

### LU rozklad: $\mathbb{A}x = b$

- Provedeme rozklad  $\mathbb{A}$  na dolní ( $L$ ) a horní ( $U$ ) trojúhelníkovou matici. Volíme diagonálu  $\mathbb{L}$ ,  $l_{ii} = 1$ .

$$\mathbb{A} = \mathbb{L}U$$

- Řešíme soustavu

$$\mathbb{L}y = b$$

- Řešíme soustavu

$$Ux = y$$

### Norma matice a vektoru

- Řádková norma

$$\|\mathbb{A}\|_m = \max_i \sum_{j=1}^n |a_{i,j}| \qquad \|\vec{x}\|_m = \max_i |x_i|$$

- Sloupcová norma

$$\|\mathbb{A}\|_\ell = \max_j \sum_{i=1}^m |a_{i,j}| \qquad \|\vec{x}\|_\ell = \sum_{i=1}^n |x_i|$$

- Euklidovská norma

$$\|\mathbb{A}\|_E = \left( \sum_{i=1}^m \sum_{j=1}^n |a_{i,j}|^2 \right)^{\frac{1}{2}} \qquad \|\vec{x}\|_E = \left( \sum_{i=1}^n |x_i|^2 \right)^{\frac{1}{2}}$$

### Vlastnosti matice $\mathbb{A}$ :

- **ostře diagonálně dominantní** (ODD) v řádcích, pokud

$$|a_{ii}| > \sum_{j \neq i} |a_{ij}|, \quad \forall i$$

- **symetrická**, pokud  $\mathbb{A}^T = \mathbb{A}$

$$a_{ij} = a_{ji}$$

- **pozitivně definitní** pokud

$$a_{11} > 0, \left| \begin{array}{cc} a_{11} & a_{12} \\ a_{21} & a_{22} \end{array} \right| > 0, \left| \begin{array}{ccc} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{array} \right| > 0, \dots, \det \mathbb{A} > 0$$

- **spektrální poloměr** matice  $\mathbb{A}$  je číslo  $\rho(\mathbb{A})$  definované

$$\rho(\mathbb{A}) = \max\{|\lambda| : \lambda \text{ je vlastní číslo } \mathbb{A}\}$$

- spektrální poloměr a norma matice

$$\rho(\mathbb{A}) \leq \|\mathbb{A}\|$$

### Prostá iterační metoda

$$\text{Soustava zapsaná ve tvaru: } x = \mathbb{U}x + V,$$

$$\text{Iterační metoda: } X^{(k+1)} = \mathbb{U}X^{(k)} + V,$$

- **Nutná a postačující podmínka:** Prostá iterační metoda je konvergentní právě tehdy, když  $\rho(\mathbb{U}) < 1$ .
- **Postačující podmínka:** Je-li  $\|\mathbb{U}\| < 1$ , pak prostá iterační metoda je konvergentní.
- Je-li  $\|\mathbb{U}\| < 1$ , pak

$$\|x^{(k)} - x^*\| \leq \frac{\|\mathbb{U}\|}{1 - \|\mathbb{U}\|} \|x^{(k)} - x^{(k-1)}\|,$$

$$\|x^{(k)} - x^*\| \leq \frac{\|\mathbb{U}\|^k}{1 - \|\mathbb{U}\|} \|x^{(1)} - x^{(0)}\|,$$

### Jacobiho iterační metoda

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

Maticový zápis ( $\mathbb{A} = \mathbb{L} + \mathbb{D} + \mathbb{P}$ )

$$x^{(k+1)} = \underbrace{-\mathbb{D}^{-1}(\mathbb{L} + \mathbb{P})}_{\mathbb{U}_J} x^{(k)} + \underbrace{\mathbb{D}^{-1}b}_{V_J}.$$

- **Nutná a postačující podmínka:** Jacobiho iterační metoda je konvergentní právě tehdy, když  $\rho(\mathbb{U}_J) < 1$ .
- **Postačující podmínka:** Je-li matice  $A$  ODD (v řádcích nebo sloupcích), pak Jacobiho iterační metoda je konvergentní.
- Vlastní čísla matice  $\mathbb{U}_J$  jsou kořeny rovnice

$$\det(\mathbb{L} + \lambda\mathbb{D} + \mathbb{P}) = 0$$

### Gauss-Seidelova iterační metoda

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right)$$
$$x^{(k+1)} = \underbrace{-(\mathbb{D} + \mathbb{L})^{-1} \mathbb{P}}_{\mathbb{U}_{GS}} x^{(k)} + \underbrace{(\mathbb{D} + \mathbb{L})^{-1} \mathbf{b}}_{V_{GS}}.$$

- **Postačující podmínka:** Je-li matice  $\mathbb{A}$  ODD, pak Gauss-Seidelova iterační metoda je konvergentní.
- **Postačující podmínka:** Je-li matice  $\mathbb{A}$  symetrická a zároveň pozitivně definitní, pak Gauss-Seidelova iterační metoda je konvergentní.
- **Nutná a postačující podmínka:** Gauss-Seidelova iterační metoda je konvergentní právě tehdy, když  $\rho(\mathbb{U}_{GS}) < 1$ .
- Vlastní čísla matice  $\mathbb{U}_{GS}$  jsou kořeny rovnice  $\det(\lambda \mathbb{L} + \lambda \mathbb{D} + \mathbb{P}) = 0$ .

### Gradientní metoda

- **Předpoklady:** Matice  $A$  symetrická a pozitivně definitní.  $F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbb{A} \mathbf{x} - \mathbf{x}^T \mathbf{b}$ .
- **Ekvivalence:**

$$(\mathbb{A} \mathbf{x}^* = \mathbf{b}) \quad \Leftrightarrow \quad (F(\mathbf{x}^*) \leq F(\mathbf{x}) \quad \text{pro libovolné } \mathbf{x}).$$

- **Gradientní metoda:**

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha \mathbf{p}$$

- **Volba směru (největší spád):**

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

- **Volba optimálního kroku ve směru  $\mathbf{p}$**

$$\alpha = \underset{\alpha}{\text{argmin}} F(\mathbf{x}^{(k)} + \alpha \mathbf{p}) = \frac{\mathbf{p}^T (\mathbf{b} - \mathbb{A} \mathbf{x}^{(k)})}{\mathbf{p}^T \mathbb{A} \mathbf{p}}$$

### Newtonova metoda

$$f(x, y) = 0, \quad g(x, y) = 0.$$

- Taylorův rozvoj resp. tečná rovina v bodě  $A = [x^{(k)}, y^{(k)}]$ .

$$0 = f(x^*, y^*) = f(A) + f_x(A)(x^* - x^{(k)}) + f_y(A)(y^* - y^{(k)}) + \dots$$

$$0 = g(x^*, y^*) = g(A) + g_x(A)(x^* - x^{(k)}) + g_y(A)(y^* - y^{(k)}) + \dots$$

- Pro přírůstek  $\Delta_x = (x^{(k+1)} - x^{(k)})$ ,  $\Delta_y = (y^{(k+1)} - y^{(k)})$  dostáváme

$$f_x(A)\Delta_x + f_y(A)\Delta_y = -f(A)$$

$$g_x(A)\Delta_x + g_y(A)\Delta_y = -g(A)$$

•

$$\begin{pmatrix} x^{(k+1)} \\ y^{(k+1)} \end{pmatrix} = \begin{pmatrix} x^{(k)} \\ y^{(k)} \end{pmatrix} + \begin{pmatrix} \Delta_x \\ \Delta_y \end{pmatrix}$$

**Interpolace polynomem** Tabulku  $(x_i, y_i)$  pro  $i = 0, \dots, n$  lze interpolovat polynomem

$$p(x) = a_0 + a_1x + a_2x^2 + \dots + a_nx^n$$

polynomem nejvýše stupně  $n$ , pokud  $x_i \neq x_j$  pro  $i \neq j$ .

Interpoláčnı polynom splıuje rovnice

$$p(x_i) = y_i \quad \text{pro } i = 0 \dots n.$$

### Aproximace pomocí metody nejmenších čtverců

- Polynom stupně 1 nebo 2:

$$p(x) = a_0 + a_1x, \quad \text{nebo} \quad p(x) = a_0 + a_1x + a_2x^2$$

- tabulka dat  $[x_i, y_i]$  - podmínky pro aproximaci.
- princip: minimalizujeme kvadratickou odchylku

$$G(a_0, a_1, a_2) := \delta^2(p(x)) = \sum_i (p(x_i) - y_i)^2$$

- odvození normálních rovnic

$$\frac{\partial G}{\partial a_k} = 0 \quad k = 0, 1, 2.$$

- soustava

$$a_0 \left( \sum_i 1 \right) + a_1 \left( \sum_i x_i \right) + a_2 \left( \sum_i x_i^2 \right) = \sum_i y_i,$$

$$a_0 \left( \sum_i x_i \right) + a_1 \left( \sum_i x_i^2 \right) + a_2 \left( \sum_i x_i^3 \right) = \sum_i x_i y_i,$$

$$a_0 \left( \sum_i x_i^2 \right) + a_1 \left( \sum_i x_i^3 \right) + a_2 \left( \sum_i x_i^4 \right) = \sum_i x_i^2 y_i,$$