

Pokročilé numerické metody I

Metoda nejmenších čtverců

Jiří Zelinka

Metoda nejmenších čtverců

Systém lineárních rovnic

$$Ax = b$$

Reziduum:

$$r_x = b - Ax$$

Definice

Vektor \hat{x} se nazývá *řešením ve smyslu NČ*, jestliže

$$\forall x : \|r_x\| \geq \|r_{\hat{x}}\|$$

Věta 1

Řešení ve smyslu NČ vždy existuje a je řešením systému normálních rovnic

$$A^*Ax = A^*b.$$

Důkaz: Pomocí ortogonálního rozkladu vektoru $b = b_1 + b_2$, kde $b_1 \in \mathcal{R}(A)$.

Důsledek

Systemu normálních rovnic je vždy řešitelný.

Věta 2

Každé řešení systému normálních rovnic je řešením ve smyslu NČ.

Věta 3

Řešení ve smyslu NČ je jediné právě tehdy, když sloupce A jsou LNZ.

Numerický přístup k MNČ

Aproximace dat daným typem funkce

$\mathbf{x} = (x_0, \dots, x_N)$ – uzly

$\mathbf{f} = (f_0, \dots, f_N)$ – funkční hodnoty v uzlech neznáme funkce f

$\varphi_0, \dots, \varphi_M$ – zadané báze funkce (např. $\varphi_k = x^k$)

Data (x_i, f_i) aproximujeme funkcí $\varphi = \sum_{k=0}^M c_k \varphi_k$

Hledáme minimum výrazu

$$\sigma^2(c_0, \dots, c_M) = \sum_{j=0}^N (f_j - \varphi(x_j))^2$$

Vektor $\mathbf{c} = (c_0, \dots, c_M)^T$ je řešením normálního systému

$$A^T A \mathbf{x} = A^T \mathbf{f} \text{ pro matici } A = \begin{pmatrix} \varphi_0(x_0) & \cdots & \varphi_M(x_0) \\ \vdots & & \vdots \\ \varphi_0(x_N) & \cdots & \varphi_M(x_N) \end{pmatrix}.$$

Statistický přístup k MNČ

Lineární regresní model:

$$Y = \beta_0 X_0 + \dots + \beta_M X_M + \varepsilon$$

Y, ε – náhodné veličiny, β_j – neznámé parametry.

Pro N pozorování:

$$Y_0 = \beta_0 X_{00} + \dots + \beta_M X_{M0} + \varepsilon_0$$

\vdots

$$Y_N = \beta_0 X_{0N} + \dots + \beta_M X_{MN} + \varepsilon_N$$

t.j.

$$Y = X\beta + \varepsilon$$

X – matice plánu, β – neznámé parametry

Minimalizujeme výraz (rozptyl odhadu β)

$$(Y - X\beta)^T (Y - X\beta)$$

Řešení je odhad parametru β (BLUE)

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

Definice

Bud' A matice typu $m \times n$. Matice X se nazývá její pseudoinverzní maticí, jestliže platí následující vlastnosti (Penroseovy axiomy)

$$(1) AXA = A$$

$$(2) XAX = X$$

$$(3) (AX)^* = AX \text{ (} AX \text{ je hermitovská)}$$

$$(4) (XA)^* = XA \text{ (} XA \text{ je hermitovská)}$$

Věta 4

Pseudoinverzní matice vždy existuje a je určena jednoznačně.

Označení

Pseudoinverzní matici k matici A značíme A^+ .

Lemma (skeletní rozklad)

Nechť A je typu $m \times n$, $r(A) = r$. Pak existují matice B typu $m \times r$ a C typu $r \times n$, $r(B) = r(C) = r$, že platí $A = BC$.

Důkaz: Jako B vybereme nezávislé sloupce matice A , C pak dopočítáme.

Důkaz vety o existenci a jednoznačnosti

Jednoznačnost dostaneme z Penroseových axiomů.

Pro nulovou matici A je $A^+ = A^*$.

Pokud má A nezávislé sloupce, pak $A^+ = (A^*A)^{-1}A^*$,
pro matici s nezávislými řádky je $A^+ = A^*(AA^*)^{-1}$.

V obecném případě uděláme skeletní rozklad $A = BC$ a dokážeme, že $A^+ = C^+B^+$.

Věta 5 Vlastnosti pseudoinverzní matice

- 1 pro regulární A je $A^+ = A^{-1}$
- 2 $(A^+)^+ = A$
- 3 $(A^*)^+ = (A^+)^*$
- 4 $(A^*A)^+ = A^+A^{+*}$, $(AA^*)^+ = A^{+*}A^+$
- 5 $A^+ = (A^*A)^+A^* = A^*(AA^*)^+$
- 6 $h(A) = h(A^+) = h(A^*) = h(A^+A) = h(A^*A) = \dots$
- 7 $\mathcal{R}(A^+) = \mathcal{R}(A^*)$
- 8 $\mathcal{N}(A^+) = \mathcal{N}(A^*)$
- 9 obecně neplatí $(AB)^+ = B^+A^+$
- 10 $c \neq 0 \Rightarrow (cA)^+ = \frac{1}{c}A^+$
- 11 $A^+ = (QA^*A)^+QA^*$ pro regulární Q

Lemma

Bud' $P = AA^+$, $Q = A^+A$. Pro libovolné vektory x, y platí

- $\|Ax + (I - P)y\|^2 = \|Ax\|^2 + \|(I - P)y\|^2$
- $\|A^+y + (I - Q)x\|^2 = \|A^+y\|^2 + \|(I - Q)x\|^2$

Důkaz: dokážeme kolmost.

Věta 6

Bud' A typu $m \times n$, b typu $n \times 1$, $\hat{x} = A^+b$. Pak pro každé $x \neq \hat{x}$ platí: $\|b - Ax\| \geq \|b - A\hat{x}\|$, a v případě, že $\|b - Ax\| = \|b - A\hat{x}\|$, pak $\|x\| > \|\hat{x}\|$.

Interpretace:

$\hat{x} = A^+b$ je řešení ve smyslu NČ s minimální normou a je jediné s touto vlastností.

Důkaz

$$Ax - b = Ax - AA^+b + AA^+b - b = A(x - A^+b) + (I - AA^+)(-b)$$

Podle předchozího lemmatu

$$\|Ax - b\|^2 = \|A(x - \hat{x})\|^2 + \|A\hat{x} - b\|^2 \geq \|A\hat{x} - b\|^2,$$

přičemž rovnost nastane pouze pro

$$\|A(x - \hat{x})\|^2 = 0, \text{ tj. } Ax = A\hat{x}.$$

Pokud $Ax = A\hat{x}$, pak $A^+Ax = A^+A\hat{x} = A^+AA^+b = A^+b = \hat{x}$.

Potom $x = \hat{x} + (x - \hat{x}) = A^+b + (I - A^+A)x$.

Podle druhé rovnosti předchozího lemmatu platí

$$\|x\|^2 = \|\hat{x}\|^2 + \|x - \hat{x}\|^2, \text{ takže } \|x\|^2 \geq \|\hat{x}\|^2 \text{ a rovnost}$$

nastane pouze pro $x = \hat{x}$.

Věta 7 (Penrose 1955)

Systém rovnice $AXB = C$ je řešitelný právě tehdy, když platí $AA^+CB^+B = C$, V tom případě je obecné řešení systému ve tvaru

$$X = A^+CB^+ + Y - A^+AYBB^+$$

pro libovolnou matici Y .

Důsledek

Systém $Ax = b$ je řešitelný právě tehdy, když platí $AA^+b = b$. Obecné řešení tohoto systému je pak

$$x = A^+b + (I - A^+A)y$$

pro libovolný vektor y .

Výpočet Mooreovy–Penroseovy pseudoinverze po řádcích (sloupcích)

A : matice, A_k : prvních k řádků, a_k : k -tý řádek, známe A_{k-1}^+

Položme:

$$d_k = a_k A_{k-1}^+$$

$$c_k = a_k - d_k A_{k-1}$$

$$b_k = \begin{cases} c_k^+ & c_k \neq 0 \\ \frac{1}{1+d_k d_k^*} A_{k-1}^+ d_k^* & c_k = 0 \end{cases}$$

$$A_k^+ = (A_{k-1}^+ - b_k d_k | b_k)$$

Sloupcová verze

A : matice, A_k : prvních k sloupců, a_k : k -tý sloupec, známe

$$A_{k-1}^+$$

Položme:

$$d_k = A_{k-1}^+ a_k$$

$$c_k = a_k - A_{k-1} d_k$$

$$b_k = \begin{cases} c_k^+ & c_k \neq 0 \\ \frac{1}{1+d_k d_k^*} d_k^* A_{k-1}^+ & c_k = 0 \end{cases}$$

$$A_k^+ = \begin{pmatrix} A_{k-1}^+ - d_k b_k \\ \hline \hline b_k \end{pmatrix}$$

Využití: MNČ – přidání pozorování nebo vysvětlující proměnné

Aproximace dat nelineární funkcí závislé na parametrech, které se snažíme určit

Příklad:

Michaelisův-Mentenové model kinetiky enzymů

$$f(x, \beta) = \frac{\beta_1 x}{\beta_2 + x}$$

x_0, \dots, x_N – uzly

y_0, \dots, y_N – funkční hodnoty, $y_j \approx f(x_j, \beta)$

Rezidua: $r_j(\beta) = y_j - f(x_j, \beta)$ Hledáme minimum výrazu

$$S(\beta) = \sum_{j=0}^N r_j(\beta)^2$$

Nutná podmínka pro minimum:

$$0 = \frac{\partial S}{\partial \beta_i} = 2 \sum_{j=0}^N r_j(\beta) \frac{\partial r_j(\beta)}{\partial \beta_i} = -2 \sum_{j=0}^N J_{ji} r_j(\beta) \quad \forall i,$$

pro $\frac{\partial r_j(\beta)}{\partial \beta_i} = -\frac{\partial f(x_j, \beta)}{\partial \beta_i} = -J_{ji}$,

$J = (J_{ji})$ je Jacobiova matice, $J = J(\beta)$.

Máme systém nelineárních rovnic – řešíme iterační metodou:

β^0 - počáteční iterace, $\beta^k + \Delta\beta^k = \beta^{k+1} \approx \beta$

Taylorův rozvoj v parametrech β :

$$\begin{aligned} f(x_j, \beta) &\approx f(x_j, \beta^k) + \sum_i \frac{\partial f(x_j, \beta^k)}{\partial \beta_i} (\beta_i - \beta_i^k) \approx \\ &\approx f(x_j, \beta^k) + \sum_i J_{ji} \Delta\beta_i^k. \end{aligned}$$

Označení: $\Delta y_j^k = y_j - f(x_j, \beta^k)$

$$\begin{aligned} r_j(\beta) &= y_j - f(x_j, \beta) = (y_j - f(x_j, \beta^k)) + (f(x_j, \beta^k) - f(x_j, \beta)) \approx \\ &\approx \Delta y_j^k - \sum_i J_{ji} \Delta \beta_i^k = \Delta y_j^k - \sum_l J_{jl} \Delta \beta_l^k \end{aligned}$$

Dosazením do nutné podmínky pro minimum dostaneme

$$-2 \sum_j J_{ji} \left(\Delta y_j^k - \sum_l J_{jl} \Delta \beta_l^k \right) = 0, \quad \forall i$$

Po úpravě dostaneme systém normálních rovnic

$$J^T J \Delta \beta^k = J^T \Delta y^k, \quad \text{pro } J = J(\beta^k).$$

Gaussův-Newtonův algoritmus: volíme počáteční iteraci β^0 , z předchozího systému normálních rovnic určíme přírůstek $\Delta \beta^0$, z něj iteraci β^1 atd.