

LINEÁRNÍ ALGEBRA PRO POKROČILÉ


MARTIN ČERNÝ, PETER ZEMAN

KAM.MFF.CUNI.CZ/~CERNY
CERNY@KAM.MFF.CUNI.CZ


MAY 9, 2022

POZITIVNĚ DEFINITNÍ MATICE: EXTRÉMY A ENERGIE

- Jak hledat extrémy funkcí?
 - ▶ potřebné pro pochopení chování funkce, optimalizační úlohy
- Aproximací pomocí polynomů
 - ▶ místo funkce zvolíme speciální polynom
 - ▶ nejlepší lokální aproximace




MOTIVACE




- Kandidáti na extrém: body \mathbf{x} s $f'(\mathbf{x}) = 0$
 - ▶ lineární funkce má extrém pokud je konstantní
- ověříme kandidáty pomocí kvadratických aproximací

$$f''(x) > 0$$




kvadratická
aproximace

$$f''(x) < 0$$



$$f''(x) = 0$$



- lokální minimum lokální maximum nevíme

- v posledním případě můžeme derivovat dále a dozvědět se více

■ derivace \sim nejlepší lokální aproximace pomocí polynomu

■ **Taylorův polynom**

■ $T_f(\mathbf{x}) = f(\mathbf{o}) + f'(\mathbf{o})\mathbf{x} + \frac{f''(\mathbf{o})}{2!}\mathbf{x}^2 + \frac{f^{(3)}(\mathbf{o})}{3!}\mathbf{x}^3 + \dots$


▶ lokálně převládne první nenulový člen $\frac{f^{(k)}(\mathbf{o})}{k!}\mathbf{x}^k$

1. k liché ... inflexní bod
2. k sudé ... extrém

FUNKCE VÍCE PROMĚNNÝCH $f(x_1, \dots, x_n)$

■ stejná myšlenka

- ▶ parciální derivace $\frac{\delta f}{\delta x_i}(\mathbf{y})$



- kandidát *není extrém*

- Kandidáti na extrém: body $\mathbf{y} : \frac{\delta f}{\delta x_1}(\mathbf{y}) = 0, \dots, \frac{\delta f}{\delta x_n}(\mathbf{y}) = 0$


FUNKCE VÍCE PROMĚNNÝCH $f(x_1, \dots, x_n)$

- stejná myšlenka

- ▶ parciální derivace $\frac{\delta f}{\delta x_i}(\mathbf{y})$

- Kandidáti na extrém: body $\mathbf{y} : \frac{\delta f}{\delta x_1}(\mathbf{y}) = 0, \dots, \frac{\delta f}{\delta x_n}(\mathbf{y}) = 0$

- tečný kvadratický polynom $P(\mathbf{x})$



lokální kvadratická
aproximace

- $P(\mathbf{x}) = P(x_1, \dots, x_n) = \sum_{i,j} \frac{\delta^2 f(\mathbf{y})}{\delta x_i \delta x_j} x_i x_j = \sum_i \frac{\delta^2 f(\mathbf{y})}{\delta x_i^2} x_i^2 + 2 \sum_{i < j} \frac{\delta^2 f(\mathbf{y})}{\delta x_i \delta x_j} x_i x_j$

- ▶ $\frac{\delta^2 f(\mathbf{y})}{\delta x_i^2} x_i^2, \frac{\delta^2 f(\mathbf{y})}{\delta x_i \delta x_j}$... koeficienty $P(\mathbf{x})$

- Zajímají nás lokální i globální chování $P(\mathbf{x})$

1. $\forall \mathbf{x} : P(\mathbf{x}) > 0 \dots$ **pozitivně definitní**
 - ▶ lokální minimum
2. $\forall \mathbf{x} : P(\mathbf{x}) < 0 \dots$ **negativně definitní**
 - ▶ lokální maximum
3. $\forall \mathbf{x} : P(\mathbf{x}) \geq 0 \dots$ **pozitivně semidefinitní**
 - ▶ nevíme, potřeba aproximace vyšších řádů
4. $\forall \mathbf{x} : P(\mathbf{x}) \leq 0 \dots$ **negativně semidefinitní**
 - ▶ nevíme, potřeba aproximace vyšších řádů
5. $\exists \mathbf{x}, \exists \mathbf{y} : P(\mathbf{x}) < 0, P(\mathbf{y}) > 0 \dots$ **indefinitní**
 - ▶ není extrém

TYPY $P(x_1, x_2)$

- existuje 6 typů (Sylvestrova věta o setrvačnosti):

$$x_1^2 + x_2^2$$



pozitivně def.

$$-x_1^2 - x_2^2$$



negativně def.

$$x_1^2 - x_2^2$$



indefinitní

$$x_1^2$$



pozitivně
semidef.

$$-x_1^2$$



negativně
semidef.

$$0$$



pozitivně i
negativně
semidef.

- ▶ $P(x_1, x_2) = x_1 x_2$ je sedlo otočené o 45°

- **Otázka:** Jak zjistit typ daného polynomu?

$$\blacksquare P(\mathbf{x}) = P(x_1, \dots, x_n) = \sum_{i,j} \frac{\delta^2 f(\mathbf{y})}{\delta x_i \delta x_j} x_i x_j = \sum_i \frac{\delta^2 f(\mathbf{y})}{\delta x_i^2} x_i^2 + 2 \sum_{i < j} \frac{\delta^2 f(\mathbf{y})}{\delta x_i \delta x_j} x_i x_j$$

$$\blacksquare \text{matice } A : a_{ij} = \frac{\delta^2 f(\mathbf{y})}{\delta x_i \delta x_j}$$

$$\blacksquare P(\mathbf{x}) = \mathbf{x}^T A \mathbf{x} \dots \text{kvadratická forma}$$

■ předpokládáme symetrické matice A


$$\blacksquare \implies P(\mathbf{x}) = \sum_i a_{ii} x_i^2 + 2 \sum_{i < j} a_{ij} x_i x_j$$

1. A je **pozitivně definitní** (SPD), pokud $\mathbf{x}^T A \mathbf{x} > 0 \forall \mathbf{x} \neq \mathbf{0}$
2. A je **negativně definitní** (SND), pokud $\mathbf{x}^T A \mathbf{x} < 0 \forall \mathbf{x} \neq \mathbf{0}$
3. A je **pozitivně semidefinitní** (PSD), pokud $\mathbf{x}^T A \mathbf{x} \geq 0$
4. A je **negativně semidefinitní** (NSD), pokud $\mathbf{x}^T A \mathbf{x} \leq 0$
5. A je **indefinitní** (ID), pokud $\exists \mathbf{x}, \mathbf{y} : \mathbf{x}^T A \mathbf{x} < 0$ a $\mathbf{y}^T A \mathbf{y} > 0$

1. A je **pozitivně definitní** (SPD), pokud $\mathbf{x}^T A \mathbf{x} > 0 \forall \mathbf{x} \neq \mathbf{0}$
2. A je **negativně definitní** (SND), pokud $\mathbf{x}^T A \mathbf{x} < 0 \forall \mathbf{x} \neq \mathbf{0}$
3. A je **pozitivně semidefinitní** (PSD), pokud $\mathbf{x}^T A \mathbf{x} \geq 0$
4. A je **negativně semidefinitní** (NSD), pokud $\mathbf{x}^T A \mathbf{x} \leq 0$
5. A je **indefinitní** (ID), pokud $\exists \mathbf{x}, \mathbf{y} : \mathbf{x}^T A \mathbf{x} < 0$ a $\mathbf{y}^T A \mathbf{y} > 0$
 - typ matice lze rozeznat efektivně řadou kritérií
 - speciálně se zaměříme na SPD

Charakterizace pozitivní definitnosti

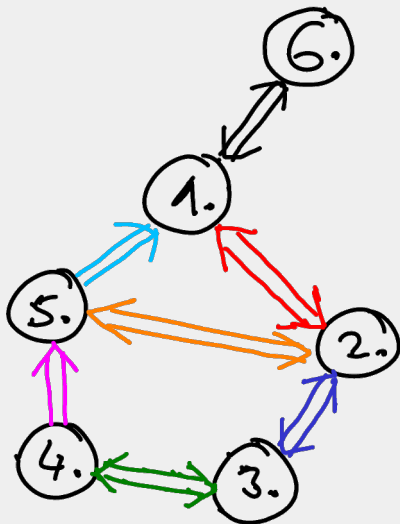
1. $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0 \quad \forall \mathbf{x} \neq \mathbf{0}$
2. vlastní čísla $\lambda_i > 0$
3. determinanty principiálních minorů jsou kladné:
 $\det(A_1) > 0, \dots, \det(A_n) > 0$



- ▶ principiální minor A_k je podmatice $k \times k$ v levém horním rohu
4. Gaussova eliminace lze provést bez *prohazování řádků a násobení* a má všechny *pivoty* $p_i > 0$
 5. existuje regulární matice R , že $A = R^T R$
 6. $\langle \mathbf{x}, \mathbf{y} \rangle = \mathbf{x}^T \mathbf{A} \mathbf{y}$ je skalární součin a $\|\mathbf{x}\| = \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$ je norma

CHARAKTERIZACE POZITIVNÍ DEFINITNOSTI

- Dokážeme si co nejvíce směrů:



Charakterizace pozitivní definitnosti 1 \Rightarrow 2

1. $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0 \quad \forall \mathbf{x} \neq \mathbf{0}$
2. vlastní čísla $\lambda_i > 0$

Důkaz:

- ze symetrie jsou všechna vlastní čísla reálná
- $\mathbf{A} \mathbf{x} = \lambda \mathbf{x}$
- $\lambda = \frac{\mathbf{x}^T \mathbf{A} \mathbf{x}}{\mathbf{x}^T \mathbf{x}}$
 - ▶ $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0 \dots A$ je SPD
 - ▶ $\mathbf{x}^T \mathbf{x} = \|\mathbf{x}\|^2 > 0$
- $\lambda > 0$

Charakterizace pozitivní definitnosti 1 \Leftrightarrow 2

1. $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0 \quad \forall \mathbf{x} \neq \mathbf{0}$
2. vlastní čísla $\lambda_i > 0$

Důkaz:

- ze symetrie spektrální rozklad $A = Q \Lambda Q^T$
 - ▶ $\mathbf{q}_1, \dots, \mathbf{q}_n$... ortogonální báze z vlastních vektorů
- $\mathbf{x} = \sum \alpha_i \mathbf{q}_i$
- $\mathbf{x}^T \mathbf{A} \mathbf{x} = (\sum \alpha_i \mathbf{q}_i)^T A (\sum \alpha_i \mathbf{q}_i) =$
- $= \sum_{i,j} \alpha_i \alpha_j \mathbf{q}_i^T A \mathbf{q}_j = \sum_{i,j} \lambda_j \alpha_i \alpha_j \mathbf{q}_i^T \mathbf{q}_j =$
- $= \sum_i \lambda_i \alpha_i^2 \mathbf{q}_i^T \mathbf{q}_i = \sum_i \lambda_i \alpha_i^2 > 0$

Charakterizace pozitivní definitnosti 2 \iff 3

2. vlastní čísla $\lambda_j > 0$
3. determinanty principiálních minorů jsou kladné:
 $\det(A_1) > 0, \dots, \det(A_n) > 0$



- ▶ principiální minor A_k je podmatice $k \times k$ v levém horním rohu

Důkaz:


- pomůžeme si tvrzením o prolétání vlastní čísel

O proplétání vlastních čísel

Nechť A je symetrická a B vznikne z A vyškrtnutím i -tého řádku a sloupce. Nechť $\lambda_1 \geq \dots \geq \lambda_n$ jsou vlastní čísla A a $\sigma_1 \geq \dots \geq \sigma_{n-1}$ vlastní čísla B . Potom

$$\lambda_1 \geq \sigma_1 \geq \lambda_2 \geq \sigma_2 \geq \dots \geq \lambda_{n-1} \geq \sigma_{n-1} \geq \lambda_n.$$

$$\underline{\lambda_i \geq G_i \geq \lambda_{i+1}.}$$



Důkaz:

- příští cvičení

Charakterizace pozitivní definitnosti 2 \Rightarrow 3

- vlastní čísla $\lambda_i > 0$
- determinanty principiálních minorů jsou kladné:
 $\det(A_1) > 0, \dots, \det(A_n) > 0$



- ▶
- ▶ principiální minor A_k je podmatice $k \times k$ v levém horním rohu

Důkaz:

- podle věty o proplétání jsou vlastní čísla všech minorů A_k mezi λ_1 a λ_n , tedy kladná
- $\det(A_k) > 0$


CHARAKTERIZACE POZITIVNÍ DEFINITNOSTI 2 \Leftrightarrow 3

Charakterizace pozitivní definitnosti 2 \Leftrightarrow 3

- vlastní čísla $\lambda_j > 0$
- determinanty principiálních minorů jsou kladné:
 $\det(A_1) > 0, \dots, \det(A_n) > 0$
 - ▶ principiální minor A_k je podmatice $k \times k$ v levém horním rohu

Důkaz:

- indukci podle A_k
- $\det(A_1) > 0 \implies$ vlastní číslo A_1 je kladné
- A_k má vlastní čísla kladné
- \implies A_{k+1} má max jedno vlastní číslo λ_{min} záporné



- potom $\det(A_{k+1}) > 0 \implies \lambda_{min} > 0$

Charakterizace pozitivní definitnosti 3 \Rightarrow 4

- determinanty principiálních minorů jsou kladné:
 $\det(A_1) > 0, \dots, \det(A_n) > 0$
 - ▶ principiální minor A_k je podmatice $k \times k$ v levém horním rohu
- Gaussova eliminace lze provést bez *prohazování řádků a násobení* a má všechny *pivoty* $p_i > 0$

Důkaz:

- $\det(A_k) > 0 \implies A_k$ je regulární
- lze provést GE bez prohazování řádků
- úpravy nemění determinant: $\det(A_k) = \prod_{i=1}^k p_i$
- proto $p_k = \frac{\det(A_k)}{\det(A_{k-1})} > 0$

Charakterizace pozitivní definitnosti 3 \iff 4

3. determinanty principiálních minorů jsou kladné:
 $\det(A_1) > 0, \dots, \det(A_n) > 0$
 - ▶ principiální minor A_k je podmatice $k \times k$ v levém horním rohu
4. Gaussova eliminace lze provést bez *prohazování řádků a násobení* a má všechny *pivoty* $p_i > 0$

Důkaz:

- G-E nemění determinant žádné podmatice A_k

- $\implies \det(A_k) = \prod_{i=1}^k p_i > 0$

Charakterizace pozitivní definitnosti $4 \Rightarrow 5$

4. Gaussova eliminace lze provést bez *prohazování řádků a násobení* a má všechny *pivoty* $p_i > 0$
5. existuje regulární matice R , že $A = R^T R$

Důkaz:

- ukážeme pomocí LDU dekompozice
- $A = LDU = U^T D U$
 - ▶ L ... matice úprav
 - ▶ D ... diagonální matice s p_i na diagonále
 - ▶ druhá rovnost ze symetrie A
- Potřebujeme *rozdělit* D
- $\exists \sqrt{D}$ s diagonálou $\sqrt{p_i}$
- $R = \sqrt{D} U$
- $A = R^T R$

Charakterizace pozitivní definitnosti 1 \Leftrightarrow 5

1. $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0 \quad \forall \mathbf{x} > 0$
5. existuje regulární matice R , že $A = R^T R$

Důkaz:

- dosazení $R^T R$ za A
- $\mathbf{x}^T \mathbf{A} \mathbf{x} = \mathbf{x}^T R^T R \mathbf{x} = (R \mathbf{x})^T (R \mathbf{x}) = \|R \mathbf{x}\|^2 = \|\mathbf{s}\|_A > 0$
- **Poznámka:** Kvadratická forma s pozitivně definitní maticí určuje čtverec nějaké normy

Charakterizace pozitivní definitnosti $2 \Rightarrow 5$

2. vlastní čísla $\lambda_j > 0$
5. existuje regulární matice R , že $A = R^T R$

Důkaz:

- uvažujme spektrální rozklad $A = Q\Lambda Q^T$
- Λ má kladnou diagonálu
- $R = \sqrt{\Lambda}Q^T$
 - ▶ $\sqrt{\Lambda}$ s diagonálou $\sqrt{\lambda_1}, \dots, \sqrt{\lambda_n}$

Charakterizace pozitivní definitnosti 2 \Leftrightarrow 5

2. vlastní čísla $\lambda_i > 0$
5. existuje regulární matice R , že $A = R^T R$

Důkaz:

- $A\mathbf{x} = \lambda\mathbf{x}$
- $\lambda = \frac{\mathbf{x}^T A \mathbf{x}}{\mathbf{x}^T \mathbf{x}} = \frac{\|R\mathbf{x}\|^2}{\|\mathbf{x}\|^2} = \frac{\|\mathbf{x}\|_A^2}{\|\mathbf{x}\|^2} > 0$
 - ▶ podíl čtverců norem

DŮLEŽITOST POZITIVNĚ DEFINITNÍCH MATIC

1. propojují celou lineární algebru

- ▶ díky speciálním vlastnostem
- ▶ řada problémů jednodušší: $A\mathbf{x} = \mathbf{b}$, $A\mathbf{x} = \lambda\mathbf{x}$

2. Statistika

- ▶ *Kovarianční matice* jsou pozitivně definitní
- ▶ popisují lineární závislost veličin
- ▶ ve fyzice k modelování energie

DŮLEŽITOST POZITIVNĚ DEFINITNÍCH MATIC

1. propojují celou lineární algebru

- ▶ díky speciálním vlastnostem
- ▶ řada problémů jednodušší: $A\mathbf{x} = \mathbf{b}$, $A\mathbf{x} = \lambda\mathbf{x}$

2. Statistika

- ▶ *Kovarianční matice* jsou pozitivně definitní
- ▶ popisují lineární závislost veličin
- ▶ ve fyzice k modelování energie

3. Metody optimalizace a řešení soustav

Nechť A je pozitivně definitní. Potom \mathbf{x} minimalizuje $\mathbf{x}^T A \mathbf{x} - \mathbf{x}^T \mathbf{b} \iff$ je řešením $A\mathbf{x} = \mathbf{b}$.