

1. Základní pojmy

1.1. Matematický model

- formulace reálného problému pomocí matematiky

1.2. Matematická úloha

→ numerická úloha

- vztah mezi konečným počtem vstupních a výstupních dat

- konečnost je důležitá z hlediska počítačové řešitelnosti

1.3. Numerická metoda, algoritmus

- způsob, jak vypočítat formulovanou úlohu pomocí počítače

→ zabývá se numerická matematika

1.4. Korektní úloha

Úloha je korektní na dvojici prostorech (B_1, B_2) , když

a) ke každému $x \in B_1$ $\exists!$ $y \in B_2$

b) toto řešení sponitě závisí na vst. datech, tj. když

$$x_n \rightarrow x \wedge U(x_n) = y_n$$

potom

$$U(x_n) \rightarrow U(x) = y_n$$

1.5. Podmíněnost úlohy

- úloha je dobře podmíněná, pokud malá změna vst. dat způsobí relativně malou změnu dat výstupních

1.6. Číslo podmíněnosti

$$C_p = \frac{\frac{\|\Delta y\|}{\|y\|}}{\frac{\|\Delta x\|}{\|x\|}} \approx \frac{\delta(y)}{\delta(x)} \quad (= \frac{\text{rel. chyba na výst.}}{\text{rel. chyba na vst.}})$$

Zpravidla: $C_p \approx 1$ - dobře podmíněná úloha

$C_p \approx 100$ - špatně podmíněná úloha

1.7. Podmíněnost algoritmu

= citlivost na poruchu v datech (viz [1.5], [1.6])

1.8. Stabilita algoritmu

- Stabilita je dana:

a) podmíněnosti (viz [1.7.])

b) numerickou stabilitou

↳ = citlivost na vliv zaokrouhlovacích chyb

1.9. Příklady

1.9.1. Špatná podmíněnost

$$x^2 - 4x + 4 = 0 \quad ; \quad x_1 = x_2 = 2$$

$$x^2 - 4x + 3,9999 = 0 \quad ; \quad x_1 = 2,01 \quad x_2 = 1,99$$

porucha vstupu = $1 \cdot 10^{-4}$] => změna vstupu vyvolala 100x

porucha výstupu = $1 \cdot 10^{-2}$] větší změna výstupu

1.9.2. Numerická nestabilita

- při jednotlivých iteracích může špatnou volbou algoritmu dojít k tomu, že chyba výsledku přetoste jeho hodnotu

$$J_n = \int_0^1 \frac{x^n}{x+5} dx \quad n=0, 1, 2, \dots$$

$$\int_0^1 x^{n-1} dx = \int_0^1 \frac{x^n}{x+5} + 5 \cdot \int_0^1 \frac{x^{n-1}}{x+5} \rightarrow J_n = -5 \cdot J_{n-1} + \frac{1}{n}$$

→ počítáme-li ve 3D:

$$J_0 \approx 0,182 \quad (\ln \frac{6}{5})$$

$$J_1 \approx 0,090$$

$$J_2 \approx 0,050$$

$$J_3 \approx 0,083$$

$$J_4 \approx -0,165 \quad - \text{absurdní}$$

- příčina tkví v násobení, jelikož

společně s výsledkem předchozí

operace násobíme i jeho chybu

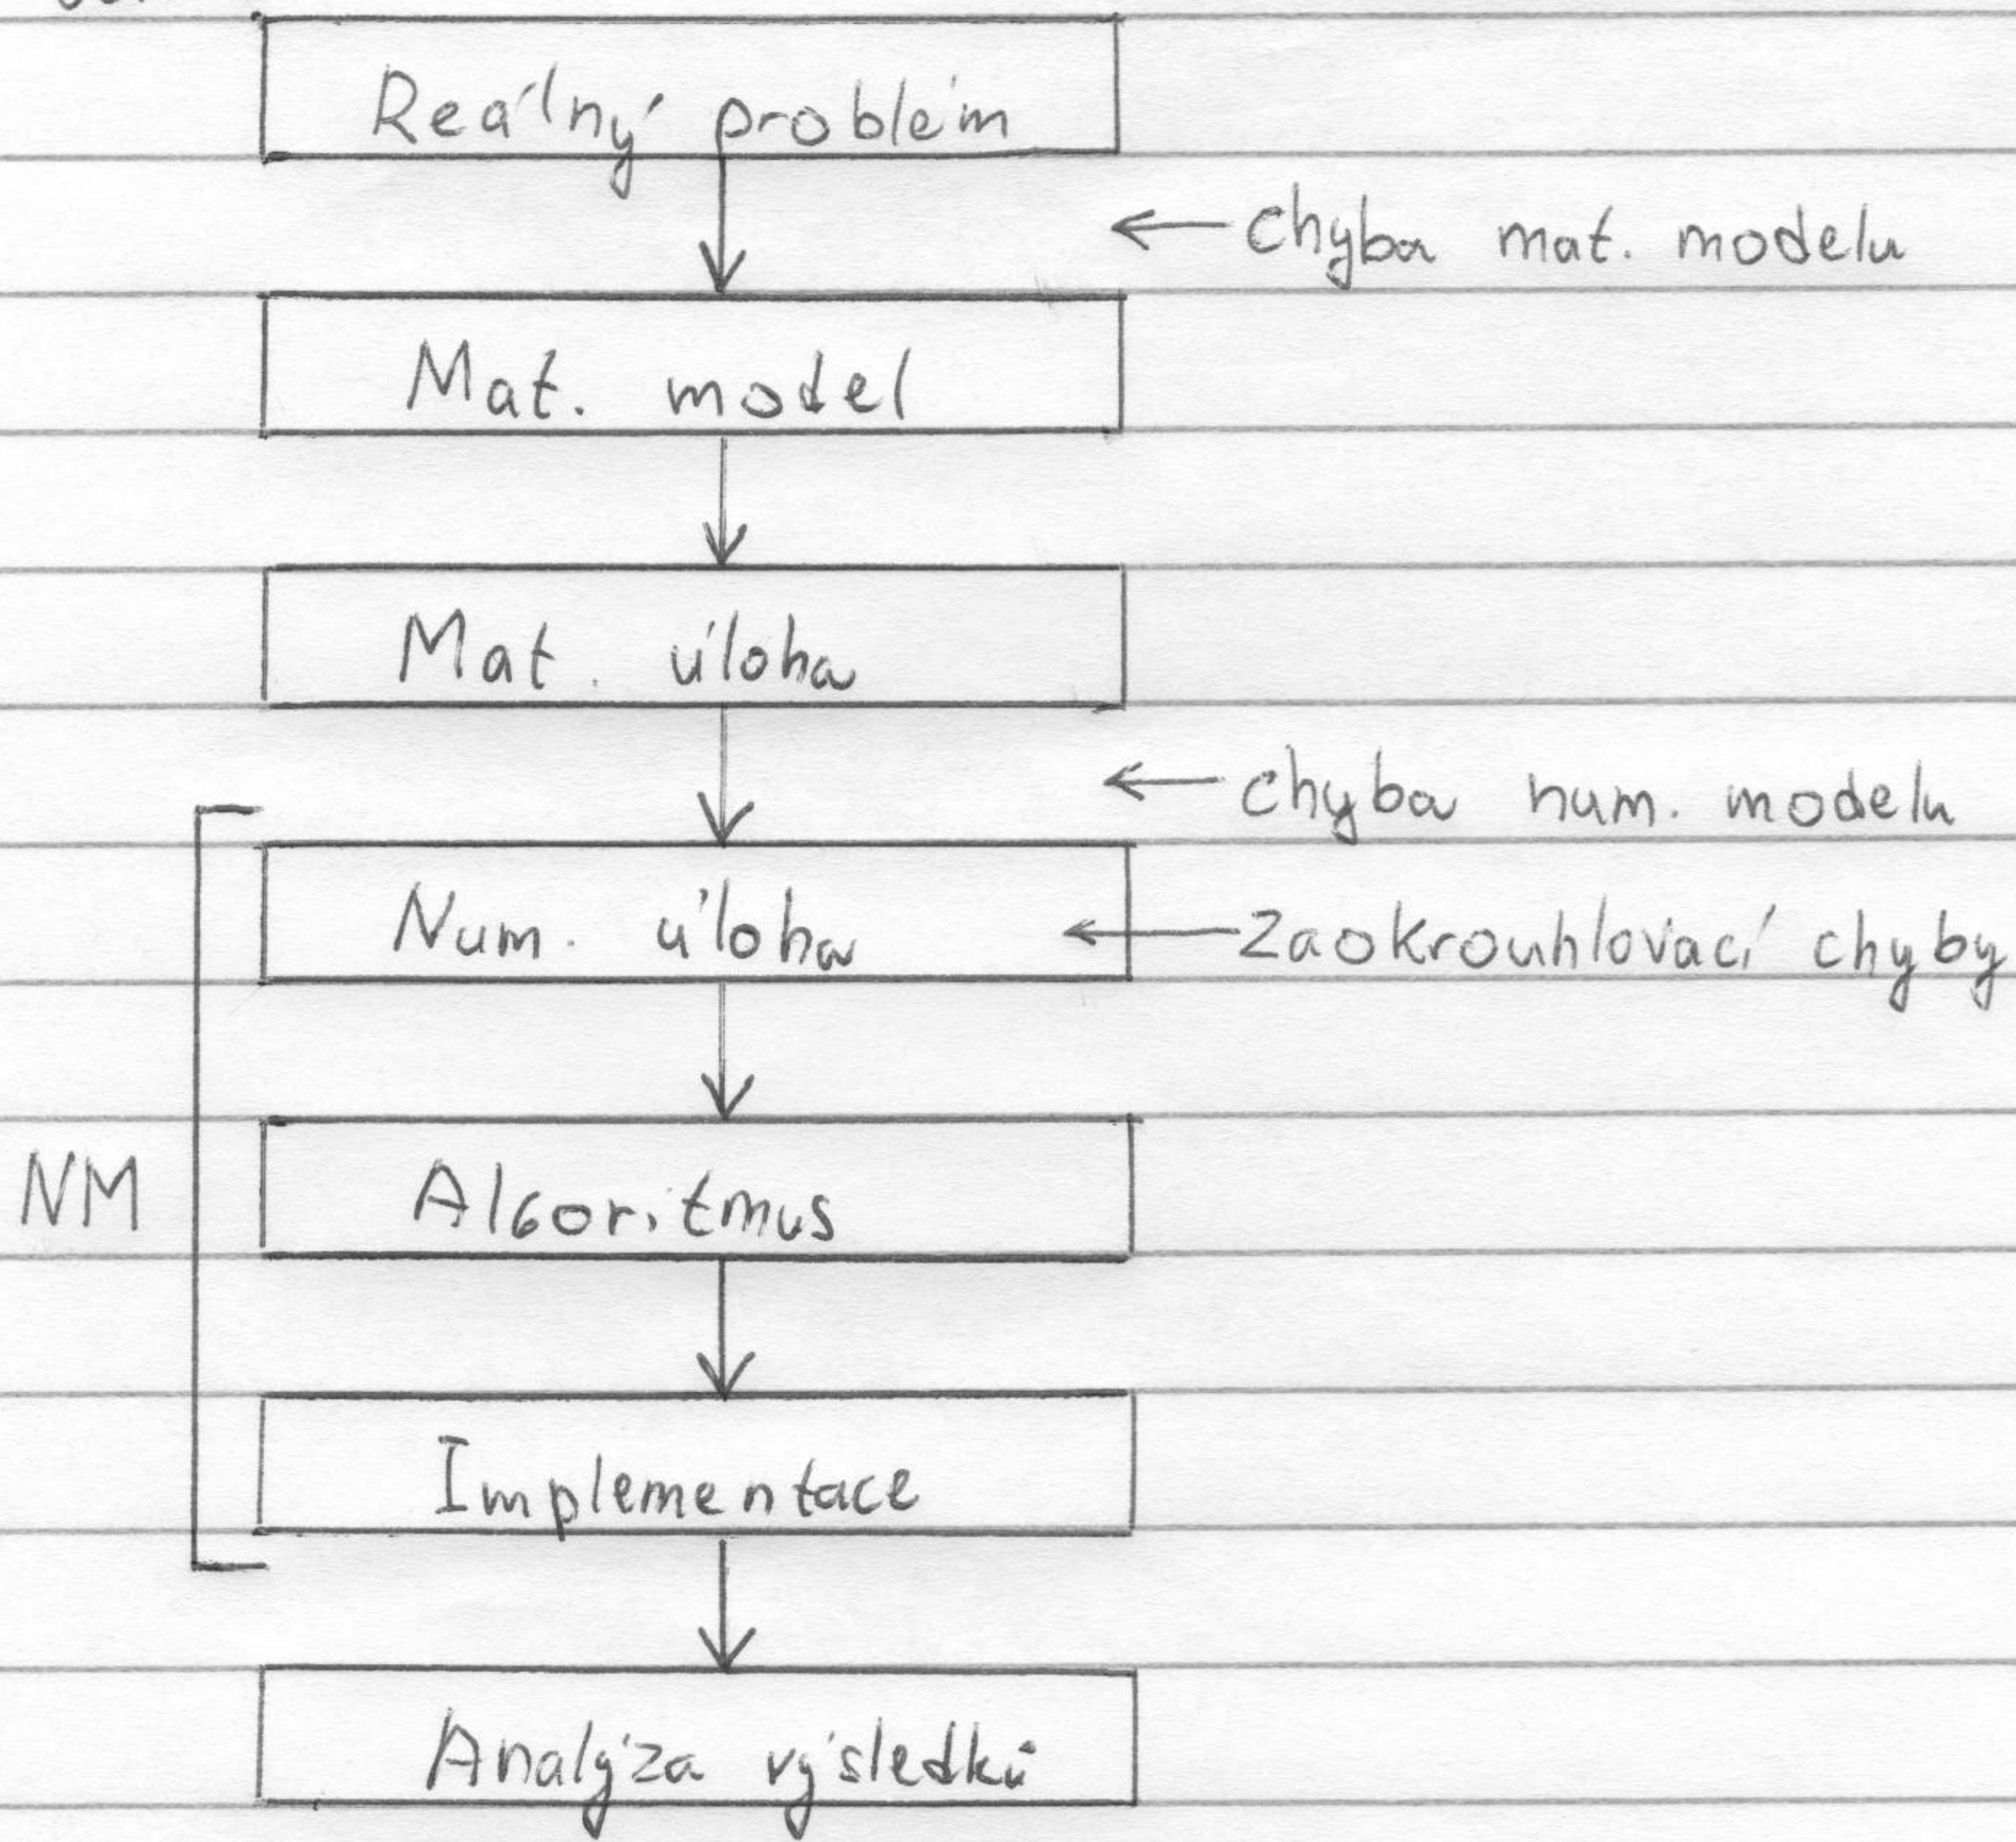
- řešením je stanovit hodnotu J_n pro

dostatečně velké n a provést

výpočet opačně, tj.

$$J_{n-1} = \frac{-J_n}{5} + \frac{1}{5n}$$

Obr. 1.



2. Řešení nelineárních rovnic

a jejich soustav

2.1. Metoda 'proste' iterace

- převedeme rovnici do iterčního tvaru:

$$x = \varphi(x)$$

- x se snažíme (v zájmu rychlosti konvergence, respektive obecně konvergence) vyjádřit z nejvyšší mocniny

- hledáme geometrický průsečík $f(x)$ a $\varphi(x)$

2.1.1. Podmínka konvergence

Předpokládáme, že $\varphi(x)$ je na $I := \langle a, b \rangle$ spojitá a platí

a) $\forall x \in I: \varphi(x) \in I$

- φ zobrazuje sama do sebe

b) $\exists q \in \langle 0, 1 \rangle: |\varphi(x) - \varphi(y)| \leq q \cdot |x - y| \quad \forall x, y \in I$

- kontrakce φ (viz [2.1.2])

2.1.2. Kontrakce

$$\left| \frac{\varphi(x_{k+1}) - \varphi(x_k)}{x_{k+1} - x_k} \right| < 1 \Rightarrow |\varphi'(x_k)| < 1$$

2.1.3. Odhad chyby

$$\exists q \in \langle 0, 1 \rangle: |\varphi'(x)| \leq q \quad \forall x \in I$$

$$|x_k - x^*| = |\varphi(x_{k-1}) - \varphi(x^*)| \leq q |x_{k-1} - x^*| \leq q \cdot |x_k - x_{k-1}| + q |x_k - x^*|$$

$$|x_k - x^*| \leq \frac{q}{1-q} \cdot |x_k - x_{k-1}|$$

2.1.3.1. Příklad

$$x^2 - 3x - 5 = 0 \rightarrow x = \sqrt{3x+5} \rightarrow \varphi(x) = \frac{3}{2} \cdot \frac{1}{\sqrt{3x+5}} \quad I = \langle 0, 10 \rangle \quad \varepsilon = 0,01$$

$$q = \max_{x \in \langle 0, 10 \rangle} \varphi'(x) = \varphi'(0) \doteq 0,67$$

$$x_5 = 4,1971 \approx x^*$$

$$|x_5 - x^*| \leq \frac{0,67}{1-0,67} \cdot \overbrace{|x_5 - x_4|}^{\leq 0,01} \leq 0,02$$

2.1.4. Rychlost konvergence

- Je-li φ dostatečně hladká:

$$\varphi(x) = \varphi(x^*) + \varphi'(x^*) \cdot (x - x^*) + \frac{\varphi''(x^*)}{2!} \cdot (x - x^*)^2 + \frac{\varphi'''(\xi)}{3!} \cdot (x - x^*)^3$$

$$\varphi(x_{k-1}) = x_k :$$

$$x_k - x^* = \varphi'(x^*) \cdot (x_{k-1} - x^*) + \frac{\varphi''(x^*)}{2} (x_{k-1} - x^*)^2$$

$$a) \varphi'(x^*) \neq 0 : r=1$$

$$b) \varphi'(x^*) = 0 ; \varphi''(x^*) \neq 0 : r=2$$

2.2. Newtonova metoda

$$f(x) = f(x_0) + f'(x_0) \cdot (x - x_0) + \frac{f''(\xi)}{2} (x - x_0)^2$$

chyba

$$f(x_0) + f'(x_0) \cdot (x - x_0) = 0$$

$$x = x_0 - \frac{f(x_0)}{f'(x_0)} \rightarrow$$

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$

$$; k=0, 1, 2, \dots$$

$$|x_{k+1} - x_k| < \varepsilon$$

zast. podmínka

- zpřesňující metoda, očekává

- na $\langle a, b \rangle$ leží jediný kořen x^*
- x_0 je relativně blízko x^*

2.2.1. Rychlost konvergence

$$\varphi'(x^*) = 0 : r=2$$

$$\varphi'(x^*) \neq 0 :$$

$$\varphi'(x) = 1 - \frac{(f'(x))^2 - f(x) \cdot f''(x)}{(f'(x))^2}$$

$$\varphi'(x^*) = 1 - \frac{f'(x^*)}{(f'(x^*))^2} \Rightarrow r=0$$

3. Příme' metody pro řešení SLAR

3.2. Učební úlohy

3.1. Gaussova eliminační metoda

- princip je převést matici na stupňovitý tvar
- nejednodušší (resp. nejjednodušší) metoda je určit multiplikační koeficienty každého řádku dle pivotního prvku, následně řádky vynásobit jejich součinem se součinem jejich multiplikačních koeficientů a prvního řádku a postup opakovat až do dosažení stupňovitého tvaru
- problém: metoda není obecně realizovatelná pro každou regulární matici, jelikož pivotní prvek může být 0, s čímž metoda nepočítá

G.m. je realizovatelná, pokud:

- a) matice A je ostře diagonálně dominantní
- nebo b) matice A je symetrická a poz. definitní

3.1.1. Pivotace

= výběr hlavního prvku

- podle typu pivotace vždy vybereme největší (v absolutní hodnotě) prvek a pomocí prohazování řádků jej umístíme na vhodné místo

- typy pivotace:

- řádková
- sloupcová
- úplná (kombinovaná)

- použitím libovolného typu pivotace dosáhneme řešitelnosti G. metodou pro libovolnou reg. matici

3.1.2. Zpětný chod

- po získání horní trojúhelníkové matice dosadíme hodnoty neznámých od konce a tím postupně získáme hodnotu všech

- počet operací = $\frac{N \cdot (N-1)}{2}$ dělení + $\frac{N^3 - N}{3}$ násobení
 $\frac{N^3 - N}{3}$ sčítání

3.2. LU rozklad

a) $A = L \cdot U$ - provedeme rozklad na dolni Δ matici L a horni ∇ matici U

$$L = \begin{pmatrix} 1 & 0 & 0 \\ l_{21} & 1 & 0 \\ l_{31} & l_{32} & 1 \end{pmatrix} \quad U = \begin{pmatrix} u_{11} & u_{12} & u_{13} \\ 0 & u_{22} & u_{23} \\ 0 & 0 & u_{33} \end{pmatrix}$$

b) vyřešime soustavu $L \cdot y = b$; ziskáme y

c) vyřešime soustavu $U \cdot x = y$; ziskáme řešení původní soustavy

- výhody především, pokud máme více soustav se stejnou maticí soustavy

- počet operací: $\frac{N^3}{3} + O(n^2)$ násobení, sčítání

$\frac{N \cdot (N-1)}{2}$ dělení

N^2 - opakované řešení

3.3. Choleského rozklad

- metoda rozložení symetrické, pozitivně definitní čtv. matice na dvě stejné

(po transpozici) matice, jejichž součin dává původní matici A :

$$A = L \cdot L^T \quad \text{popř.} \quad A = U^T \cdot U \quad ; \quad \text{kde } U = L^T$$

3.3.1. Výpočet inverzní matice

$$A^{-1} = (L^{-1})^T \cdot L^{-1}$$

3.3.2. Řešení SLAR

$$L \cdot y = b$$

$$L^T \cdot x = y$$

3.3.3. Algoritmus rozkladu

- počítáme po sloupcích (lze i po řádcích)

$$a_{11} = l_{11} \cdot l_{11} \rightarrow l_{11} = \sqrt{a_{11}}$$

$$a_{21} = l_{21} \cdot l_{11} \rightarrow l_{21} = a_{21} / l_{11}$$

- obecně:

$$a_{kk} = \sum_{i=1}^k l_{ki}^2 \rightarrow l_{kk} = \sqrt{a_{kk} - \sum_{i=1}^k l_{ki}^2} \quad \text{pro prvky na diagonále}$$

$$a_{rc} = \sum_{i=1}^c l_{ri} \cdot l_{ci} \rightarrow l_{rc} = \frac{a_{rc} - \sum_{i=1}^{c-1} l_{ri} \cdot l_{ci}}{l_{cc}}$$

3.4. Existence a jednoznačnost trojúhelníkového rozkladu

- LU rozklad (a tedy i Choleského rozklad) existuje, pokud je matice regulární, a zároveň ostře diagonálně dominantní nebo symetrická a pozitivně definitní

- v závislosti na volbě diagonálních prvků matice L lze získat různé

LU rozklady matice - rozklad je volbou prvků jednoznačně určen

- GEM vlastně získáme matici U \Rightarrow řešitelnost LU rozkladem je

z hlediska existence ekvivalentní řešitelnosti pomocí GEM

3.5. Stabilita trojúhelníkového rozkladu

- při ručním výpočtu zapisujeme do tabulky už výsledky, čímž se vliv zaokrouhlení částečně omezí

3.6. Soustavy se speciální matricí

Speciální matice má alespoň jednu z následujících vlastností:

- symetrickost a pozitivní definitnost
- diagonální dominantnost
- pásovost

3.6.1. Symetrické a pozitivně definitní matice

Je-li A sym. a poz. def. matice, potom $\exists!$ horní ∇ matice U s kladnými diagonálními prvky taková, že

$$A = U^T \cdot U$$

viz [3.3]

3.6.2. Pásové matice

Lze-li LU rozklad provést, pak

$$i < j < i - p : l_{ij} = 0 \quad \wedge \quad j < i < j - p : u_{ij} = 0$$

což značí, že L a U budou pásové.

- dochází k velké úspoře operací, zejména je-li matice ∇ diagonální

3.6.3. Symetrické pozitivně definitní pásové matice

- velké soustavy řešeny iteracími metodami

- výhodně se použít LU rozklad či jinou eliminační metodu

4. Iterační metody pro SLAR

902 8.1

4.1. Jacobiho metoda

- ze všech rovnic vyjádříme i -tou neznámou

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1}^{i-1} a_{ij} \cdot x_j^{(k)} - \sum_{j=i+1}^n a_{ij} \cdot x_j^{(k)} \right) \quad i=1,2,\dots,n$$

$k=0,1,\dots,n$

- iterujeme za použití výše uvedených vzorců, jako zastavovací podmínku použijeme $\|x^{(k)} - x^{(k-1)}\| \leq \epsilon$, přičemž je vhodné použít např. maximovou normu (není nezbytné)

4.1.1. Iterační matice

$$A = M + D + N$$

$$(M + D + N) \cdot x = b$$

$$D x^{(k+1)} = -(M + N) x^{(k)} + b$$

$$H_j = -D^{-1} \cdot (M + N)$$

4.2. Gauss-Seidelova metoda

- podobně jako Jacobiho, ale do sa zůdeme vždy nejnovejší hodnoty:

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left(b_i - \sum_{j=1}^{i-1} a_{ij} \cdot x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} \cdot x_j^{(k)} \right) \quad i=1,2,\dots,n$$

$k=0,1,\dots,n$

4.2.1. Iterační matice

$$(M + D + N) \cdot x = b$$

$$(M + D) \cdot x^{(k+1)} = -N \cdot x^{(k)} + b$$

$$H_s = (M + D)^{-1} \cdot N$$

4.3. SOR

=relaxační metoda

-jako GS, ale přidává relaxační parametr ω :

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

-pro $\omega=1$ je tento vzorec stejný jako pro GS

- ω vybíráme z intervalu $(0;2)$ ($|1-\omega| > 1$ nesmí nastat!) tak, aby byla konvergence co nejrychlejší

4.3.1. Iterační matice

$$H_\omega = (D + \omega M)^{-1} \cdot [(1-\omega)D - \omega N]$$

4.4. Podmínky konvergence

4.4.1. Nutná a postačující podmínka

Iterace $x^{(k+1)} = H \cdot x^{(k)} + q$ konverguje pro libovolné $x^{(0)}$ právě když

$$\rho(H) = \max_i |\lambda_i(H)| < 1$$

kde $\rho(H)$ je spektrální poloměr matice H a $\lambda_i(H)$ jsou vlastní čísla této matice.

4.4.2. Postačující podmínka

Pokud $\|H\| \leq q < 1$, potom $\{x^{(k)}\}_{k=0}^{\infty}$ konverguje při volbě libovolného $x^{(0)}$

6. Metody pro řešení úloh na

vlastní čísla

~~6.1. Částečný vs. úplný problém vl. čísel~~

6.1.X Částečný problém vl. čísel

- hledáme vlastní číslo matice A s největší absolutní hodnotou - tzv.

dominantní číslo

- předpokládáme, že:

a) matice A má n lineárně nezávislých vektorů

b) dominantní vl. číslo je jediné:

$$\lambda_1 > \lambda_2 \geq \lambda_3 \geq \dots$$

6.1.1. Mocninová metoda

- předpoklady viz [6.1]

- sestavíme posloupnost $\{y^{(k)}\}$ pomocí

$$y^{(k)} = A \cdot y^{(k-1)} \quad ; \quad k = 1, 2, \dots$$

- pro dostatečně velká k bude

$$\lambda_1 = \lim_{k \rightarrow \infty} \frac{y^{(k+1)}}{y^{(k)}}$$

aproximovat vlastní číslo λ_1

- ke zastavení procesu použijeme podmínku $|\lambda_1^{(k)} - \lambda_1^{(k-1)}| < \delta$ kde δ je předem stanovena hranice (zpravidla)

- z důvodu nezabírání příliš velkého prostoru v paměti počítače používáme normalizaci - pokud některá složka vektoru $y^{(k)}$ přeroste určitou hodnotu (zpravidla 100), vydělíme touto složkou (popř. největší ze složek v abs. hodnotě) složky ostatní a složku nahradíme jedničkou

- počet operací: řádově n^2 na jednu iteraci

6.1.2. Metoda Rayleighova podílu

- Oproti předpokladům mocninové metody (viz [6.1]) je zde navíc předpoklad, že

A je symetrická

- iterace probíhají analogicky k mocninové metodě (viz [6.1.1]), ale k výpočtu použijeme vzorec

$$\lambda_1 = \lim_{k \rightarrow \infty} \frac{y^{(k-1)T} \cdot y^{(k)}}{y^{(k-1)T} \cdot y^{(k-1)}}$$

ktejž pro dostatečně velká k aproximuje vl. číslo λ_1 a to až dvakrát rychleji než vzorec mocninové metody (viz [6.1.1])

6.2. Úplný problém vlastních čísel

a) metody využívající charakteristický polynom

b) metody využívající vztah podobnosti matic:

6.2.1. Metoda LU rozkladu

1) rozložíme A_k na $L_k \cdot U_k$

2) spočítáme $A_{k+1} = U_k \cdot L_k$

3) iterujeme, než dostaneme horní ∇ matici

- získaná matice má vlastní čísla původní matice na diagonále

6.3. Singulární rozklad matice

K \mathbb{R} matici A typu $m \times n$, $m \geq n$, existují takové ortogonální matice U ($n \times m$) a V ($n \times n$) že prvky σ matice $\Sigma = U^T \cdot A \cdot V$ ($m \times n$) mají vlastnosti

$$a) \sigma_{ij} = 0 \quad ; \quad i \neq j$$

$$b) \sigma_{ij} = \sigma_i \geq 0$$

-číslem σ_i se říká singulární čísla matice

Tady by toho přece jen mohlo být více...

7. Aproximace funkcí

7.1. Základní úlohy

- vyběr typu aproximující funkce $g(x)$
- vyběr kritéria pro vyjádření blízkosti funkcí $f(x)$ a $g(x)$

7.2. Aproximace Taylorovým polynomem

- aproximujeme T. polynomem n -tého stupně - funkce musí mít derivaci n -tého stupně!

$$T_n(x) = f(x_0) + \frac{f'(x_0)}{1} \cdot (x-x_0) + \frac{f''(x_0)}{2} \cdot (x-x_0)^2 + \dots + \frac{f^{(n)}(x_0)}{n!} (x-x_0)^n = p_n(x)$$

7.2.1. Chyba aproximace

$$E(x) = f(x) - p_n(x) \quad - \text{v bodě } x_0 \text{ je rovno } 0$$

Obecně:

$$E(x) = f(x) - p_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \cdot (x-x_0)^{n+1} \quad \text{kde } \xi \text{ je neurčité; } \xi \in (x; x_0)$$

7.2.2. Odhad chyby aproximace

- jelikož ξ je neznámé číslo, dávat vzorec pro výpočet chyby

(viz [7.2.1]) pouze kvalitativní informaci

- umíme-li stanovit M takové, že

$$|f^{(n+1)}(x)| \leq M \quad \text{pro } \forall x \in (a,b)$$

potom

$$|E(x)| \leq \frac{M}{(n+1)!} |x-x_0|^{n+1}$$

- úloha se převádí na odhad $n+1$ ní derivace původní fce

7.3. Aproximace interpolačním polynomem

- pokud máme zadanou funkci pouze jako soubor jejích hodnot (typicky tabulkou), můžeme hledat hodnotu v nějakém bodě \hat{x} ležícím mezi dvěma tabulkovými body

- 1) stanovíme třídu aproximací f_i a vybereme jednu konkrétní
- 2) pomocí zvolené funkce interpolujeme zadané hodnoty

- různé používané druhy interpolačních polynomů:

- Lagrangeův

- Newtonův

- Nevilleův - získáme přímo hodnotu v bodě, nikoli předpis

7.4. L_2 aproximace

- jsou-li hodnoty zatíženy chybami, není interpolace nevhodnější

způsob - volíme raději třídu aproximací V_n ($n < m$;

$\varphi(x_i) = f(x_i)$, $i = 0, 1, \dots, m$) a snažíme se minimalizovat souhrnnou odchylku

aproximací funkce $\varphi(x)$ od zadaných dat

→ řešíme tedy vlastně metodu nejmenších čtverců:

$$R(f, \varphi) = \sum_{i=0}^m [f(x_i) - \varphi(x_i)]^2 = 0$$

- vypočítáme parciální derivace $R(f, \varphi)$ a položíme je rovno nule →

dostaneme soustavu $n+1$ rovnic o $n+1$ neznámých pro

$$c_j, \quad j = 0, 1, \dots, n \quad \rightarrow \quad \varphi(x) = \sum_{j=0}^n c_j \cdot \varphi_j(x)$$

$$\text{tzv. normální rovnice} \quad : \quad \frac{\partial R(f, \varphi)}{\partial c_j} = 0, \quad j = 0, 1, \dots, n$$

Je-li systém základních f_i $\{\varphi_j, j = 0, 1, \dots, n\}$ lineárně nezávislý, pak $\exists!$

$$\text{aproximace} \quad \varphi^*(x) = \sum_{j=0}^n c_j^* \cdot \varphi_j(x)$$

7.4.1. Spojitá L_2 aproximace

- aproximujeme analogicky k diskretní L_2 aproximaci (viz [7.4]):

$$R(f, \varphi) = \int_a^b [f(x) - \varphi(x)]^2 dx = 0$$

- v praxi nemá moc velký význam

7.5. Diskretní Fourierova transformace

- aproximace obecně funkce trigonometrickými funkcemi

$$f(x) = \sum_{k=0}^{\infty} (a_k \cdot \cos k\omega x + b_k \cdot \sin k\omega x)$$

kde

$$a_k = \frac{1}{\pi} \cdot \int_{-\pi}^{\pi} f(x) \cdot \cos kx \, dx \quad b_k = \frac{1}{\pi} \cdot \int_{-\pi}^{\pi} f(x) \cdot \sin kx \, dx$$

Fourierova transformace více viz M2/MA2/...

8. Numerické derivování a

integrování

- použití v případech, kdy analyticky úloha vyřešit nelze nebo je to moc pracné

- Je-li integrovatelná funkce φ dobrou aproximací funkce f na celém intervalu $\langle a, b \rangle$,
je integrál z φ dobrou aproximací integrálu f :

$$\left| \int_a^b f(x) dx - \int_a^b \varphi(x) dx \right| \leq \int_a^b |f(x) - \varphi(x)| dx \leq (b-a) \cdot \sup_{x \in \langle a, b \rangle} |f(x) - \varphi(x)|$$

8.1. Diference

- poměr rozdílu funkčních hodnot a vstupních hodnot

Levá poměrná diference: $f'(x) = \frac{f(x_0) - f(x_0 - h)}{h}$

Pravá poměrná diference: $f'(x) = \frac{f(x_0 + h) - f(x_0)}{h}$

Centrální pom. diference: $f'(x) = \frac{f(x_0 + h) - f(x_0 - h)}{2h}$

8.2. Richardsonova extrapolace

- vypočítáme výsledek s různými x kroky a poté výsledky interpolujeme

$$R(h) = \frac{2^n \cdot A(\frac{h}{2}) - A(h)}{2^n - 1} \quad \text{- obecně nemusí být faktor = 2}$$

- Opakováním extrapolace dochází k dalšímu zpřesňování původních výsledků

8.3. Newton-Cotesovy vzorce

- na zadaném intervalu $\langle a; b \rangle$ nahradíme funkci f jejím interpolačním polynomem s ekvidistantními uzly, vzdálenými $h = (b-a)/N$ kde N je jejich počet

8.3.1. Obdelnikove pravidlo

- funkci nahradíme na celém intervalu funkcí konstantní, s funkční hodnotou, jaké nabývá původní funkce v bodě $x_k + \frac{1}{2}h$, tedy

$$\int_{x_k}^{x_{k+1}} f(x) dx \approx h \cdot f\left(x_k + \frac{h}{2}\right) = R_2(f; h)$$

Složený vzorec:

$$\int_a^b f(x) dx = \sum_{k=0}^{N-1} \int_{x_k}^{x_{k+1}} f(x) dx \approx h \cdot \sum_{k=0}^{N-1} f\left(x_k + \frac{h}{2}\right) = R_2(f; h)$$

8.3.2. Lichoběžníkové pravidlo

- původní funkci nahradíme funkcí lineární - přímkou, spojující bod $[x_k; f(x_k)]$ a $[x_{k+1}; f(x_{k+1})]$

$$\int_{x_k}^{x_{k+1}} f(x) dx \approx \frac{h}{2} \cdot [f(x_k) + f(x_{k+1})] = T_2(f; h)$$

Složený vzorec:

$$\int_a^b f(x) dx \approx \frac{h}{2} [f(x_0) + 2 \cdot \sum_{k=1}^{N-1} f(x_k) + f(x_N)] = h \cdot \left[\frac{1}{2} f(x_0) + \sum_{k=1}^{N-1} f(x_k) + \frac{1}{2} f(x_N) \right] = T_2(f; h)$$

8.3.3. Simpsonovo pravidlo

- nahrazeníme parabolou, která interpoluje v x_k, x_{k+1}, x_{k+2}

$$\int_{x_k}^{x_{k+2}} f(x) dx \approx \frac{h}{3} [f(x_k) + 4 \cdot f(x_{k+1}) + f(x_{k+2})] = S_2(f; h)$$

Složený vzorec:
$$\int_a^b f(x) dx \approx \frac{h}{3} [f(x_0) + 4 \cdot f(x_1) + 2 \cdot f(x_2) + 4 \cdot f(x_3) + \dots + f(x_N)] = S_2(f; h)$$

N musí být sudé číslo!

8.4. Gaussovy kvadraturní vzorce

- aproximace neekvidistantními uzly
- algebraický řád G. kvadr. vzorce s $n+1$ uzly je $2n+1$ - G. kv. vzorce mají nejvyšší možný algebraický řád
- pro $n \rightarrow \infty$ tvoří konvergentní kvadratura - přesně aproximují hodnotu integrálu integrované funkce, přičemž rychlost konvergence závisí na hladkosti funkce
- vzorce konvergují i pro po částech spojitě (s konečným počtem skoků) funkce, byť pomalu
- je vhodné mít uhdovány hodnoty koeficientů w_i a uzlů x_i pro jednotlivé stupně vzorce
- uzly x_i jsou rozloženy symetricky okolo středu intervalu