

Optimalizace

3. Metoda nejmenších čtverců

Tom Werner

FEL ČVUT

Řešitelnost lineárních soustav

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

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

má řešení, právě když $\mathbf{b} \in \text{rng } \mathbf{A}$, tj. $\text{rank}[\mathbf{A} \ \mathbf{b}] = \text{rank } \mathbf{A}$ (Frobeniova věta).

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

Lineární úloha nejmenších čtverců

Přibližné řešení přeurčené 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

$$x + 2y = 6$$

$$-x + y = 3$$

$$x + y = 4$$

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

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

Řešení pomocí derivací

Minimalizujeme funkci

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

- funkce f je konvexní, kvadratická, zdola omezená nulou
- Nutná podmínka na lokální extrém (= stacionární podmínka):

$$\nabla f(\mathbf{x}) = 2\mathbf{A}^T (\mathbf{Ax} - \mathbf{b}) = \mathbf{0}$$


- f je konvexní \implies stacionární body jsou globální minima

Věta

Vektor \mathbf{x} je optimální řešení úlohy právě tehdy, když splňuje soustavu **normálních rovnic**

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

To je lineární soustava n rovnic o n neznámých.



Řešíme úlohu

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

Věta o kolmici: $\mathbf{y} = \mathbf{Ax}$ je optimální právě tehdy, když

$$(\mathbf{b} - \mathbf{Ax}) \perp \text{rng } \mathbf{A} \iff \mathbf{b} - \mathbf{Ax} \in (\text{rng } \mathbf{A})^\perp = \text{null}(\mathbf{A}^T)$$

$$\iff \mathbf{A}^T(\mathbf{b} - \mathbf{Ax}) = \mathbf{0}$$

$$\iff \mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b}$$

Řešení normálních rovnic pomocí (pseudo)inverze

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 $\mathbf{Ax} = \mathbf{0} \implies \mathbf{A}^T \mathbf{Ax} = \mathbf{0}$.

Ale také $\mathbf{A}^T \mathbf{Ax} = \mathbf{0} \implies \mathbf{x}^T \mathbf{A}^T \mathbf{Ax} = (\mathbf{Ax})^T (\mathbf{Ax}) = \|\mathbf{Ax}\|^2 = 0 \implies \mathbf{Ax} = \mathbf{0}$.

První rovnost pak plyne z druhé rovnosti a z věty o hodnotě a nulitě.

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

- 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

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

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 normálních rovnic 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: $\mathbf{x} = \mathbf{A} \backslash \mathbf{b}$

Ortogonalní projekce na podprostor



Ortogonalní projekce vektoru $\mathbf{b} \in \mathbb{R}^m$ na podprostor $X \subseteq \mathbb{R}^m$ je vektor $\mathbf{y} \in X$ takový, že $(\mathbf{b} - \mathbf{y}) \perp X$.

Jestliže X má bázi tvořenou sloupci matice \mathbf{A} (tedy $X = \text{rng } \mathbf{A}$), pak

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

Matice $\mathbf{P} \in \mathbb{R}^{m \times m}$ je **ortogonalní projektor** na podprostor X .

Tvoří-li sloupce \mathbf{A} ortonormální bázi podprostoru X (tj. $\mathbf{A}^T\mathbf{A} = \mathbf{I}$), máme $\mathbf{P} = \mathbf{A}\mathbf{A}^T$.

Tvrzení: \mathbf{P} nezávisí na volbě báze podprostoru X . Tedy ortog. projekce existuje a je jediná.


Důsledek

Každé $\mathbf{b} \in \mathbb{R}^m$ lze jednoznačně rozložit jako $\mathbf{b} = \mathbf{y} + \mathbf{y}'$ kde $\mathbf{y} \in X$ a $\mathbf{y}' \in X^\perp$.

- $\mathbf{y}' = \mathbf{b} - \mathbf{y} = \mathbf{b} - \mathbf{P}\mathbf{b} = (\mathbf{I} - \mathbf{P})\mathbf{b}$ je ortog. projekce vektoru \mathbf{b} na podprostor X^\perp .
- $\mathbf{I} - \mathbf{P}$ je ortog. projektor na X^\perp .
- Zřejmě $\text{rng } \mathbf{P} = X$ a $\text{null } \mathbf{P} = X^\perp$.

Věta (charakterizace ortog. projektorů)

Matice \mathbf{P} je ortog. projektor (na nějaký podprostor) právě když $\mathbf{P}^2 = \mathbf{P} = \mathbf{P}^T$.



Podprostory $X, X' \subseteq \mathbb{R}^m$ nazveme **komplementární**, jestliže

$$X \cap X' = \{\mathbf{0}\}$$


$$\dim X + \dim X' = m$$

Věta

Každé $\mathbf{b} \in \mathbb{R}^m$ lze jednoznačně rozložit jako $\mathbf{b} = \mathbf{y} + \mathbf{y}'$ kde $\mathbf{y} \in X$ a $\mathbf{y}' \in X'$.

Vektor \mathbf{y} se nazývá **projekce** vektoru \mathbf{b} na podprostor X ve směru podprostoru X' .

Nepovinné: Obecné projektor



Definice: Matice \mathbf{P} se nazývá (obecný) **projektor**, jestliže $\mathbf{P}^2 = \mathbf{P}$.

- Podprostory $\text{rng } \mathbf{P}$ a $\text{null } \mathbf{P}$ jsou komplementární a platí $\text{null } \mathbf{P} = \text{rng}(\mathbf{I} - \mathbf{P})$.
- Tedy $\mathbf{y} = \mathbf{P}\mathbf{b}$ je projekce vektoru \mathbf{b} na podprostor $\text{rng } \mathbf{P}$ ve směru podprostoru $\text{null } \mathbf{P}$.
- Pro každou komplementární dvojici podprostorů X, X' existuje právě jeden projektor tak, že $\text{rng } \mathbf{P} = X$ a $\text{null } \mathbf{P} = X'$.
- Matice \mathbf{P} je projektor, právě když $\mathbf{P} = \mathbf{B}(\mathbf{A}\mathbf{B})^{-1}\mathbf{A}$ pro nějaké matice \mathbf{A}, \mathbf{B} takové, že $\mathbf{A}\mathbf{B}$ je regulární.
- Speciálně, když $\mathbf{A}\mathbf{B} = \mathbf{I}$ tak $\mathbf{P} = \mathbf{B}\mathbf{A}$.

Ortogonální projekce/projektory jsou spec. případ, kdy $X' = X^\perp$ a $\mathbf{P} = \mathbf{P}^T$.

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

$$x + 2y + z = 1$$

$$-x + y + 2z = 2$$

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

Řešení úlohy



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

Věta

\mathbf{x} je optimální řešení úlohy, právě když existuje \mathbf{y} tak, že

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

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

Řešme soustavu

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

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


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

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

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

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

Jiné řešení úlohy



- Necht' \mathbf{x}_0 je libovolné splňující $\mathbf{A}\mathbf{x}_0 = \mathbf{b}$.
- Optimální \mathbf{x} je ortog. projekce vektoru \mathbf{x}_0 na podprostor $(\text{null } \mathbf{A})^\perp = \text{rng}(\mathbf{A}^T)$, tedy

$$\mathbf{x} = \mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}\mathbf{x}_0 = \underbrace{\mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1}}_{\mathbf{A}^+} \mathbf{b}$$

(nezávisí na tom, jaké partikulární řešení \mathbf{x}_0 jsme vybrali!)

Důsledek: Má-li soustava $\mathbf{A}\mathbf{x} = \mathbf{b}$ řešení, má právě jedno řešení s nejmenší normou.

Pseudoinverze obecné matice

Hledejme optimální řešení úlohy

$$\min_{\mathbf{x} \in \mathbb{R}^n} \|\mathbf{Ax} - \mathbf{b}\|^2 \quad (\text{LS})$$

s nejmenší normou.

To vede na úlohu

$$\min\{ \|\mathbf{x}\|^2 \mid \mathbf{x} \in \mathbb{R}^n, \mathbf{A}^T \mathbf{Ax} = \mathbf{A}^T \mathbf{b} \} \quad (\text{LSN})$$

Nechť \mathbf{x}^* je (jediné) řešení úlohy (LSN).

- Má-li soustava $\mathbf{Ax} = \mathbf{b}$ jediné řešení, pak \mathbf{x}^* je toto řešení.
- Má-li soustava $\mathbf{Ax} = \mathbf{b}$ více řešení, pak \mathbf{x}^* je její řešení s nejmenší normou.
- Nemá-li soustava $\mathbf{Ax} = \mathbf{b}$ řešení, pak \mathbf{x}^* je optimální řešení úlohy (LS) s nejmenší normou.

Fakt: Existuje matice \mathbf{A}^+ (**Moore-Penroesova pseudoinverze** matice \mathbf{A}) tak, že $\mathbf{x}^* = \mathbf{A}^+ \mathbf{b}$.

- Má-li \mathbf{A} l.n. sloupce, pak $\mathbf{A}^+ = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$.
- Má-li \mathbf{A} l.n. řádky, pak $\mathbf{A}^+ = \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1}$.
- Nemá-li \mathbf{A} plnou hodnotu, pak \mathbf{A}^+ lze spočítat pomocí SVD.