

Optimalizace

3. Metoda nejmenších čtverců

Tom Werner

FEL ČVUT

Řešitelnost lineárních soustav

Soustava m lineárních rovnic o n neznámých ($\mathbf{A} \in \mathbb{R}^{m \times n}$, $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{b} \in \mathbb{R}^m$)

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

- pro $\mathbf{b} = \mathbf{0}$ je **homogenní**, pro $\mathbf{b} \neq \mathbf{0}$ je **nehomogenní**.
- má řešení, právě když $\mathbf{b} \in \text{rng } \mathbf{A}$, tj. $\text{rank}[\mathbf{A} \ \mathbf{b}] = \text{rank } \mathbf{A}$ (Frobeniova věta)
- množina řešení je afinní podprostor \mathbb{R}^n

Tři případy:

- nemá řešení ($\mathbf{b} \notin \text{rng } \mathbf{A}$): **přeurčená** soustava
- právě jedno řešení ($\mathbf{b} \in \text{rng } \mathbf{A}$, $\text{rank } \mathbf{A} = n$)
- nekonečně mnoho řešení ($\mathbf{b} \in \text{rng } \mathbf{A}$, $\text{rank } \mathbf{A} < n$): **nedourčená** soustava

Úloha nejmenších čtverců

Přibližné řešení přeурčené soustavy $\mathbf{Ax} = \mathbf{b}$ ve smyslu nejmenších čtverců:

$$\min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|^2$$

Také se nazývá **(lineární) úloha nejmenších čtverců**.


Příklad: Pro soustavu

$$\begin{aligned}x + 2y &= 6 \\ -x + y &= 3 \\ x + y &= 4\end{aligned}$$

hledáme přibližné řešení $x, y \in \mathbb{R}$, které minimalizuje

$$(x + 2y - 6)^2 + (-x + y - 3)^2 + (x + y - 4)^2.$$

Řešení úlohy



Věta

Vektor \mathbf{x} je optimální řešení úlohy

$$\min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{A}\mathbf{x} - \mathbf{b}\|^2 = \min_{\mathbf{y} \in \text{rng } \mathbf{A}} \|\mathbf{y} - \mathbf{b}\|^2$$

právě když splňuje soustavu **normálních rovnic**

$$\mathbf{A}^T \mathbf{A}\mathbf{x} = \mathbf{A}^T \mathbf{b}.$$

Důkaz: Věta o kolmici: \mathbf{x} je optimální řešení právě když $(\mathbf{b} - \mathbf{A}\mathbf{x}) \perp \text{rng } \mathbf{A}$, tj. $\mathbf{A}^T(\mathbf{b} - \mathbf{A}\mathbf{x}) = 0$.

Řešení pomocí derivací

Stejnou podmínku dostaneme z analýzy: minimalizujeme funkci

$$\begin{aligned}f(\mathbf{x}) &= \|\mathbf{Ax} - \mathbf{b}\|^2 = (\mathbf{Ax} - \mathbf{b})^T (\mathbf{Ax} - \mathbf{b}) \\ &= \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} - \mathbf{x}^T \mathbf{A}^T \mathbf{b} - \mathbf{b}^T \mathbf{Ax} + \mathbf{b}^T \mathbf{b} \\ &= \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} - 2\mathbf{b}^T \mathbf{Ax} + \mathbf{b}^T \mathbf{b}\end{aligned}$$

- f je konvexní, kvadratická, zdola omezená funkce n proměnných
- Gradient f (vrátíme se k němu později):

$$\nabla f(\mathbf{x}) = 2\mathbf{A}^T \mathbf{Ax} - 2\mathbf{A}^T \mathbf{b}$$

- stacionární podmínka $\nabla f(\mathbf{x}) = \mathbf{0}$ jsou normální rovnice

Řešitelnost soustavy normálních rovnic

Věta

- $\text{rng}(\mathbf{A}^T \mathbf{A}) = \text{rng}(\mathbf{A}^T)$
- $\text{null}(\mathbf{A}^T \mathbf{A}) = \text{null } \mathbf{A}$

Důkaz druhé rovnosti: Zřejmě $\mathbf{Ax} = \mathbf{0} \Rightarrow \mathbf{A}^T \mathbf{Ax} = \mathbf{0}$. Ale také $\mathbf{A}^T \mathbf{Ax} = \mathbf{0} \Rightarrow \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} = (\mathbf{Ax})^T (\mathbf{Ax}) = \|\mathbf{Ax}\|^2 = 0 \Rightarrow \mathbf{Ax} = \mathbf{0}$. První rovnost pak plyne z druhé rovnosti a rank-nullity theoremu.

Důsledky pro řešitelnost soustavy $\mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}$:

- Soustava má řešení pro každé \mathbf{A}, \mathbf{b} (neboť vždy $\mathbf{A}^T \mathbf{b} \in \text{rng}(\mathbf{A}^T) = \text{rng}(\mathbf{A}^T \mathbf{A})$).
- $\mathbf{A}^T \mathbf{A}$ je regulární, právě když \mathbf{A} má lin. nezávislé sloupce. Pak

$$\mathbf{x} = \underbrace{(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b}}_{\mathbf{A}^+}$$

Matice \mathbf{A}^+ se nazývá **pseudoinverze** matice \mathbf{A} (s l.n. sloupci).

Je to jedna z levých inverzí matice \mathbf{A} , neboť $\mathbf{A}^+ \mathbf{A} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A} = \mathbf{I}$.

Řešení pomocí QR rozkladu

Řešíme soustavu normálních rovnic

$$\mathbf{A}^T \mathbf{A} \mathbf{x} = \mathbf{A}^T \mathbf{b}$$

kde sloupce \mathbf{A} jsou l.n.

- řešení pomocí inverze matice $\mathbf{A}^T \mathbf{A}$ zanáší zaokrouhlovací chyby
- lépe pomocí (redukovaného) QR rozkladu $\mathbf{A} = \mathbf{QR}$:

$$\mathbf{A}^T \mathbf{A} \mathbf{x} = \mathbf{A}^T \mathbf{b}$$


$$\mathbf{R}^T \mathbf{Q}^T \mathbf{Q} \mathbf{R} \mathbf{x} = \mathbf{R}^T \mathbf{Q}^T \mathbf{b}$$

$$\mathbf{R}^T \mathbf{R} \mathbf{x} = \mathbf{R}^T \mathbf{Q}^T \mathbf{b}$$

$$\mathbf{R} \mathbf{x} = \mathbf{Q}^T \mathbf{b}$$

V Matlabu: `x=A\b`

Ortogonalní projekce na podprostor zadaný obecnou bází



Zopakujme úlohu nejmenších čtverců: $\min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|^2 = \min_{\mathbf{y} \in \text{rng } \mathbf{A}} \|\mathbf{y} - \mathbf{b}\|^2$

- Když jsou sloupce \mathbf{A} lin. nezávislé, tvoří bázi podprostoru $X = \text{rng } \mathbf{A}$.
- Pak optimální řešení

$$\mathbf{y} = \mathbf{Ax} = \mathbf{AA}^+ \mathbf{b} = \underbrace{\mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T}_{\mathbf{P}} \mathbf{b}$$

je ortogonální projekce vektoru \mathbf{b} na podprostor X a \mathbf{P} je ortog. projektor.

- Když \mathbf{A} má ortonormální sloupce ($\mathbf{A}^T \mathbf{A} = \mathbf{I}$), tak $\mathbf{P} = \mathbf{AA}^T$. To už známe!

Řešení nedourčené lineární soustavy s nejmenší normou

Mezi řešeními soustavy $\mathbf{Ax} = \mathbf{b}$ najdeme to s nejmenší normou:


$$\min\{ \|\mathbf{x}\|^2 \mid \mathbf{x} \in \mathbb{R}^n, \mathbf{Ax} = \mathbf{b} \}$$

Příklad: Soustava

$$\begin{aligned}x + 2y + z &= 1 \\ -x + y + 2z &= 2\end{aligned}$$

má nekonečně mnoho řešení. Hledáme řešení které minimalizuje číslo $x^2 + y^2 + z^2$.

Řešení úlohy



x má nejmenší normu $\Leftrightarrow x \perp \text{null } \mathbf{A} \Leftrightarrow x \in (\text{null } \mathbf{A})^\perp = \text{rng}(\mathbf{A}^T) \Leftrightarrow x = \mathbf{A}^T y$

Věta

x je optimální řešení úlohy, právě když existuje y tak, že

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

$$\mathbf{A}^T y = x$$

Dosazení dá $\mathbf{A}\mathbf{A}^T y = \mathbf{b}$. Má-li \mathbf{A} l.n. řádky, je $y = (\mathbf{A}\mathbf{A}^T)^{-1}\mathbf{b}$. Tedy

$$x = \mathbf{A}^T y = \underbrace{\mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1}}_{\mathbf{A}^+} \mathbf{b}$$

kde \mathbf{A}^+ je **pseudoinverze** matice \mathbf{A} (s l.n. řádky).

Je to jedna z pravých inverzí matice \mathbf{A} , neboť $\mathbf{A}\mathbf{A}^+ = \mathbf{A}\mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1} = \mathbf{I}$.

Použití metody nejmenších čtverců

Lineární regrese

Regrese je modelování funkční závislosti proměnné $y \in \mathbb{R}$ na proměnné $x \in X$ (kde X je libovolná množina) **regresní funkcí**

$$y = f(x, \theta).$$

Odhad parametrů: Hledáme parametry $\theta \in \mathbb{R}^n$ tak, aby funkce f dobře modelovala naměřená data $(x_1, y_1), \dots, (x_m, y_m)$:

$$\min_{\theta \in \mathbb{R}^n} \sum_{i=1}^m (y_i - f(x_i, \theta))^2$$

- Regrese je **lineární**, jestliže pro každé $x \in X$ je f lineární funkcí θ . Tedy

$$f(x, \theta) = \theta_1 \varphi_1(x) + \dots + \theta_n \varphi_n(x) = \varphi(x)^T \theta$$

kde $\varphi = (\varphi_1, \dots, \varphi_n): X \rightarrow \mathbb{R}$ jsou dané "bázové funkce".

- Pak

$$\sum_{i=1}^m (y_i - f(x_i, \theta))^2 = \|\mathbf{y} - \mathbf{A}\theta\|^2$$

kde $\mathbf{y} = (y_1, \dots, y_m)$ a prvky matice \mathbf{A} jsou $a_{ij} = \varphi_j(x_i)$.

Příklad: Aproximace polynomiální funkcí

Nechť $X = \mathbb{R}$ a $\varphi_j(x) = x^{j-1}$. Pak

$$f(x, \theta) = \theta_1 + \theta_2 x + \theta_3 x^2 + \cdots + \theta_n x^{n-1}$$

a

$$\mathbf{A} = \begin{bmatrix} 1 & x_1 & x_1^2 & \cdots & x_1^{n-1} \\ 1 & x_2 & x_2^2 & \cdots & x_2^{n-1} \\ & & & \vdots & \\ 1 & x_m & x_m^2 & \cdots & x_m^{n-1} \end{bmatrix}$$

(**Vandermondova matice**).

- Pro $n = 1$ je $f(x, \theta) = \theta$ a $f(x, \theta) = \sum_{i=1}^m (x_i - \theta)^2$. Řešení: $\theta^* = \frac{1}{m} \sum_{i=1}^m x_i$.
- Zobecnění na polynomy více proměnných: $X = \mathbb{R}^d$ a φ_j jsou monomy proměnných x_1, \dots, x_d

Pozor! Pořád jde o lineární regresi, protože f je lineární v parametrech θ .

Mnoho dalších použití!

Mnoho dalších použití úlohy

$$\min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|^2$$

je v této knize (zdarma ke stažení i se slajdy, viz doplňující literatura na CW):

