0)} = \mathbf{s}^{(0)})$$



2. a)  $\forall k < j$  platí:  $\mathbf{r}^{(j+1)T} \mathbf{r}^{(k)} = 0$

$$\mathbf{r}^{(j+1)T} \mathbf{r}^{(k)} = (\mathbf{r}^{(j)} + t^{(j)} \mathbf{A} \mathbf{s}^{(j)})^T \mathbf{r}^{(k)} = \underbrace{\mathbf{r}^{(j)T} \mathbf{r}^{(k)}}_{=0 \text{ (předpoklad)}} + t^{(j)} \underbrace{\mathbf{s}^{(j)T} \mathbf{A} \mathbf{r}^{(k)}}_{=0 \text{ (Věta 2)}}$$

b)  $\mathbf{r}^{(j+1)T} \mathbf{r}^{(j)} = 0$

$$\mathbf{r}^{(j+1)T} \mathbf{r}^{(j)} = (\mathbf{r}^{(j)} + t^{(j)} \mathbf{A} \mathbf{s}^{(j)})^T \mathbf{r}^{(j)} = \mathbf{r}^{(j)T} \mathbf{r}^{(j)} + t^{(j)} \mathbf{s}^{(j)T} \mathbf{A} \mathbf{r}^{(j)} = \underbrace{\mathbf{r}^{(j)T} \mathbf{r}^{(j)} - \frac{\mathbf{r}^{(0)T} \mathbf{s}^{(j)}}{\mathbf{s}^{(j)T} \mathbf{A} \mathbf{s}^{(j)}} \mathbf{s}^{(j)T} \mathbf{A} \mathbf{r}^{(j)}}_{\mathbf{s}^{(j)T} \mathbf{A} \mathbf{s}^{(j)} = \mathbf{s}^{(j)T} \mathbf{A} \mathbf{r}^{(j)} \text{ (Věta 2)}} + \mathbf{r}^{(j)T} \mathbf{r}^{(j)} \quad (\text{Věta 1})$$

□

Důkaz: Platí:

$$\beta_{ki} = -\frac{\mathbf{s}^{(i)T} \mathbf{A} \mathbf{r}^{(k)}}{\mathbf{s}^{(i)T} \mathbf{A} \mathbf{s}^{(i)}}$$

Pro čitatel platí:

$$\mathbf{s}^{(i)T} \mathbf{A} \mathbf{r}^{(k)} = \mathbf{r}^{(k)T} \mathbf{A} \mathbf{s}^{(i)} = \mathbf{r}^{(k)T} \frac{\mathbf{1}}{t^{(i)}} (\mathbf{r}^{(i+1)} - \mathbf{r}^{(i)}),$$

kde se použil vztah

$$\mathbf{r}^{(i+1)} = \mathbf{r}^{(i)} + t^{(i)} \mathbf{A} \mathbf{s}^{(i)}, \quad t^{(i)} \neq 0 \text{ pro } \mathbf{r}^{(i)} \neq \mathbf{0}$$

Platí

• pro  $i < k - 1$ : čitatel  $\beta_{ki} = \mathbf{r}^{(k)T} (\mathbf{r}^{(i+1)} - \mathbf{r}^{(i)}) \frac{1}{t^{(i)}} = 0$  **(Tvzení)**

• pro  $i = k - 1$ : čitatel  $\beta_{k,k-1} = \mathbf{r}^{(k)T} (\mathbf{r}^{(k)} - \mathbf{r}^{(k-1)}) \frac{1}{t^{(k-1)}} = \mathbf{r}^{(k)T} \mathbf{r}^{(k)} \frac{1}{t^{(k-1)}} \neq 0$  (pro  $\mathbf{r}^{(k)} \neq \mathbf{0}$ )

□

Algoritmus (Metoda sdružených gradientů)

1.  $\mathbf{x}^{(0)}, \varepsilon$

2.  $\mathbf{r}^{(0)} = \mathbf{b} - \mathbf{A} \mathbf{x}^{(0)}, \mathbf{s}^{(0)} = \mathbf{r}^{(0)}$

3.  $t^{(k)} = \frac{\mathbf{s}^{(k)T} \mathbf{r}^{(k)}}{\mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(k)}}$


4.  $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t^{(k)} \mathbf{s}^{(k)}$

5.  $\mathbf{r}^{(k+1)} = \mathbf{r}^{(k)} + t^{(k)} \mathbf{A} \mathbf{s}^{(k)}$

6.  $\beta_k = -\frac{\mathbf{s}^{(k)T} \mathbf{A} \mathbf{r}^{(k+1)}}{\mathbf{s}^{(k)T} \mathbf{A} \mathbf{s}^{(k)}}$

7.  $\mathbf{s}^{(k+1)} = \mathbf{r}^{(k+1)} + \beta_k \mathbf{s}^{(k)}$


8. If  $\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\| < \varepsilon$  then konec, else  $\rightarrow$  add 3




**Geometrický význam metody sdružených gradientů**



Metoda sdruzených gradientů



$k$	$x^{(k)}$	$y^{(k)}$
0	9.0000	0
1	4.7425	1.0321
2	4.0000	6.0000





Poznámka: Gradientní metody patří mezi **nestacionární metody**.

např. pro metodu největšího spádu platí

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t^{(k)} \mathbf{d}^{(k)} = \mathbf{x}^{(k)} + t^{(k)} (\mathbf{b} - \mathbf{A} \mathbf{x}^{(k)}) = \underbrace{(\mathbf{I} - t^{(k)} \mathbf{A})}_{\mathbf{H}^{(k)}} \mathbf{x}^{(k)} + \underbrace{t^{(k)} \mathbf{b}}_{\mathbf{g}^{(k)}}$$

V každém kroku se mění matice  $\mathbf{H}^{(k)}$ .

Platí-li  $\|\mathbf{H}^{(k)}\| \rightarrow 0$  (pro  $k \rightarrow \infty$ ), dostaneme metody se superlineární rychlostí konvergence.

**Věta** Necht'  $\mathbf{A}$  je symetrická pozitivně definitní. Potom metoda sdružených gradientů konverguje nejvýše po  $n$  krocích. Navíc chyba  $k$ -té iterace ( $k < n$ ) je ortogonální na směry  $\mathbf{s}^{(j)}$ ,  $j = 0, 1, \dots, k-1$  a platí:

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\|_{\mathbf{A}} \leq \frac{2C^k}{1 + C^{2k}} \|\mathbf{x}^{(0)} - \mathbf{x}^*\|_{\mathbf{A}},$$

kde  $C = \frac{\sqrt{\kappa(\mathbf{A})} - 1}{\sqrt{\kappa(\mathbf{A})} + 1}$ ,  $\kappa(\mathbf{A}) = \frac{\lambda_{max}}{\lambda_{min}}$ .

Poznámka: V metodě největšího spádu vystupuje ve vztahu pro chybu  $k$ -té iterace koeficient


$$\left( \frac{\kappa(\mathbf{A}) - 1}{\kappa(\mathbf{A}) + 1} \right)^k.$$

Je zřejmé, že na rychlost konvergence má vliv číslo  $\kappa(\mathbf{A})$ , tj.  $\lambda_{max}$  a  $\lambda_{min}$ . Čím blíže je  $\lambda_{max}$  a  $\lambda_{min}$ , tím rychleji metody konvergují.

#### Příklad 4

Řešte soustavu  $\mathbf{Ax} = \mathbf{b}$ , kde

$$\mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & 10000 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 1 \\ 10000 \end{bmatrix}, \quad \text{přesné řešení } \mathbf{x}^* = \begin{bmatrix} 1 \\ 1 \end{bmatrix}.$$



- poměr poloos elips je  $\sqrt{10000} : \sqrt{1} = 100 : 1$  !!!
- $\kappa(\mathbf{A}) = \frac{10000}{1} = 10000 \Rightarrow$  pomalá konvergence!

Vezměme si matici  $\mathbf{P}^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & \frac{1}{10000} \end{bmatrix}$  ( $\det(\mathbf{P}^{-1}) \neq 0$ ) a řešme soustavu

$$\mathbf{P}^{-1} \mathbf{Ax} = \mathbf{P}^{-1} \mathbf{b}$$



$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

- $\kappa(\mathbf{P}^{-1} \mathbf{A}) = \frac{1}{1} = 1 \Rightarrow$  rychlá konvergence (1. iterace). Mluvíme o tzv. **předpodmiňování**.

#### Poznámka:

Chceme-li i novou (předpodmíněnou) soustavu řešit metodou sdružených gradientů, musí být její matice symetrická pozitivně definitní.

Místo matice  $\mathbf{P}^{-1} \mathbf{A}$  vezmeme matici (podobnou  $\mathbf{A}$ )  $\mathbf{P}^{-\frac{1}{2}} \mathbf{A} \mathbf{P}^{-\frac{1}{2}}$  ( $\mathbf{P} \dots$  symetrická pozitivně definitní) a řešíme soustavu

$$\boxed{\tilde{\mathbf{A}} \tilde{\mathbf{x}} = \tilde{\mathbf{b}}}$$

$$\tilde{\mathbf{A}} = \mathbf{P}^{-\frac{1}{2}} \mathbf{A} \mathbf{P}^{-\frac{1}{2}}, \quad \tilde{\mathbf{x}} = \mathbf{P}^{\frac{1}{2}} \mathbf{x}, \quad \tilde{\mathbf{b}} = \mathbf{P}^{-\frac{1}{2}} \mathbf{b}$$

Jak volit matice předpodmínění  $\mathbf{P}$  ?

... řada možností, např.  $\mathbf{P} = \text{diag}(\mathbf{A})$

#### Příklad 5

Porovnejte vlastní čísla zadané matice  $\mathbf{A}$  a matice získané pomocí diagonálního předpodmínění.

$$\mathbf{A} = \begin{bmatrix} 1000000 & 200 & 30 & 0 \\ 200 & 10000 & 40 & 0 \\ 30 & 40 & 100 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\mathbf{P} = \begin{bmatrix} 1000000 & 0 & 0 & 0 \\ 0 & 10000 & 0 & 0 \\ 0 & 0 & 100 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\mathbf{P}^{-\frac{1}{2}} = \begin{bmatrix} \frac{1}{\sqrt{1000000}} & 0 & 0 & 0 \\ 0 & \frac{1}{\sqrt{10000}} & 0 & 0 \\ 0 & 0 & \frac{1}{\sqrt{100}} & 0 \\ 0 & 0 & 0 & \frac{1}{\sqrt{1}} \end{bmatrix} = \begin{bmatrix} \frac{1}{1000} & 0 & 0 & 0 \\ 0 & \frac{1}{100} & 0 & 0 \\ 0 & 0 & \frac{1}{10} & 0 \\ 0 & 0 & 0 & \frac{1}{1} \end{bmatrix}$$

$$\begin{aligned} \tilde{\mathbf{A}} = \mathbf{P}^{-\frac{1}{2}} \mathbf{A} \mathbf{P}^{-\frac{1}{2}} &= \begin{bmatrix} \frac{1}{1000} & 0 & 0 & 0 \\ 0 & \frac{1}{100} & 0 & 0 \\ 0 & 0 & \frac{1}{10} & 0 \\ 0 & 0 & 0 & \frac{1}{1} \end{bmatrix} \begin{bmatrix} 1000000 & 200 & 30 & 0 \\ 200 & 10000 & 40 & 0 \\ 30 & 40 & 100 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{1000} & 0 & 0 & 0 \\ 0 & \frac{1}{100} & 0 & 0 \\ 0 & 0 & \frac{1}{10} & 0 \\ 0 & 0 & 0 & \frac{1}{1} \end{bmatrix} = \\ &= \begin{bmatrix} 1 & 0.002 & 0.003 & 0 \\ 0.002 & 1 & 0.04 & 0 \\ 0.003 & 0.04 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \end{aligned}$$

vlastní čísla matice  $\mathbf{A}$ :

$$\lambda_1 = 1; \quad \lambda_2 \doteq 99,837534233; \quad \lambda_3 \doteq 10000,121161153; \quad \lambda_4 \doteq 1000000,041304614$$

$$\kappa(\mathbf{A}) \doteq \frac{1000000,041304614}{1} = 1000000,041304614$$

vlastní čísla matice  $\tilde{\mathbf{A}} = \mathbf{P}^{-\frac{1}{2}}\mathbf{A}\mathbf{P}^{-\frac{1}{2}}$ :

$$\tilde{\lambda}_1 \doteq 0,959987454937999; \quad \tilde{\lambda}_2 \doteq 0,999702401514713; \quad \tilde{\lambda}_3 = 1; \quad \tilde{\lambda}_4 \doteq 1,040310143547287$$

$$\kappa(\tilde{\mathbf{A}}) \doteq \frac{1,040310143547287}{0,959987454937999} \doteq 1,083670560689229$$