

# 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

---

# Úloha nejmenších čtverců

Přibližné řešení přeurtčené soustavy  $\mathbf{Ax} = \mathbf{b}$ : minimalizuj součet

$$\|\mathbf{r}\|^2 = \mathbf{r}^T \mathbf{r} = r_1^2 + \dots + r_m^2$$

čtverců reziduí  $(r_1, \dots, r_m) = \mathbf{r} = \mathbf{b} - \mathbf{Ax}$ . Tedy

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

**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 úlohy nejmenších čtverců



## Věta

Vektor  $\mathbf{x}$  je optimální řešení úlohy

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

právě když splňuje soustavu **normálních rovnic**

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

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

## 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  $\mathbf{A}^T \mathbf{b} \in \text{rng}(\mathbf{A}^T) = \text{rng}(\mathbf{A}^T \mathbf{A})$ ).
- Matice  $\mathbf{A}^T \mathbf{A}$  je regulární, právě když  $\mathbf{A}$  má lin. nezávislé sloupce. Pak řešení soustavy lze napsat pomocí inverze:

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

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 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 matice  $\mathbf{P}$  je ortogonální projektor).

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

# 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  $(x_1, y_1), \dots, (x_m, y_m)$ :

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

- **Lineární regrese:** pro každé  $x \in X$  je  $f$  lineární funkcí  $\theta$ . 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  $\mathbf{A} = [a_{ij}] = [\varphi_j(x_i)]$ .

## 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  $\varphi_j$  jsou monomy proměnných  $x_1, \dots, x_d$

**Pozor! Pořád jde o lineární regresi, protože  $f$  je lineární v parametrech  $\theta$ .**

# **Statistický pohled na úlohu nejmenších čtverců**

---

$$\mathbf{y} = \mathbf{Ax} + \boldsymbol{\epsilon}$$

- $\mathbf{x} = (x_1, \dots, x_n)$  jsou odhadované (nepozorovatelné) parametry
- $\mathbf{y} = (y_1, \dots, y_m)$  jsou naměřené (pozorované) parametry
- $\boldsymbol{\epsilon} = (\epsilon_1, \dots, \epsilon_m)$  jsou náhodné chyby (šum, chyby měření, neznalost modelu)

Předpoklady na náhodné chyby:

- nulové střední hodnoty:  $E[\epsilon_i] = 0$  pro každé  $i$
- stejné variance:  $E[\epsilon_i^2] = \sigma^2$  pro každé  $i$
- náhodné chyby jsou nekorelované:  $E[\epsilon_i \epsilon_j] = 0$  pro každé  $i \neq j$

Neboli

$$\begin{aligned} E[\boldsymbol{\epsilon}] &= \mathbf{0} \\ E[\boldsymbol{\epsilon}\boldsymbol{\epsilon}^T] &= \sigma^2 \mathbf{I} \end{aligned}$$

# Lineární estimátor

Lineární model:

$$\mathbf{y} = \mathbf{Ax} + \epsilon$$

**Lineární estimátor** ('odhadovač'): Odhad  $\mathbf{x}$  jako lineární funkce  $\mathbf{y}$ :

$$\hat{\mathbf{x}} = \mathbf{By}$$

- Střední hodnota odhadu:

$$E[\hat{\mathbf{x}}] = E[\mathbf{By}] = E[\mathbf{B}(\mathbf{Ax} + \epsilon)] = \mathbf{BAx} + \mathbf{BE}[\epsilon] = \mathbf{BAx}$$

Estimátor je **nevychýlený**, jestliže  $E[\hat{\mathbf{x}}] = \mathbf{x}$  pro všechna  $\mathbf{x}$ .

To platí právě když  $\mathbf{BA} = \mathbf{I}$ , tj.  $\mathbf{B}$  je levá inverze  $\mathbf{A}$ .

Potom  $\hat{\mathbf{x}} = \mathbf{B}(\mathbf{Ax} + \epsilon) = \mathbf{x} + \mathbf{B}\epsilon$ .

- Variance (přesněji: kovarianční matice) nevychýleného odhadu:

$$E[(\hat{\mathbf{x}} - \mathbf{x})(\hat{\mathbf{x}} - \mathbf{x})^T] = E[\mathbf{B}\epsilon\epsilon^T\mathbf{B}^T] = \mathbf{BE}[\epsilon\epsilon^T]\mathbf{B}^T = \sigma^2\mathbf{BB}^T$$

## Estimátor metodou nejm. čtverců (least-squares estimator)

Pro LS (least-squares) estimátor máme

$$\mathbf{B} = \mathbf{A}^+ = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$$

- LS estimátor je nevychýlený, neboť  $\mathbf{A}^+ \mathbf{A} = \mathbf{I}$ .
- Variance odhadu:

$$\mathbb{E}[(\hat{\mathbf{x}} - \mathbf{x})(\hat{\mathbf{x}} - \mathbf{x})^T] = \sigma^2 \mathbf{A}^+ (\mathbf{A}^+)^T = \sigma^2 (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A} (\mathbf{A}^T \mathbf{A})^{-1} = \sigma^2 (\mathbf{A}^T \mathbf{A})^{-1}$$

## Příklad

**Motivace:** Máme  $m$  stejných kuliček a studnu. Chceme odhadnout čas  $x$ , jak dlouho padá kulička do studny.

Model pro  $n = 1$ ,  $\mathbf{A} = \mathbf{1}$ :

$$\mathbf{y} = \mathbf{1}x + \boldsymbol{\epsilon} \quad \text{neboli} \quad y_i = x + \epsilon_i$$

- LS odhad je aritmetický průměr:

$$\hat{x} = \mathbf{A}^+ \mathbf{y} = \frac{1}{m} \mathbf{1}^T \mathbf{y} = \frac{1}{m} \sum_{i=1}^m y_i$$

- variance:

$$E[(\hat{\mathbf{x}} - \mathbf{x})(\hat{\mathbf{x}} - \mathbf{x})^T] = \sigma^2 (\mathbf{A}^T \mathbf{A})^{-1} = \sigma^2 (\mathbf{1}^T \mathbf{1})^{-1} = \frac{\sigma^2}{m}$$

Intuice: Provedu-li  $m$  nepřesných měření veličiny  $x$  a výsledek zprůměruju, variance ('neurčitost') odhadu veličiny klesne  $m$ -krát.



## Příklad

**Motivace:** Mám pružinu a předpokládám Hookeův zákon: síla  $F$  tahu pružiny závisí na délce  $d$  pružiny jako  $F = kd$ . Chci odhadnout  $k$ .

Zde je opět  $n = 1$ .

# LS estimátor je BLUE (Gauss-Markov theorem)

Částečné uspořádání  $\preceq$  pro čtvercové symetrické matice  $n \times n$ :

- $\mathbf{K} \preceq \mathbf{L}$  značí, že matice  $\mathbf{K} - \mathbf{L}$  je pozitivně semidefinitní
- Tj. pro každé  $\mathbf{z} \in \mathbb{R}^{n \times n}$  platí  $\mathbf{z}^T \mathbf{K} \mathbf{z} \leq \mathbf{z}^T \mathbf{L} \mathbf{z}$ .
- Tj.  $\mathbf{K}$  je 'menší' než  $\mathbf{L}$ .
- Tj. náhodný vektor s variancí  $\mathbf{K}$  je 'méně nerčitý' než náh. vektor s variancí  $\mathbf{L}$ .

## Věta (Gauss-Markov)

Pro všechny matice  $\mathbf{A}, \mathbf{B}$  splňující  $\mathbf{B}\mathbf{A} = \mathbf{I}$  platí  $\mathbf{A}^+(\mathbf{A}^+)^T \preceq \mathbf{B}\mathbf{B}^T$ .

**Důkaz:**

- Každý projektor  $\mathbf{P}$  splňuje  $\mathbf{0} \preceq \mathbf{P} \preceq \mathbf{I}$ .
- Tedy  $\mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \preceq \mathbf{I}$ , tj. pro každé  $\mathbf{y}$  je  $\mathbf{y}^T \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y} \leq \mathbf{y}^T \mathbf{y}$ .
- Speciálně, pro  $\mathbf{y} = \mathbf{B}^T \mathbf{z}$  je  $\mathbf{z}^T \mathbf{B} \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{B}^T \mathbf{z} = \mathbf{z}^T (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{z} \leq \mathbf{z}^T \mathbf{B} \mathbf{B}^T \mathbf{z}$ .

Tedy: LS estimátor je **best linear unbiased estimator (BLUE)**.

Další vhléd:

- $\mathbf{A}^+(\mathbf{A}^+)^T \preceq \mathbf{B}\mathbf{B}^T$  implikuje  $\|\mathbf{A}^+\| \leq \|\mathbf{B}\|$  (kde  $\|\mathbf{B}\|^2 = \text{tr}(\mathbf{B}\mathbf{B}^T) = \sum_{i,j} b_{ij}^2$ )
- Intuice: Pro menší  $\|\mathbf{B}\|$  mají chyby  $\epsilon$  menší vliv na odhad  $\hat{\mathbf{x}} = \mathbf{x} + \mathbf{B}\epsilon$ .

# Řešení lineární soustavy s nejmenší normou

---

## Řešení 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  $x^2 + y^2 + z^2$ .

Je-li  $\mathbf{Ax}_0 = \mathbf{b}$ , pak  $\{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{b}\} = \mathbf{x}_0 + \text{null } \mathbf{A}$ .



Řešení  $\mathbf{x}$  má nejmenší normu, právě když  $\mathbf{x} \perp \text{null } \mathbf{A}$ , tj.  $\mathbf{x} \in (\text{null } \mathbf{A})^\perp = \text{rng}(\mathbf{A}^T)$ , tj.  $\mathbf{x} = \mathbf{A}^T \mathbf{y}$  pro nějaké  $\mathbf{y}$ . Tedy řešíme soustavu

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

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

Řešení: Dosazení dá  $\mathbf{AA}^T \mathbf{y} = \mathbf{b}$ . Má-li  $\mathbf{A}$  l.n. řádky, máme  $\mathbf{y} = (\mathbf{AA}^T)^{-1} \mathbf{b}$ . 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  $\mathbf{AA}^+ = \mathbf{AA}^T (\mathbf{AA}^T)^{-1} = \mathbf{I}$ ).

## Úloha

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

a příbuzné úlohy mají velmi mnoho aplikací. Mnoho jich je popsáno v této knize (zdarma ke stažení, viz doplňující literatura na CW):

