

# SOUSTAVY LINEÁRNÍCH ALGEBRAICKÝCH ROVNIC

## Metody

- **přímé** (GEM, metoda LU-rozkladu)
- **iterační** (Jacobi, Gauss-Seidel, SOR)
- **gradientní**

## Motivace:

Uvažujme kvadratickou funkci

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

Nutná a postačující podmínka minima má tvar

$$ax = b.$$

To znamená, že místo řešení rovnice můžeme řešit úlohu najít minimum konvexní kvadratické funkce  $f(x)$  (obě úlohy mají stejné 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 (matice  $\mathbf{A}$  je symetrická, pozitivně definitní)

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

Dále uvažujeme kvadratickou formu - **energetický funkcionál**

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

Platí

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

Funkce  $\mathbf{F}(\mathbf{x})$  je konvexní a kvadratická

$\implies \mathbf{F}(\mathbf{x})$  má globální minimum a pro bod minima  $\tilde{\mathbf{x}}$  platí

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

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

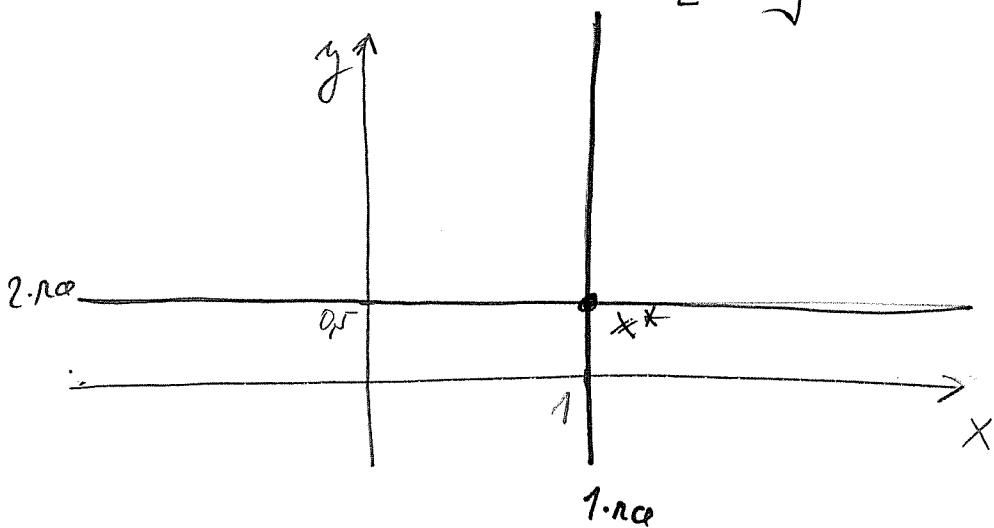
### Poznámka:

Úlohy najít bod minima funkce  $\mathbf{F}$  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  $\mathbf{F}(\mathbf{x})$  eliptický paraboloid, jehož vrstevnice jsou elipsy. Minima  $\mathbf{F}(\mathbf{x})$  se nabývá ve vrcholu paraboloidu.

Práhled

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



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

$$\begin{aligned} &= \frac{1}{2} [x, y] \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} - [25, 8] \begin{bmatrix} x \\ y \end{bmatrix} \\ &= \frac{1}{2} (25x^2 + 16y^2) - 25x - 8y \end{aligned}$$

Vrstevnice (blading):

$$F(x) = c$$

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

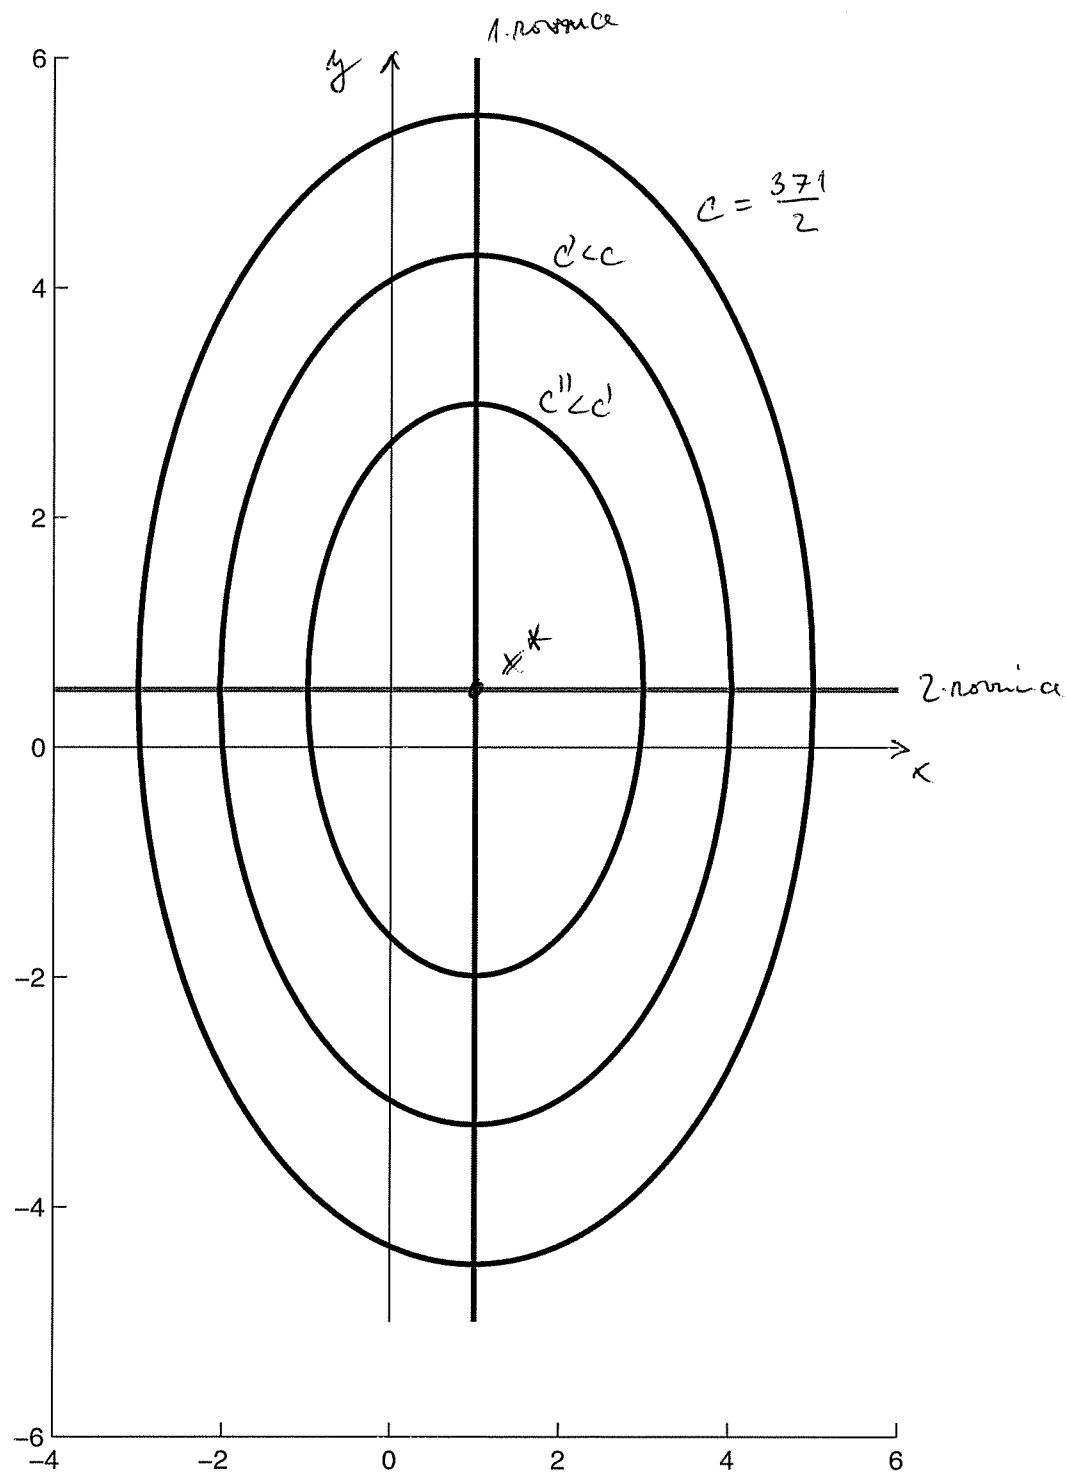
$$\underline{25x^2} + 16y^2 - \underline{50x} - 16y = 2c$$

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

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

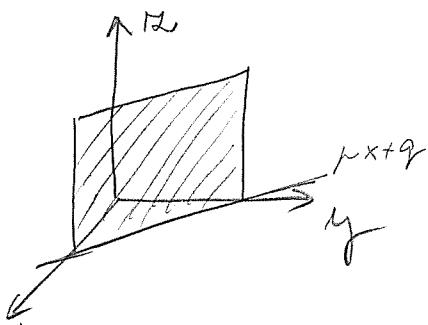
$$\frac{(x-1)^2}{4^2} + \frac{(y - \frac{1}{2})^2}{5^2} = \frac{2c + 29}{400} = 1$$

např pro
$c = \frac{371}{2}$

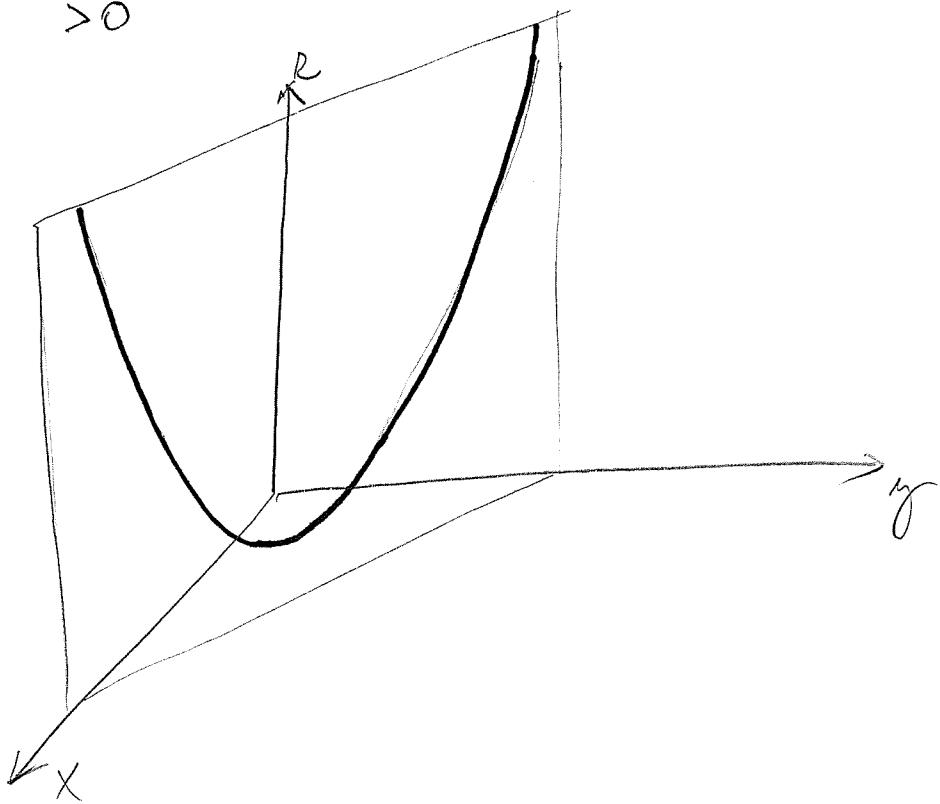


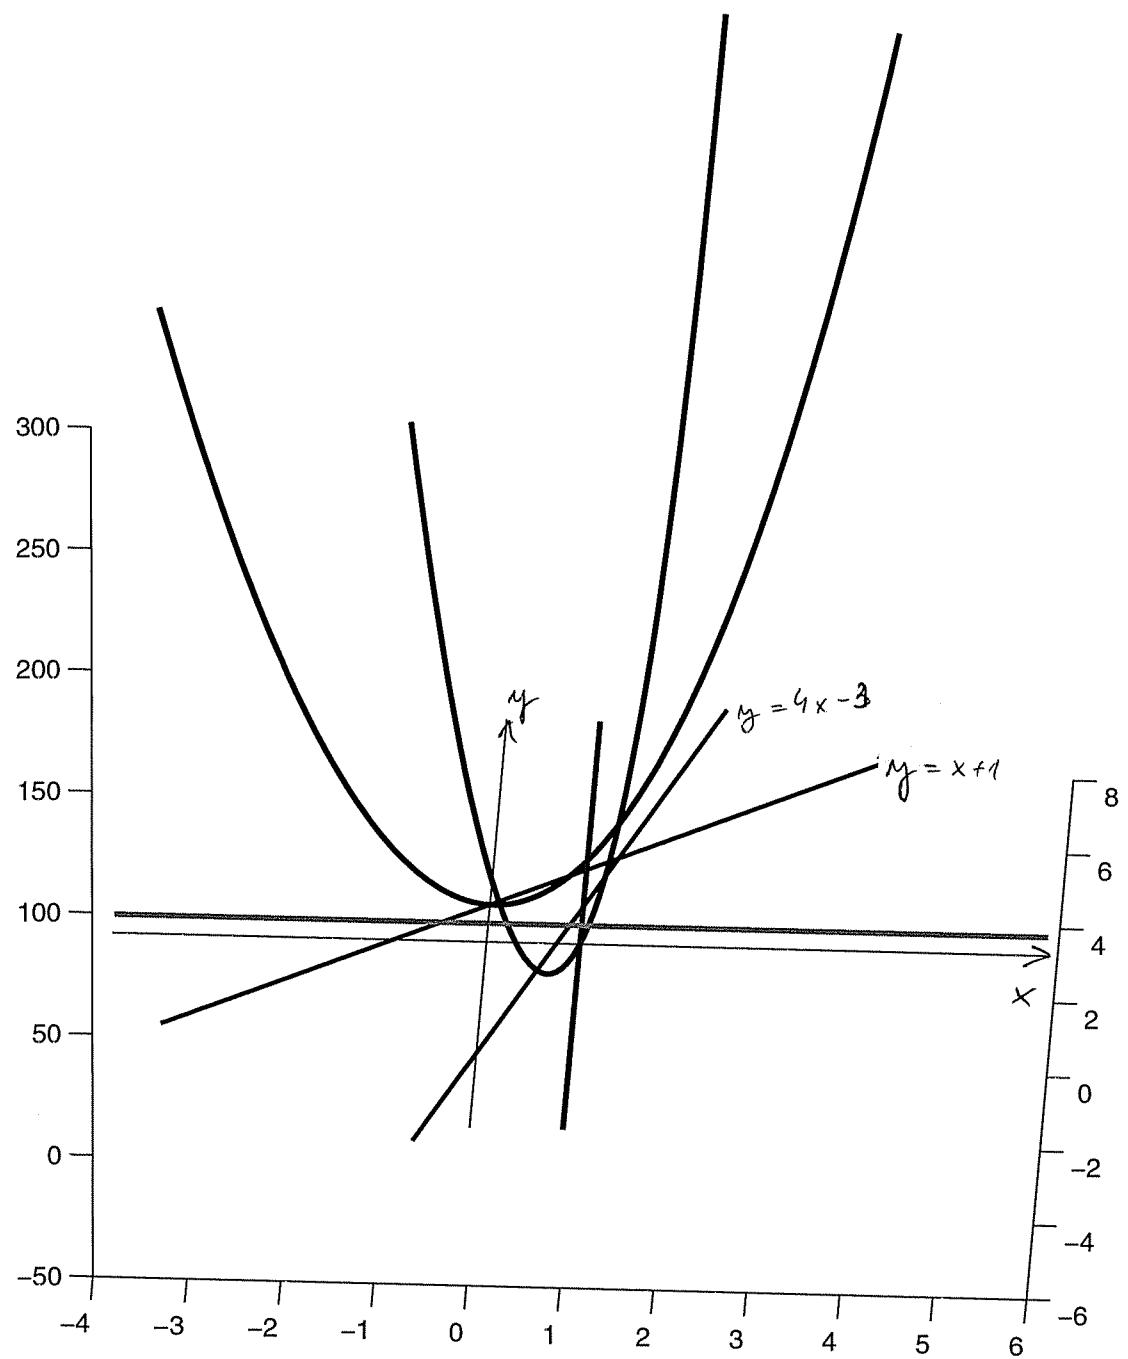
Rozvoj výkonu roviny

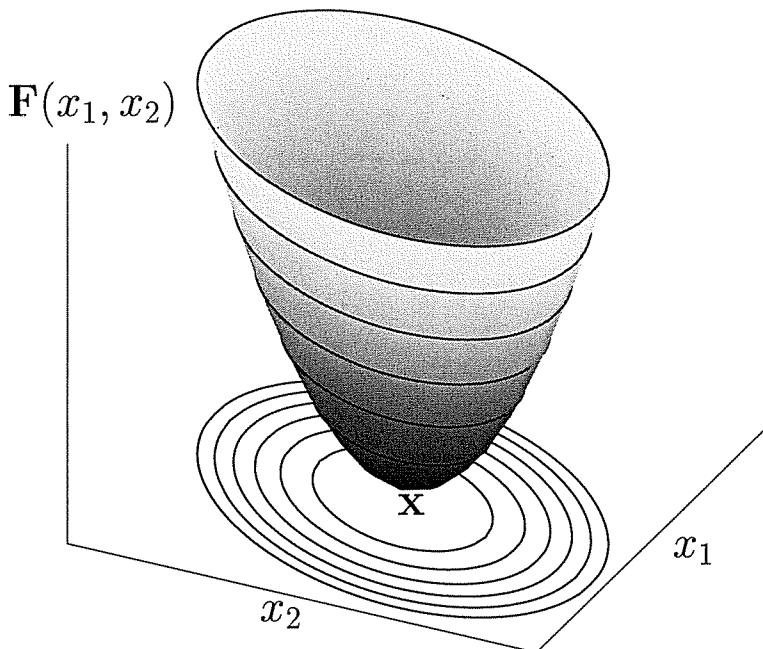
$$y = px + q$$



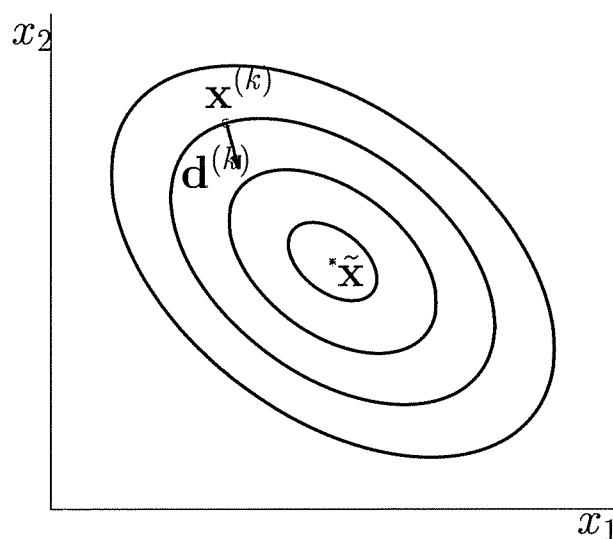
$$\begin{aligned}F(x) &= \frac{1}{2}(25x^2 + 16y^2) - 25x - 8y \\&= \frac{1}{2}(25x^2 + 16(px+q)^2) - 25x - 8(px+q) \\&= \frac{1}{2}(25x^2 + 16(p^2x^2 + 2pqx + q^2)) - 25x - 8px - 8q \\&= \underbrace{\left(\frac{25}{2} + \frac{16}{2}p^2\right)}_{>0} x^2 + (16pq - 25 - 8p)x + 8q^2 - 8q\end{aligned}$$







Stejně jako u každé iterační metody nejprve zvolíme počáteční approximaci řešení  $\mathbf{x}^{(0)}$ . 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 dána volbou směrů, ve kterých minimalizujeme funkci  $\mathbf{F}$ .



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

První možností je za směrový vektor volit směr největšího spádu, tj. vektor

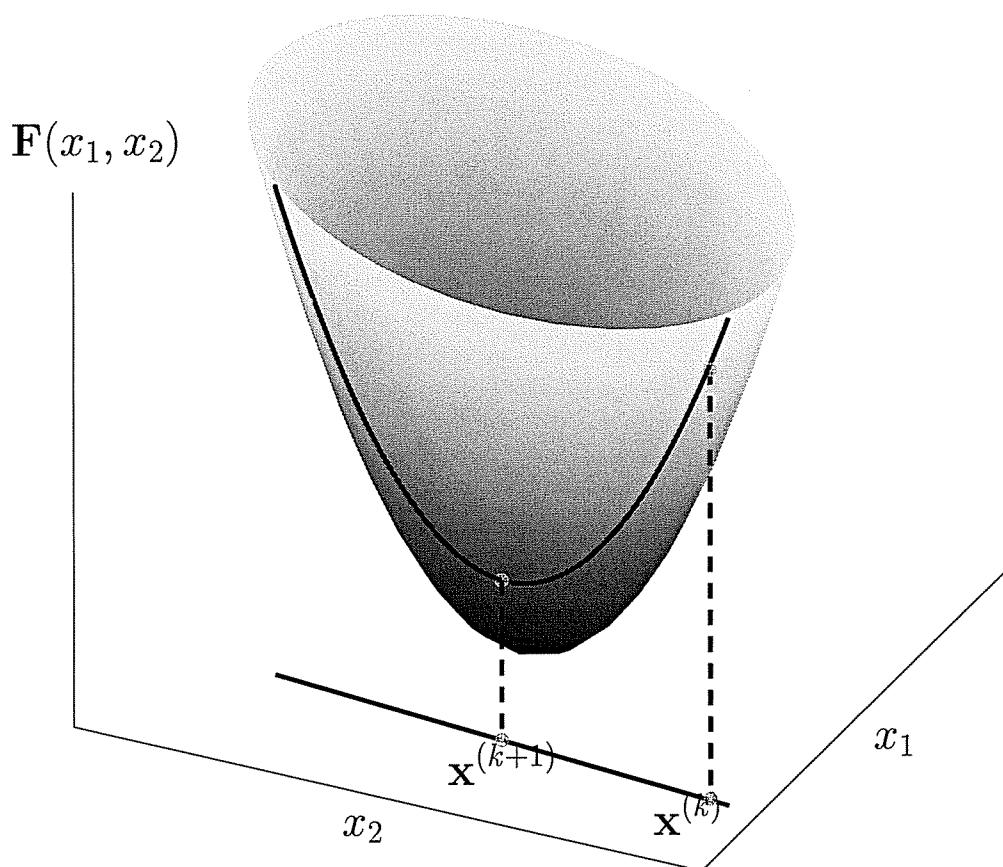
$$\mathbf{d}^{(k)} = -\text{grad } \mathbf{F}(\mathbf{x}^{(k)}) = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}.$$

Získáme tzv. **metodu největšího spádu**. 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.

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



Minimalizovanou funkci proměnné  $t$  označíme  $\Psi(t)$ . Potom platí:

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

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

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

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

### Poznámka:

Ve výrazu pro derivaci  $\Psi(t)$  jsme využili symetrii matice  $\mathbf{A}$ .

$$\frac{d}{dt} (\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}) = \mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} \quad \dots \text{ skalár}$$

$$\frac{d}{dt} (\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)}) = \underbrace{\mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)}}_{\dots \text{ skalár}}$$

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

Platí  $\mathbf{A}^T = \mathbf{A}$ , proto

$$\mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)} + \mathbf{d}^{(k)T} \mathbf{A} \mathbf{x}^{(k)} = \underline{\underline{2 \mathbf{x}^{(k)T} \mathbf{A} \mathbf{d}^{(k)}}}$$

Algoritmus metody největšího spádu potom můžeme zapsat takto:

- 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 množení matice a vektorem, můžeme  $\mathbf{d}^{(k+1)}$  psát takto:

$$\begin{aligned}\mathbf{d}^{(k+1)} &= \mathbf{b} - \mathbf{A}\mathbf{x}^{(k+1)} = \underline{\mathbf{b} - \mathbf{A}(\mathbf{x}^{(k)} + \lambda^{(k)}\mathbf{d}^{(k)})} = \\ &= \underline{\mathbf{d}^{(k)}} + \lambda^{(k)} \underbrace{\mathbf{A}\mathbf{d}^{(k)}}_{\text{toto se počítalo v kroku 3}}\end{aligned}$$

v původní iteraci

**Věta:** Metoda největšího spádu konverguje (pro symetrickou, pozitivně definitní matici) po libovolné velké početné approximaci k přesnému řešení soustavy  $A\mathbf{x} = \mathbf{b}$ .

**Věta** Nechť  $\mathbf{x}^*$  je bodem minima kvadratické funkce  $F(\mathbf{x})$  a  $\mathbf{x}^{(k)}$  je approximace nízkané metody největšího spádu. Potom

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\|_A = \left( \frac{\alpha(A) - 1}{\alpha(A) + 1} \right)^k \cdot \|\mathbf{x}^{(0)} - \mathbf{x}^*\|_A, \quad \mathbf{x}^{(0)} \in \mathbb{R}^N$$

hde  $\alpha(A) = \frac{\lambda_{\max}}{\lambda_{\min}}$ ,  $\|\cdot\|_A = \sqrt{(A\mathbf{x}, \mathbf{x})} = \sqrt{\mathbf{x}^T A \mathbf{x}}$   
 .... energetická norma

Dihar: diskritne konvergencija norme  $\| \cdot \|_A$ .

II. II<sub>A</sub> je sekundární normální divalentní,  
jež lze jít plyně i konverguje s II. II<sub>B</sub>

Def:  $X$ .. bin prostor,  $\|\cdot\|_1$  a  $\|\cdot\|_2$  .. normy na  $X$   
 $\|\cdot\|_1$  a  $\|\cdot\|_2$  jsou ekvivalentní, existují čísla  
 $c, \epsilon > 0 : \forall x \in X$

$$C \|x\|_1 \leq \|x\|_2 \leq C \|x\|_1$$

$X^*$ ... prime 'risen'  $Ax = b$

$$d^{(k)} = \underline{x^{(k)}} - x^* \dots \text{czyba } k-k' \text{ iteracj}$$

$$\underline{F(x^{(k)}) - F(x^*)} = \underline{F(x^* + e^{(k)}) - F(x^*)} = \underline{\frac{1}{2} e^{(k)^\top} A e^{(k)}}$$

pro 2 body  $x, x+10t$  plot:

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

$$-\frac{1}{2} x^T A x + b^T x \quad ||$$

$$= \underline{A} \times^T A \underline{d} + \frac{1}{2} \underline{A}^2 \underline{d}^T A \underline{d} - \underline{A} b^T \underline{d} =$$

$$= \frac{1}{2} \cdot d^T (A \cdot x - b) + \frac{\lambda}{2} \|A^T A \cdot d\|^2$$

[pro next input  $x = x^*, t = 1, \alpha = e^{(h)}$ ]

$$\Rightarrow \underline{-1} = 0$$

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

$$\rightarrow x^{(k+1)} = x^{(k)} + \lambda^{(k)} r$$

$$\underline{F(x^{(k+1)}) - F(x^{(k)})} = \lambda^{(k)} r^{(k)}^T \underbrace{(A x^{(k)} - b)}_{-r^{(k)}} + \frac{1}{2} \lambda^{(k)2} r^{(k)T} A r^{(k)} =$$

$\lambda^{(k)}$  gime positionielle pole

$$\boxed{\lambda^{(k)} = \frac{r^{(k)T} r^{(k)}}{r^{(k)T} A r^{(k)}}}$$

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

$$= - \frac{1}{2} \frac{(r^{(k)T} \cdot r^{(k)})^2}{r^{(k)T} A r^{(k)}}$$

$$- \frac{1}{2} \frac{(r^{(k)T} \cdot r^{(k)})^2}{r^{(k)T} A r^{(k)}} = \left( \frac{1}{2} e^{(k+1)T} A e^{(k+1)} \right) - \frac{1}{2} e^{(k)T} A e^{(k)}$$

a) 1.2

b) post. iter  
fixierung

c) cyclische Sch.

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

platt'  $\boxed{A e^{(k)} = r^{(k)}}$ , probieren



$$e^{(k)} = A^{-1} r^{(k)}$$

$$A x^* = b = 0 \text{ a}$$

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

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

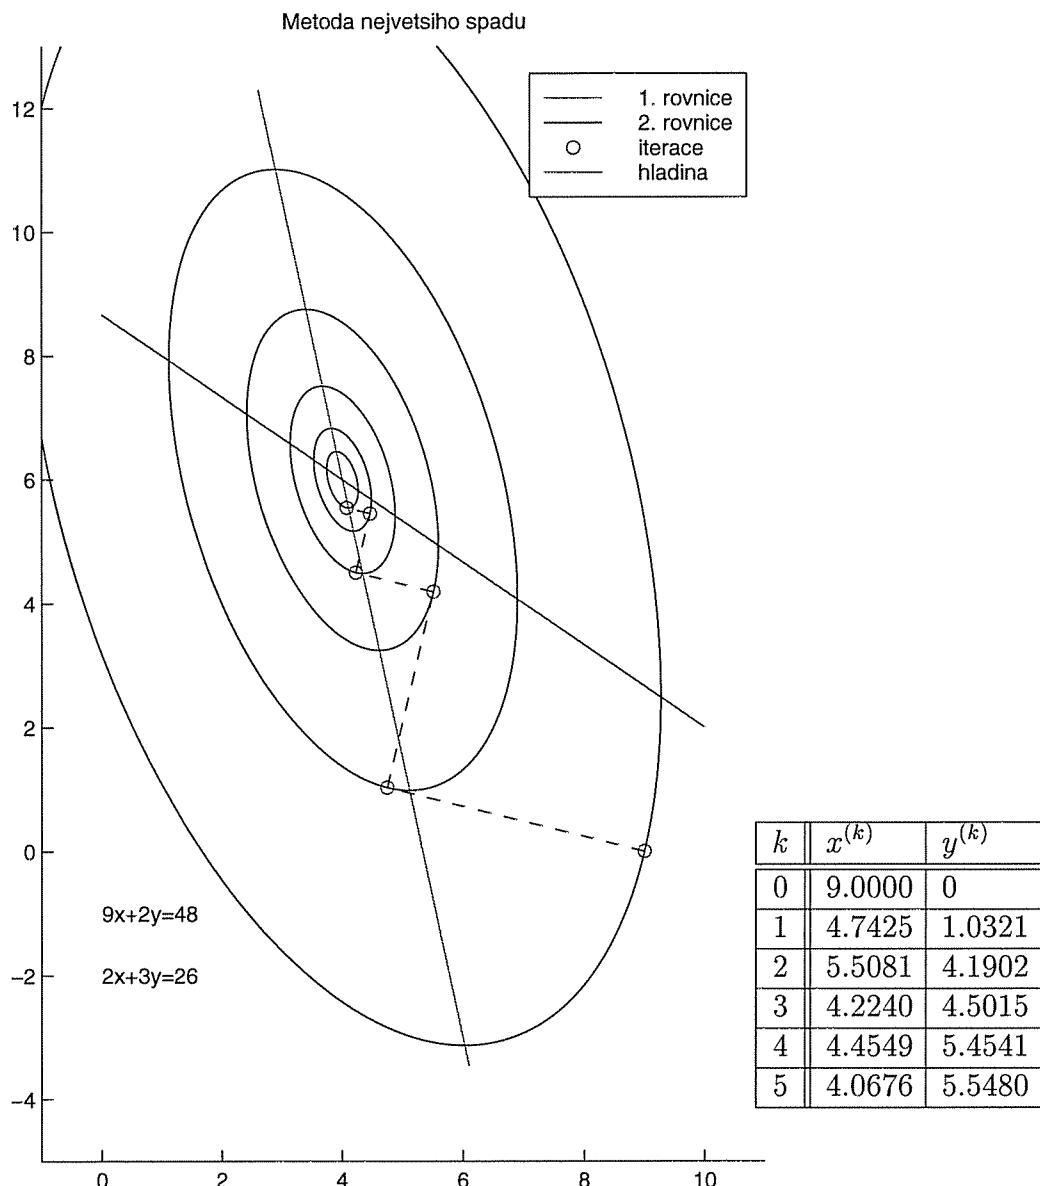
Distanzvahle verringert:

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

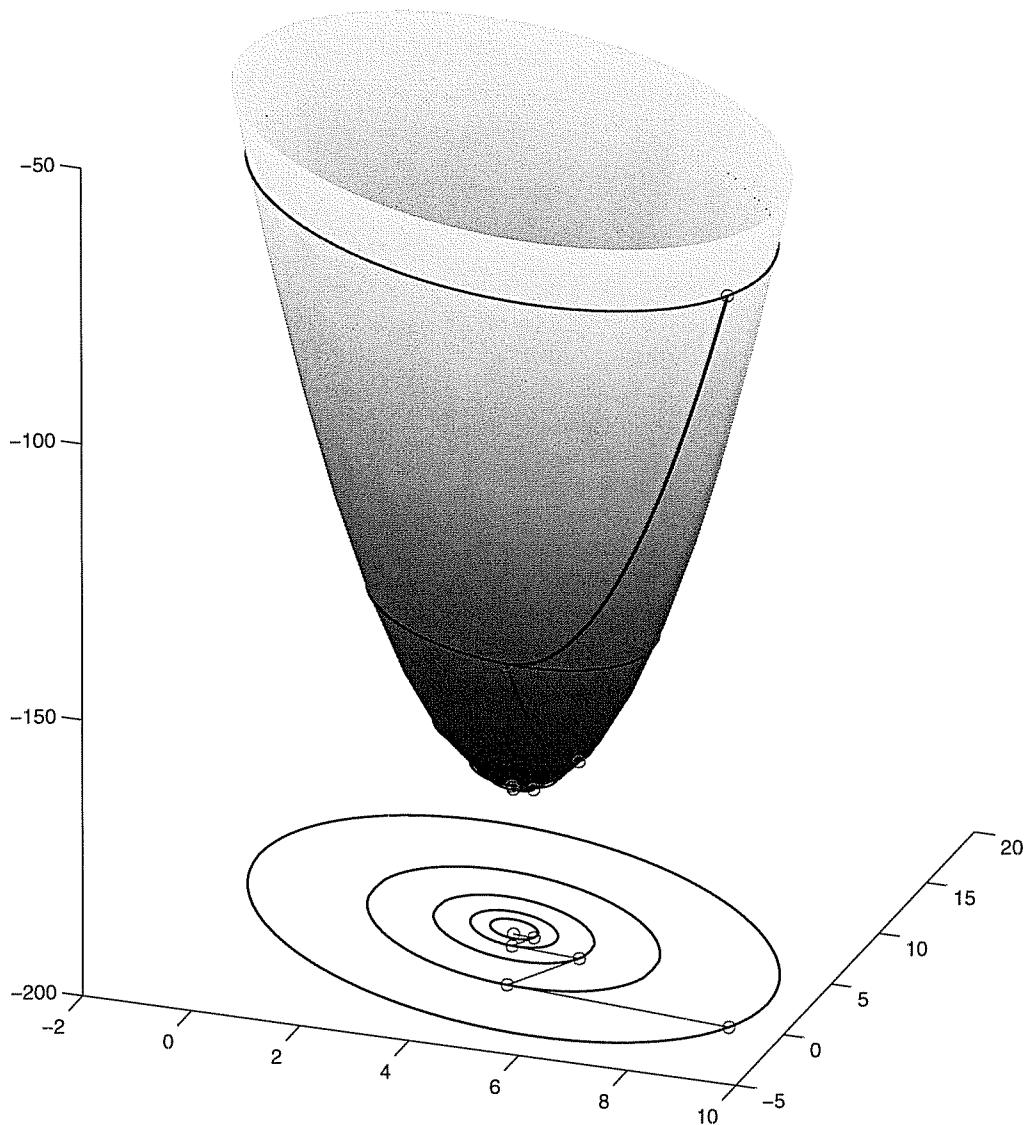
$$e^{(k+1)T} A e^{(k+1)} \leq q \cdot e^{(k)T} A e^{(k)} \quad \forall k$$

$$\Rightarrow \lim_{k \rightarrow \infty} e^{(k+1)T} A e^{(k+1)} = 0 \Rightarrow \boxed{\lim_{k \rightarrow \infty} \|e^{(k)}\| = 0}$$

# GEOMETRICKÝ VÝZNAM METODY NEJVĚTŠÍHO SPÁDU



# GEOMETRICKÝ VÝZNAM METODY NEJVĚTŠÍHO SPÁDU VE 3D



Pro soustavu dvou rovnic si opět lze udělat geometrickou představu. 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:** Dokažte, že platí  $\mathbf{d}^{(k)T} \mathbf{d}^{(k+1)} = 0$

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

**Poznámka:** V případě, že budou hladiny (elipsy) „velmi protáhlé“, bude 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 odstraňuje 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.

určit první příklad

$$A = \begin{bmatrix} 25 & 0 \\ 0 & 16 \end{bmatrix} \quad b = \begin{bmatrix} 25 \\ 8 \end{bmatrix}$$

jedna je kružnice:

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

poměr polos:

$$\frac{\sqrt{\lambda_2}}{\sqrt{\lambda_1}} = \frac{\sqrt{16}}{\sqrt{25}} = \frac{4}{5}$$

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

Použití:  
• Pro případ  $\lambda_2 \gg \lambda_1$   
kružnice protáhlé / elipsy

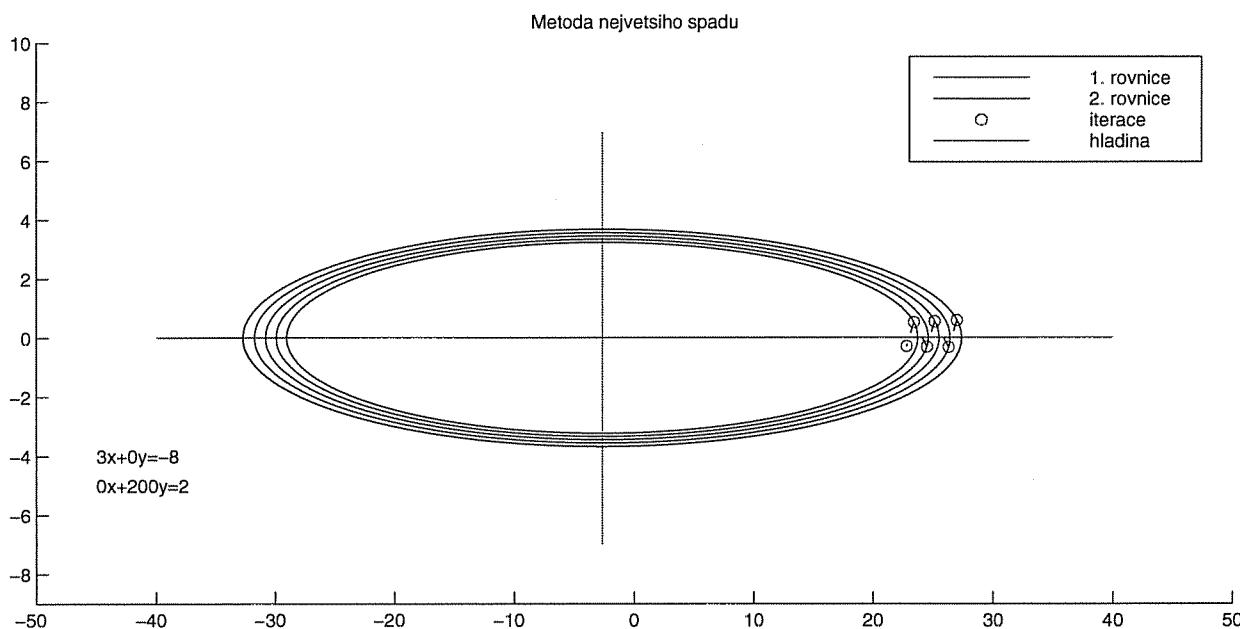
• Pro případ  $\lambda_2 \approx \lambda_1$   
kružnice skoro kružnice

**Příklad 1.** Pomocí metody největšího spádu řešte soustavu

$$3x + 0y = -8$$

$$0x + 200y = 2$$

Jako počáteční approximaci volte  $x^{(0)} = 27$ ,  $y^{(0)} = 0.6$ .



$k$	$x^{(k)}$	$y^{(k)}$
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
:	:	:
250	-2.657606	0.010180

(Přesné řešení soustavy je  $[\tilde{x}, \tilde{y}] = \left[ -\frac{8}{3}, \frac{1}{100} \right]$ .)

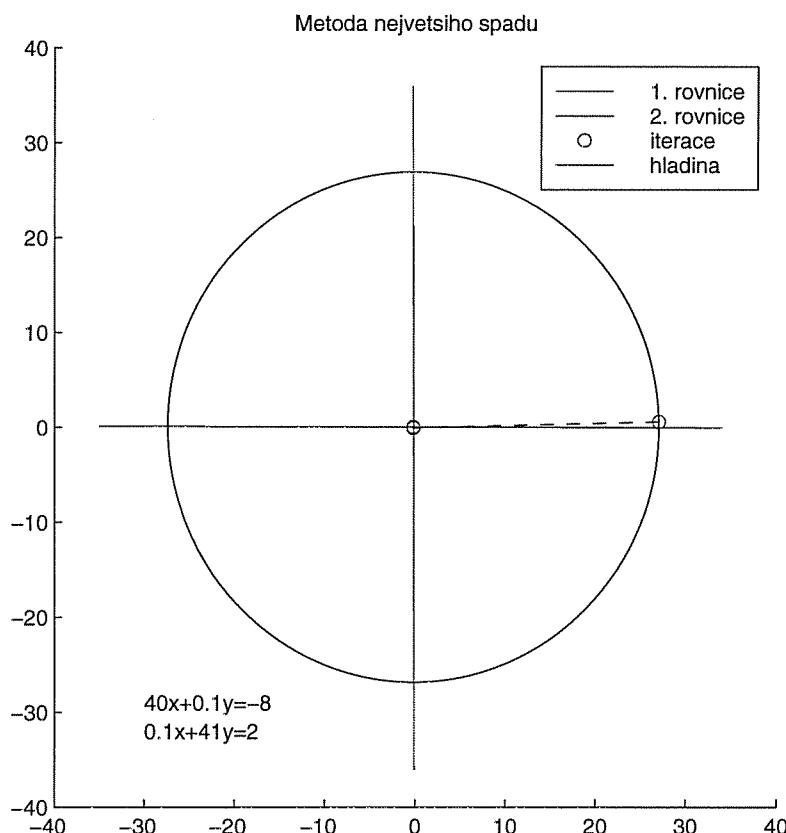
$$\lambda_1 = 3$$

$$\lambda_2 = 200$$

**Příklad 2.** Pomocí metody největšího spádu řešte soustavu

$$\begin{aligned} 40x + 0.1y &= -8 \\ 0.1x + 41y &= 2 \end{aligned}$$

Jako počáteční approximaci volte  $x^{(0)} = 27$ ,  $y^{(0)} = 0.6$ .



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

(Přesné řešení se na 6 desetiných míst shoduje s  $[x^{(3)}, y^{(3)}]$ .)

$$\lambda_1 \doteq 39,99$$

$$\lambda_2 \doteq 41,01$$

Pomáhaj:

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

- Je-li  $\alpha(A) > 1$ , tj.  $\lambda_{\max} \rightarrow \lambda_{\min}$ , pak

metoda největšího spádu konverguje pomalu

$$\frac{\alpha(A) - 1}{\alpha(A) + 1} = \frac{\alpha(A) - 1 + 1 - 1}{\alpha(A) + 1} = 1 - \frac{2}{\alpha(A) + 1} \underset{\alpha(A) \rightarrow \infty}{\approx} 1$$

$$0 \quad (\alpha(A) \rightarrow 0)$$

- Je-li  $\alpha(A) \approx 1$ , tj.  $\lambda_{\max} \approx \lambda_{\min}$ , pak

metoda největšího spádu konverguje rychle

$$\frac{\alpha(A) - 1}{\alpha(A) + 1} = 1 - \frac{2}{\alpha(A) + 1} \underset{\alpha(A) \rightarrow 1}{\approx} 0$$

- Pokud jsou vektorové sféry ( $\pi R^2$  hranice), potom metoda největšího spádu našme řešení ('prům.') v jednom kroku.

Poznámka: Tím, vektorém prováděme minimizaci  
v rámci jehož složek může být i jízda  
než měr největšho způsobu. Označme ho  $\alpha^{(k)}$

$$\boxed{x^{(k+1)} = x^{(k)} + \lambda \cdot \alpha^{(k)}}$$

$$\boxed{\min_{\lambda > 0} F(x^{(k)} + \lambda \alpha^{(k)})}$$

$$\underline{F(\lambda)} = \frac{1}{2} (x^{(k)} + \lambda \alpha^{(k)})^T A (x^{(k)} + \lambda \alpha^{(k)}) - b^T (x^{(k)} + \lambda \alpha^{(k)})$$

$$\frac{d \underline{F(\lambda)}}{d \lambda} = \lambda \alpha^{(k)T} A \alpha^{(k)} + \underbrace{\cancel{x^{(k)T} A \alpha^{(k)}} - b^T \alpha^{(k)}}_{\left( x^{(k)T} A - b^T \right) \alpha^{(k)}} = 0$$

$$(A x^{(k)} - b)^T \dots \text{residue} \quad r^{(k)}$$

$$\boxed{\lambda^{(k)} = \frac{-r^{(k)T} \alpha^{(k)}}{\alpha^{(k)T} A \alpha^{(k)}}}$$

- Voleme-li za vektor  $\alpha^{(k)}$  postupme —  
jednotkové vektory soudružích os, různé  
Gauss-Seidelovu metodu !!!

```

>> gs_gm;

A =
    8      3      2
    3      6      1
    2      1      7

b =
  20
  18
  25

x0 =
  0
  0
  0

vysledky_gs =
    0      0      0
  2.5000  1.7500  2.6071
  1.1920  1.9695  2.9495
  1.0241  1.9964  2.9936
  1.0029  1.9996  2.9992
  1.0004  2.0000  2.9999
  1.0000  2.0000  3.0000
  1.0000  2.0000  3.0000
  1.0000  2.0000  3.0000

vysledky_gm =
    0      0      0
  2.5000  1.7500  2.6071
  1.1920  1.9695  2.9495
  1.0241  1.9964  2.9936
  1.0029  1.9996  2.9992
  1.0004  2.0000  2.9999
  1.0000  2.0000  3.0000
  1.0000  2.0000  3.0000
  1.0000  2.0000  3.0000

>> vysledky_gs-vysledky_gm
  1.0e-15 *
    0      0      0
    0      0      0
    0      0.2220  0
 -0.4441  0.2220  -0.4441
  0.2220  -0.4441  0.4441
  0.2220  -0.4441  0.4441
    0     -0.2220  0
  0.2220      0      0
    0      0      0

```

>>

ÚVAHA: Při vhodné/volné směrové  
vektoru  $\alpha^{(k)}$  je možné slojit do přeměny  
řešení na konečný počet kroků  $\leq m$   
Musí existovat n vektory  $\alpha^{(k)}$  tak, že

$$x^* - x^{(0)} = \sum_{k=1}^m \lambda^{(k)} \alpha^{(k)} \quad (1)$$

? Jak volit směr  $\alpha^{(k)}$ ?

- Základní náplň: nechť  $\alpha^{(k)}$  jsou vektory (orthogonální)  
n-rozměrného euklidovského prostoru, potom  
výhodou využití (1) je skladatelnost  $\alpha^{(k)}$  a správná  
náhláška

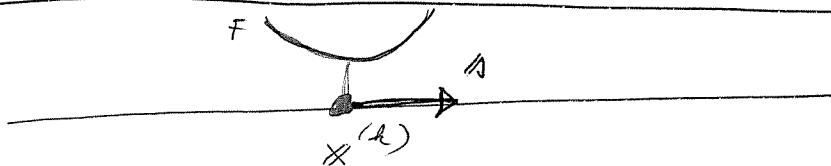
$$\alpha^{(k)\top} (x^* - x^{(0)}) = \lambda^{(k)} \alpha^{(k)\top} \alpha^{(k)}$$

$$\lambda^{(k)} = \frac{\alpha^{(k)\top} (x^* - x^{(0)})}{\alpha^{(k)\top} \alpha^{(k)}} \quad \dots \text{nesítrovně!}$$

- Je třeba zvolit lepší strategii volby vektoru  $\alpha^{(k)}$

Definice  $\mathbf{x}^{(k)}$  je optimální vzhledem k směru  $\mathbf{p} \neq 0$ ,  
ještě když

$$F(\mathbf{x}^{(k)}) \leq F(\mathbf{x}^{(k)} + \lambda \cdot \mathbf{p}) \quad \forall \lambda \in \mathbb{R}$$



Pom: Je-li  $\mathbf{x}^{(k)}$  optimální vzhledem k libovolnému směru  $\mathbf{p}$  vektorového prostoru  $V$ , třeba, že je  $\mathbf{x}^{(k)}$  optimální vzhledem k  $V$ .

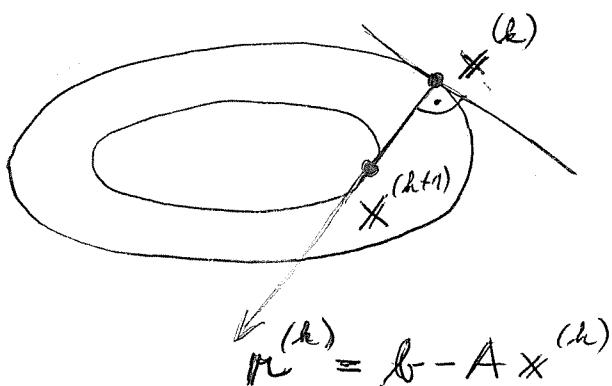
→ minima se nalyhá pro  $\lambda = 0$ , tzn. že derivace  $F$  podle  $\lambda$  je v minima ( $\lambda = 0$ ) rovna 0:

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

$$\frac{\partial F}{\partial \lambda} (\mathbf{x}^{(k)}) = \mathbf{p}^T (\underbrace{\mathbf{A} \mathbf{x}^{(k)} - \mathbf{b}}_{\mathbf{r}^{(k)} \dots \text{residuum}}) = 0$$

$$\boxed{\mathbf{p} \perp \mathbf{r}^{(k)}}$$

Poznámka: Kterací  $\mathbf{x}^{(k+1)}$  metody největšího směru je optimální vzhledem k residuum  $\mathbf{r}^{(k)} \dots$  směru, ve kterém minimalizuje.



Násím cílem je, aby se i v dalsích krokacích rachovatelských optimalitách k řízení povídaly mezi sebou. To pro metodu největšího spádu bude třeba nechat.

(např. pro soustavu  $n \times 2D$  jsme uvažovali, že směr největšího spádu (nominální) jde na sebe kolmo, tj.  $\mathbf{r}^{(k)} \perp \mathbf{r}^{(k+1)}$  a  $\mathbf{r}^{(k+1)} \perp \mathbf{r}^{(k+2)}$ )

$$\Rightarrow \boxed{\mathbf{r}^{(k)} \parallel \mathbf{r}^{(k+2)}} \quad \dots \dots \dots$$

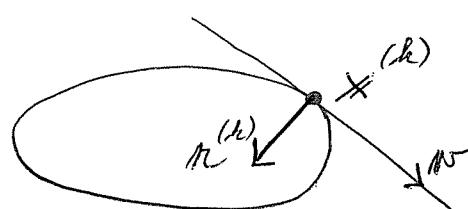
$\mathbf{x}^{(k+2)}$  je optimální vršekeden k  $\mathbf{r}^{(k+1)}$ , ale již není optimální vršekeden k  $\mathbf{r}^{(k)}$

? Existuje směr, který "máruje" optimální vršekeden?

Neckl -

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

Předpokládejme, že  $\mathbf{x}^{(k)}$  je optimální vršekeden k  $\mathbf{r}^{(k)}$  ( $A_j \cdot \mathbf{r}^{(k)} \perp \mathbf{r}^{(k)}$ )



Chceme-li, aby bylo  $\mathbf{x}^{(k+1)}$  optimální vršekeden k  $\mathbf{r}^{(k+1)}$ , ( $A_j \cdot \mathbf{r}^{(k+1)} \perp \mathbf{r}^{(k+1)}$ ), musí platit:

$$\begin{aligned} 0 &= \mathbf{r}^{(k)} \cdot \mathbf{r}^{(k+1)} = \mathbf{r}^{(k)} \cdot (\mathbf{b} - A \cdot \mathbf{x}^{(k+1)}) = \mathbf{r}^{(k)} \cdot (\mathbf{b} - A(\mathbf{x}^{(k)} + \Delta)) = \\ &= \mathbf{r}^{(k)} \cdot (\underbrace{\mathbf{b} - A \cdot \mathbf{x}^{(k)}}_{\mathbf{r}^{(k)}} - A \Delta) = \mathbf{r}^{(k)} \cdot (\mathbf{r}^{(k)} - A \Delta) = \boxed{-\mathbf{r}^{(k)} \cdot A \Delta} \end{aligned}$$

Záver: Keene - h' rechovat optimální všechny  
ke všem použitým mezin, musí byt' mezi  
optimální rovniny sv. A-orthogonality, tj.  
pro 2 mezin' mezi  $\pi$  a  $\pi'$  musí platit:

$$\pi^T A \pi' = 0$$

Pozn: Vektorem, který jde A-orthogonalní se  
kole' něha' A-schuné!

## Metoda sbránízí oh graidentu

Za směr, ve který oh minimální je můžeme brát  
A-ortogonální vektory  $\alpha^{(k)}$ . Platí tedy:

$$\boxed{\alpha^{(k)T} A \alpha^{(l)} = 0 \quad k \neq l}$$

Cheze, aby platilo:

$$\alpha^{(k)T} A . / \boxed{x^* - x^{(0)} = \sum_{k=1}^n \lambda^{(k)} \alpha^{(k)}} \quad (1)$$

$$\alpha^{(k)T} A \underbrace{(x^* - x^{(0)})}_{\lambda^{(k)}} = \lambda^{(k)} \cdot \alpha^{(k)T} A \alpha^{(k)}$$

$$A x^* - A x^{(0)} = \underbrace{A x^* - b}_{= 0} - \underbrace{A x^{(0)} + b}_{= \mu^{(0)}} = 0$$

$$\boxed{\lambda^{(k)} = - \frac{\alpha^{(k)T} \alpha^{(0)}}{\alpha^{(k)T} A \alpha^{(k)}}}$$

## Strategie volby směru

- máme-li ortogonální bázi  $R^n$ , lze s ním procesem A-ortogonalizace získat A-ortogonální bázi.
- každou ortogonální bázi můžeme volit vektorové/reidkové/vektory (aby proces ortogonalizace vedl k cíli, musíme ráznit, že vektorové/vektory tvorí bázi). Orthonormalita ukážeme náspečkou, když ne stál, že se některé vektorové vektory sčítají. Potom ovšem iterativní proces končí - doložili jsme původní řešení.)
- Provádime tedy současné 2 procesy!
  - iterativní proces
  - proces A-ortogonalizace
- vektorové/reidkové vektory můžeme znázít  $\mu^{(k)}$   
získané sdružené směry označíme  $\alpha^{(k)}$ 
  - pro zadání  $\mathbf{x}^{(0)}$  můžeme  $\mathbf{r}^{(0)} = \mathbf{b} - \mathbf{A}\mathbf{x}^{(0)}$
  - $\mathbf{r}^{(0)}$  položme rovnou  $R^{(0)}$
  - můžeme  $\mathbf{x}^{(1)}$  optimální vzhledem k  $\mathbf{r}^{(0)}$
  - můžeme  $\mathbf{r}^{(1)}$
  - $\mathbf{r}^{(1)}$  můžeme r  $\mathbf{r}^{(0)}$  tak, aby  $\underline{\alpha^{(1)T} A \alpha^{(0)}} = 0$
  - :  
:

## Proces A-ortogonalizace:

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

(Pracovní vektor  $\mathbf{v}^{(k)}$  výjde ze vektoru  $\mathbf{r}^{(k)}$ . Buďťme mimořádně předchozích)  
 $\mathbf{s}^{(i)}$  tak, aby obecnou rovnici A-ortogonalitu

$\beta_{ki}$  volné lze, aby

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

(•) využíváme  $\mathbf{s}^{(i)\top} A \mathbf{v}$ ,

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

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

→ 2 vlastnosti A-ortogonality využívá řada shněkostí:

Věta ① Platí:

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

DK:

$$-b_0 / A \cdot / \quad \mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \lambda^{(k)} \mathbf{s}^{(k)}$$

$$\Rightarrow \mathbf{r}^{(k+1)} = \mathbf{r}^{(k)} + \lambda^{(k)} A \mathbf{s}^{(k)}$$

$$\Rightarrow \mathbf{r}^{(k)} = \mathbf{r}^{(0)} + \sum_{j=1}^{k-1} \lambda^{(j)} A \mathbf{s}^{(j)}$$

využíváme  
shluky  $\rightarrow \mathbf{s}^{(j)}$

$$\mathbf{r}^{(k)\top} \cdot \mathbf{s}^{(j)} = \mathbf{r}^{(0)\top} \cdot \mathbf{s}^{(j)} + \lambda^{(j)} \mathbf{s}^{(j)\top} A \mathbf{s}^{(j)}$$

počítáme podle  $\lambda^{(j)} = \frac{\mathbf{r}^{(0)\top} \cdot \mathbf{s}^{(j)}}{\mathbf{s}^{(j)\top} A \mathbf{s}^{(j)}}$

nic dívej

Věta ② Platí:

$$\begin{aligned} \alpha^{(j)\top} A r^{(k)} &= 0 & j > k \\ \alpha^{(j)\top} A r^{(i)} &= \alpha^{(j)\top} A \alpha^{(i)} \end{aligned}$$

DK: vektory  $\alpha^{(0)}$  vymážouších slouží  $A \alpha^{(k)}$

$$\alpha^{(j)\top} A \alpha^{(k)} = \alpha^{(j)\top} A r^{(k)} + \sum_{i=1}^{k-1} \beta_{ki} \alpha^{(i)\top} A \alpha^{(i)}$$

pokud  $k < j$ :

$$= 0$$

pokud  $k = j$ :

$$\begin{array}{c} \downarrow \\ = 0 \\ \downarrow \\ = 0 \end{array}$$



Věta

Nekdyž  $r^{(k)}$  je s vektorem  $r^{(j)}$  ortogonální.

DK: napomíne indukci' vektoru  $r^{(k)}$

$$\boxed{\alpha^{(j)\top} r^{(k)} = 0 \quad \forall j > k}$$

$$1) \boxed{j=1} \quad \alpha^{(1)\top} \alpha^{(0)} = (\alpha^{(0)} + \lambda^{(0)} A \alpha^{(0)})^\top \alpha^{(0)} = \alpha^{(0)\top} \alpha^{(0)} + \lambda^{(0)\top} \alpha^{(0)} A \alpha^{(0)}$$

$$= \alpha^{(0)\top} \alpha^{(0)} - \frac{\alpha^{(0)\top} \alpha^{(0)}}{\alpha^{(0)\top} A \alpha^{(0)}} \alpha^{(0)\top} A \alpha^{(0)} = 0 \quad (\lambda^{(0)} = \alpha^{(0)})$$

$$2) \boxed{k < j} \text{ platí: } ? \quad \boxed{\alpha^{(j+1)\top} r^{(k)} = 0} ?$$

$$\alpha^{(j+1)\top} r^{(k)} = (\alpha^{(j)} + \lambda^{(j)} A \alpha^{(j)})^\top r^{(k)} = \underbrace{\alpha^{(j)\top} r^{(k)}}_{\text{(předpoklad)}} + \underbrace{\lambda^{(j)\top} \alpha^{(j)} A r^{(k)}}_{= 0} \quad (\text{věta ②})$$

$$b) ? \quad \boxed{\alpha^{(j+1)\top} \cdot \alpha^{(j)} = 0} ?$$

$$\begin{aligned} \alpha^{(j+1)\top} \alpha^{(j)} &= (\alpha^{(j)} + \lambda^{(j)} A \alpha^{(j)})^\top \alpha^{(j)} = \alpha^{(j)\top} \alpha^{(j)} + \lambda^{(j)\top} \alpha^{(j)} A \alpha^{(j)} \\ &= \alpha^{(j)\top} \alpha^{(j)} - \cancel{\frac{\alpha^{(j)\top} \alpha^{(j)}}{\alpha^{(j)\top} A \alpha^{(j)}} \alpha^{(j)\top} A \alpha^{(j)}} = 0 \quad (\text{věta ②}) \end{aligned}$$



Veta ③ Pro koeficienty  $\beta_{ki}$  je A-ortogonalizace plati' že

$$\boxed{\begin{aligned}\beta_{ki} &= 0 \quad \forall i < k-1 \\ \beta_{k,k-1} &\neq 0\end{aligned}}$$

(A) pri ortogonalizaci stací k  $\underline{n}^{(k)}$  přidat pouze  $\beta_{k,k-1}$  násobek  $\underline{s}^{(k-1)}$ , A-ortogonalita k přidruženém  $\underline{n}^{(i)}$ ,  $i < k-1$  je automaticky zaručena.)

Dle: plati':

$$\beta_{ki} = -\frac{\underline{n}^{(i)T} A \underline{n}^{(k)}}{\underline{n}^{(i)T} A \underline{n}^{(i)}}$$

$$= \underline{n}^{(k)T} \underbrace{A \underline{n}^{(i)}}_{\perp} = \underline{n}^{(k)T} \cdot \frac{1}{\lambda^{(i)}} \cdot (\underline{n}^{(i+1)} - \underline{n}^{(i)})$$

$$\neq 0 \text{ pro } \underline{n}^{(i)} \neq 0$$

$$\underline{n}^{(i+1)} = \underline{n}^{(i)} + \lambda^{(i)} A \underline{n}^{(i)}$$

pro  $i < k-1$ :

$$\text{číta se } \beta_{ki} = \underline{n}^{(k)T} \left( \underline{n}^{(i+1)} - \underline{n}^{(i)} \right) \cdot \frac{1}{\lambda^{(i)}} = 0$$

pro  $i = k-1$ :

$$\text{číta se } \beta_{k,k-1} = \underline{n}^{(k)T} \left( \underline{n}^{(k)} - \underline{n}^{(k-1)} \right) \frac{1}{\lambda^{(k-1)}} \neq 0$$

$$\text{pro } \underline{n}^{(k)} \neq 0$$



# ALGORITHMUS METODY SDRUŽENÝCH

## GRADIENTU<sup>o</sup>

$$1) \quad x^{(0)}$$

$$2) \quad r^{(0)} = A x^{(0)} - b, \quad \Delta^{(0)} = r^{(0)}$$

$$3) \quad \lambda^{(k)} = - \frac{r^{(k)T} \cdot r^{(k)}}{r^{(k)T} A r^{(k)}}$$

$$4) \quad x^{(k+1)} = x^{(k)} + \lambda^{(k)} \Delta^{(k)}$$

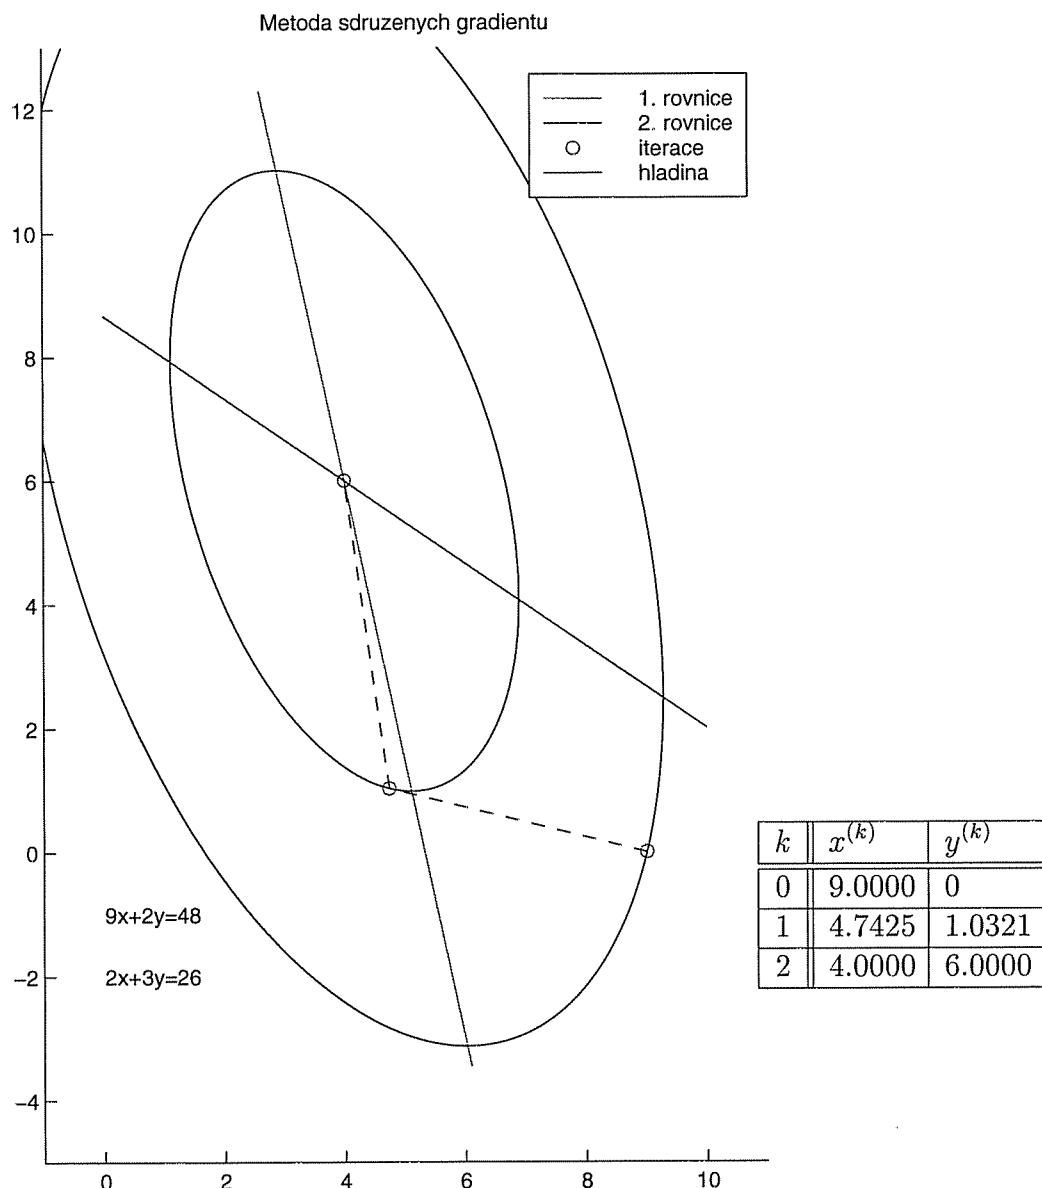
$$5) \quad r^{(k+1)} = r^{(k)} + \lambda^{(k)} A \Delta^{(k)}$$

$$6) \quad \beta_k = - \frac{\Delta^{(k)T} A r^{(k+1)}}{\Delta^{(k)T} A \Delta^{(k)}}$$

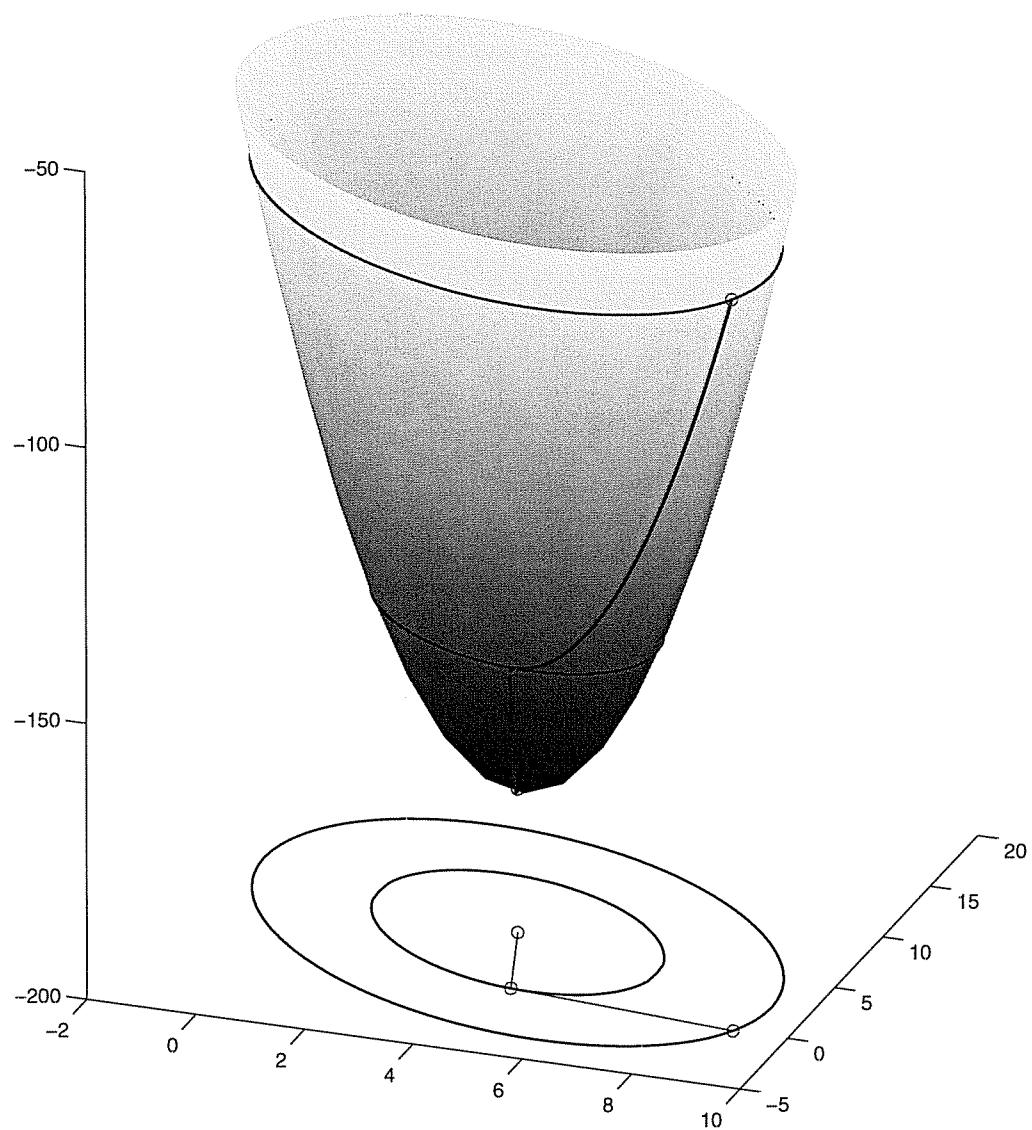
$$7) \quad \Delta^{(k+1)} = r^{(k+1)} + \beta_k \cdot \Delta^{(k)}$$

8) IF  $\|x^{(k+1)} - x^{(k)}\| < \varepsilon$  THEN KONEC  
 ELSE —

# GEOMETRICKÝ VÝZNAM METODY SDRUŽENÝCH GRADIENTŮ



# GEOMETRICKÝ VÝZNAM METODY SDRUŽENÝCH GRADIENTŮ VE 3D



Poznámka Gradientní metody patří mezi  
nестаціонарні методи

napište metodu největšího snížení:

$$\begin{aligned}
 \boxed{x^{(k+1)}} &= x^{(k)} + \lambda^{(k)} d^{(k)} = \\
 &= x^{(k)} + \lambda^{(k)} (b - Ax^{(k)}) = \\
 &= \underbrace{(I - \lambda^{(k)} A)}_{H^{(k)}} x^{(k)} + \underbrace{\lambda^{(k)} b}_{g^{(k)}} //
 \end{aligned}$$

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

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

Veta

Mákt A je symetricka' positive definita'.

Potom metoda s obnovou'k' gradientu

konverguje nejrychle' na krocích.

Matice A byla k-k' iterace ( $k < n$ ) je

ortogonalni' na smeny  $\alpha^{(j)}$ ,  $j = 0, 1, \dots, k-1$  a  
platí:

$$\|x^{(k)} - x^*\|_A \leq \frac{2C^k}{1+C^{2k}} \|x^{(0)} - x^*\|_A$$

hde

$$C = \sqrt{\frac{\alpha(A) - 1}{\alpha(A) + 1}}, \quad \alpha(A) = \frac{\lambda_{\max}}{\lambda_{\min}}$$

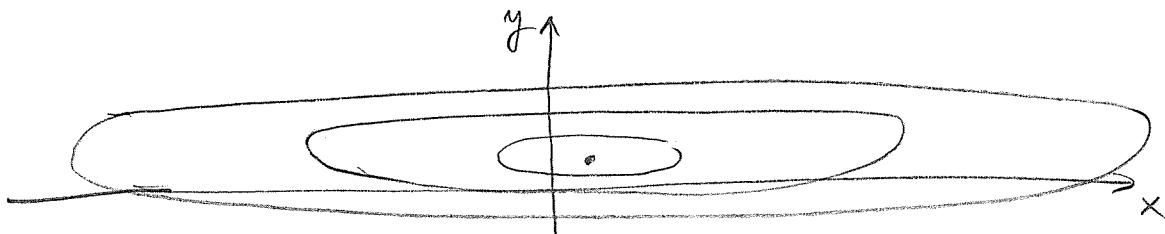
Tzn

N metoda nejrychle' rychle' vykupuje  
ve vztahu pro dily k-k' iterace koeficient

$$\left( \frac{\alpha(A) - 1}{\alpha(A) + 1} \right)^k$$

Je ruzne', re' ma rychlosť konvergencie  
ma' vliv čislo  $\alpha(A)$ , tj.  $\lambda_{\max}$  a  $\lambda_{\min}$   
čim bliži j'  $\lambda_{\max}$  a  $\lambda_{\min}$ , tím rychleji  
metoda konverguje'.

Príklad :  $A = \begin{bmatrix} 10000 & 0 \\ 0 & 1 \end{bmatrix}$   $b = \begin{bmatrix} 10000 \\ 1 \end{bmatrix}$   $x^* = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$



$\rightarrow$  pomer polos elipsy =  $\sqrt{10000} : \sqrt{1} = 100 : 1$  !!!

$\rightarrow \Re(A) = \frac{10000}{1} = 10000 \Rightarrow$  ponalo' konvergencia!

Terime si maticu  $P^{-1} = \begin{bmatrix} \frac{1}{10000} & 0 \\ 0 & 1 \end{bmatrix}$  ( $\det(P) \neq 0$ )

a řešme soustavu

$$\boxed{P^{-1} A x = P^{-1} b}$$

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

$\rightarrow \Re(P^{-1}A) = \frac{1}{1} = 1 \Rightarrow$  rychla' konvergace (1. iterace)

Máme o nov. predpohľadovanie

Cháme-li ovšem i novou soustavu řešit metodom  
sobírující gradientu, musí být jíž matice  
symetrická/positivně definovaná. Níže máme  $P^{-\frac{1}{2}}A$   
verenou matice (podoba  $A$ )  $P^{-\frac{1}{2}}AP^{-\frac{1}{2}}$   
( $P$  - symetrická/positivně definovaná) a řešit  
soustavu

$$\boxed{\bar{A}\bar{x} = \bar{b}}$$

$$\bar{A} = P^{-\frac{1}{2}}AP^{-\frac{1}{2}} \quad \bar{x} = P^{\frac{1}{2}}x \quad \bar{b} = P^{-\frac{1}{2}}b$$

? jak volit matice předpovídání  $P$ ?

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

A =

100000	200	30	4
200	10000	30	4
30	30	100	5
4	4	5	10

Vlastni cisla matice A

1.0e+05 \*

0.00009722475595  
0.00100176199725  
0.09999647672574  
1.00000453652105

Cislo podminenosti matice A

1.028549289437760e+04

Predpodminovaci matice

P =

100000	0	0	0
0	10000	0	0
0	0	100	0
0	0	0	10

P^(1/2) =

1.0e+02 \*

3.16227766016838 0 0 0  
0 1.00000000000000 0 0  
0 0 0.10000000000000 0  
0 0 0 0.03162277660168

P^(-1/2) =

0.00316227766017 0 0 0  
0 0.01000000000000 0 0  
0 0 0.10000000000000 0  
0 0 0 0.31622776601684

Matice predpodminene soustavy

new\_A =

1.00000000000000	0.00632455532034	0.00948683298051	0.00400000000000
0.00632455532034	1.00000000000000	0.03000000000000	0.01264911064067
0.00948683298051	0.03000000000000	1.00000000000000	0.15811388300842
0.00400000000000	0.01264911064067	0.15811388300842	1.00000000000000

Vlastni cisla matice predpodminene soustavy

1.16436435763202  
0.84084776216427  
0.99222963783997  
1.00255824236374

Cislo podminenosti pro matici predpodminene soustavy

1.38475049827695

>>