

# Optimalizace

## 12. Konvexní funkce a konvexní optimalizace

---

Tom Werner, Tom Kroupa

FEL ČVUT

# Konvexní funkce

---

# Konvexní funkce


## Definice

Nechť  $X \subseteq \mathbb{R}^n$  je konvexní množina.

Funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je **konvexní** na  $X$ , jestliže pro každá  $\mathbf{x}, \mathbf{y} \in X$  a  $\alpha \in [0, 1]$  je

$$f((1 - \alpha)\mathbf{x} + \alpha\mathbf{y}) \leq (1 - \alpha)f(\mathbf{x}) + \alpha f(\mathbf{y}).$$

Funkce  $f$  je **konkávní** na  $X$ , jestliže funkce  $-f$  je konvexní na  $X$ .



# Konvexní funkce


## Definice

Nechť  $X \subseteq \mathbb{R}^n$  je konvexní množina.

Funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je **konvexní** na  $X$ , jestliže pro každá  $\mathbf{x}, \mathbf{y} \in X$  a  $\alpha \in [0, 1]$  je

$$f((1 - \alpha)\mathbf{x} + \alpha\mathbf{y}) \leq (1 - \alpha)f(\mathbf{x}) + \alpha f(\mathbf{y}).$$

Funkce  $f$  je **konkávní** na  $X$ , jestliže funkce  $-f$  je konvexní na  $X$ .



Ekvivalentní podmínka (**Jensenova nerovnost**):

Pro každé  $\mathbf{x}_1, \dots, \mathbf{x}_k \in X$  a  $\alpha_1, \dots, \alpha_k \geq 0$  kde  $\alpha_1 + \dots + \alpha_k = 1$  je

$$f(\alpha_1\mathbf{x}_1 + \dots + \alpha_k\mathbf{x}_k) \leq \alpha_1 f(\mathbf{x}_1) + \dots + \alpha_k f(\mathbf{x}_k).$$


# Podmínka konvexity pro diferencovatelné funkce

## Věta (podmínka prvního řádu na konvexitu funkce)

Nechť funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je diferencovatelná.

Funkce  $f$  je konvexní, právě když pro všechna  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  platí

$$f(\mathbf{y}) \geq f(\mathbf{x}) + f'(\mathbf{x})(\mathbf{x} - \mathbf{y}).$$




# Podmínka konvexity pro diferencovatelné funkce

## Věta (podmínka prvního řádu na konvexitu funkce)

Nechť funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je diferencovatelná.

Funkce  $f$  je konvexní, právě když pro všechna  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  platí

$$f(\mathbf{y}) \geq f(\mathbf{x}) + f'(\mathbf{x})(\mathbf{x} - \mathbf{y}).$$



## Věta (podmínka druhého řádu na konvexitu funkce)

Nechť  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je dvakrát diferencovatelná. Funkce  $f$  je konvexní, právě když je pro každé  $\mathbf{x} \in \mathbb{R}^n$  Hessián  $f''(\mathbf{x})$  pozitivně semidefinitní.

## Příklady konvexních funkcí

- $f(x) = e^{ax}$  pro  $a \in \mathbb{R}$
- $f(x) = |x|^a$  pro  $a \geq 1$
- $f(\mathbf{x}) = \mathbf{x}^T \mathbf{A} \mathbf{x}$  pro  $\mathbf{A}$  pozitivně semidefinitní
- $f(\mathbf{x}) = \mathbf{a}^T \mathbf{x} + b$
- $f(\mathbf{x}) = \max \{x_1, \dots, x_n\}$
- libovolná norma

## Vztah konvexní funkce a konvexní množiny

- **Epigraf** funkce  $f: X \rightarrow \mathbb{R}$  je množina  $\{(\mathbf{x}, y) \in X \times \mathbb{R} \mid f(\mathbf{x}) \leq y\}$ .
- **Subkontura** výšky  $y$  funkce  $f$  je množina  $\{\mathbf{x} \in X \mid f(\mathbf{x}) \leq y\}$ .





# Vztah konvexní funkce a konvexní množiny

- **Epigraf** funkce  $f: X \rightarrow \mathbb{R}$  je množina  $\{(\mathbf{x}, y) \in X \times \mathbb{R} \mid f(\mathbf{x}) \leq y\}$ .
- **Subkontura** výšky  $y$  funkce  $f$  je množina  $\{\mathbf{x} \in X \mid f(\mathbf{x}) \leq y\}$ .

## Tvrzení

- Funkce je konvexní, právě když její epigraf je konvexní množina.
- Každá subkontura konvexní funkce je konvexní množina.



**Pozor:** Jsou-li všechny subkontury funkce konvexní množiny, funkce nemusí být konvexní.

# Operace zachovávající konvexitu

## Nezáporné lineární kombinace

Jsou-li  $g_1, \dots, g_k: \mathbb{R}^n \rightarrow \mathbb{R}$  konvexní funkce a  $\alpha_1, \dots, \alpha_k \geq 0$ , pak funkce

$$f = \alpha_1 g_1 + \dots + \alpha_k g_k$$

je konvexní.

# Operace zachovávající konvexitu

## Nezáporné lineární kombinace

Jsou-li  $g_1, \dots, g_k: \mathbb{R}^n \rightarrow \mathbb{R}$  konvexní funkce a  $\alpha_1, \dots, \alpha_k \geq 0$ , pak funkce

$$f = \alpha_1 g_1 + \dots + \alpha_k g_k$$

je konvexní.

## Skládání funkcí

Následující funkce jsou konvexní:

- $h = g \circ f$ , kde  $f: \mathbb{R} \rightarrow \mathbb{R}$  je konvexní a  $g: \mathbb{R} \rightarrow \mathbb{R}$  je konvexní a neklesající.
- $h(\mathbf{x}) = g(\mathbf{Ax} + \mathbf{b})$ , kde  $g: \mathbb{R}^m \rightarrow \mathbb{R}$  je konvexní.

**Pozor:** Složení konvexních funkcí obecně nemusí být konvexní funkce.

## Věta

Nechť  $g_i: \mathbb{R}^n \rightarrow \mathbb{R}$  jsou konvexní funkce pro všechna  $i \in I$ . Pak

$$f(\mathbf{x}) = \max_{i \in I} g_i(\mathbf{x})$$

je konvexní funkce (předpokládáme, že pro každé  $\mathbf{x} \in \mathbb{R}^n$  maximum existuje).

**Důkaz:** Ukážeme (není těžké), že epigraf funkce  $f$  je průnik epigrafů funkcí  $g_i$ .

Z toho plyne, že epigraf funkce  $f$  je konvexní množina. Tedy  $f$  je konvexní funkce.

Věta platí, i když nahradíme maximum supremem.

## Věta

Nechť  $g_i: \mathbb{R}^n \rightarrow \mathbb{R}$  jsou konvexní funkce pro všechna  $i \in I$ . Pak

$$f(\mathbf{x}) = \max_{i \in I} g_i(\mathbf{x})$$

je konvexní funkce (předpokládáme, že pro každé  $\mathbf{x} \in \mathbb{R}^n$  maximum existuje).

**Důkaz:** Ukážeme (není těžké), že epigraf funkce  $f$  je průnik epigrafů funkcí  $g_i$ .

Z toho plyne, že epigraf funkce  $f$  je konvexní množina. Tedy  $f$  je konvexní funkce.

Věta platí, i když nahradíme maximum supremem.

**Příklady** (funkce jsou konvexní na  $\mathbb{R}^n$ ):

- $f(\mathbf{x}) = \max\{x_1, \dots, x_n\}$
- $f(\mathbf{x}) = \max_{i=1}^k (\mathbf{a}_i^T \mathbf{x} + b_i)$
- $f(\mathbf{y}) = \max_{\mathbf{x} \in X} \|\mathbf{x} - \mathbf{y}\|$  (kde  $X \subseteq \mathbb{R}^n$  je libovolná kompaktní množina)
- $f(\mathbf{c}) = \max_{\mathbf{x} \in X} \mathbf{c}^T \mathbf{x}$  (kde  $X \subseteq \mathbb{R}^n$  je libovolná kompaktní množina)

# Konvexní optimalizační úlohy

---

# Konvexní optimalizační úloha

**Konvexní optimalizační úloha** je

$$\min_{\mathbf{x} \in X} f(\mathbf{x})$$

kde  $X \subseteq \mathbb{R}^n$  je konvexní množina a  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je konvexní funkce na množině  $X$ .

# Konvexní optimalizační úloha

**Konvexní optimalizační úloha** je

$$\min_{\mathbf{x} \in X} f(\mathbf{x})$$

kde  $X \subseteq \mathbb{R}^n$  je konvexní množina a  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je konvexní funkce na množině  $X$ .

## Věta

Nechť funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je konvexní na konvexní množině  $X \subseteq \mathbb{R}^n$ .

Pak každé lokální minimum funkce  $f$  na množině  $X$  je globální.

Tedy konvexní úlohu vyřešíme nalezením libovolného lokálního minima!



# Konvexní optimalizační úloha ve standardním tvaru

## Tvrzení

Úloha

$$\begin{aligned} \min \quad & f(\mathbf{x}) \\ \text{za podmíněk} \quad & g_i(\mathbf{x}) \leq 0, \quad i = 1, \dots, m \\ & h_i(\mathbf{x}) = 0, \quad i = 1, \dots, \ell \\ & \mathbf{x} \in \mathbb{R}^n \end{aligned}$$

je konvexní, jestliže funkce  $f, g_1, \dots, g_m$  jsou konvexní a  $h_1, \dots, h_\ell$  jsou afinní.

**Důkaz:** Množina přípustných řešení je průnik konvexních množin:

$$X = \underbrace{\bigcap_{i=1}^m \{ \mathbf{x} \in \mathbb{R}^n \mid g_i(\mathbf{x}) \leq 0 \}}_{\text{subkontura konv. fce}} \cap \underbrace{\bigcap_{i=1}^{\ell} \{ \mathbf{x} \in \mathbb{R}^n \mid h_i(\mathbf{x}) = 0 \}}_{\text{nadrovina}}$$

Tato podmínka je postačující ale ne nutná pro konvexitu úlohy.

Příklad: Množina

$$X = \{ (x, y) \in \mathbb{R}^2 \mid (x + y)^2 = 0 \}$$

je konvexní, ale  $h(x, y) = (x + y)^2$  není afinní.

# Třídy konvexních optimalizačních úloh

- Lineární programování (LP):  
 $f, g_i, h_i$  afinní
- Kvadratické programování (QP):  
 $f$  kvadratická konvexní,  $g_i, h_i$  afinní
- Kvadratické programování s kvadratickými omezeními (QCQP):  
 $f, g_i$  kvadratické konvexní,  $h_i$  afinní
- Programování na kuželu druhého řádu (SOCP)
- Semidefinitní programování (SDP)

# Kvadratické programování (QP)

Funkce  $f$  je kvadratická, funkce  $g_i, h_i$  jsou afinní.

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} \\ \text{za podm.} \quad & \mathbf{C} \mathbf{x} \leq \mathbf{d} \\ & \mathbf{E} \mathbf{x} = \mathbf{f} \end{aligned}$$

Je to konvexní úloha, právě když  $\mathbf{A}$  je pozitivně semidefinitní.

# Kvadratické programování (QP)

Funkce  $f$  je kvadratická, funkce  $g_i, h_i$  jsou afinní.

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} \\ \text{za podm.} \quad & \mathbf{C} \mathbf{x} \leq \mathbf{d} \\ & \mathbf{E} \mathbf{x} = \mathbf{f} \end{aligned}$$

Je to konvexní úloha, právě když  $\mathbf{A}$  je pozitivně semidefinitní.

**Speciální případ:** chybí podmínky typu nerovnosti ( $\mathbf{C}, \mathbf{d}$  nulové):  
podmínka optimality prvního řádu je soustava lineárních rovnic.

# Kvadratické programování (QP)

Funkce  $f$  je kvadratická, funkce  $g_i, h_i$  jsou afinní.

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} \\ \text{za podm.} \quad & \mathbf{C} \mathbf{x} \leq \mathbf{d} \\ & \mathbf{E} \mathbf{x} = \mathbf{f} \end{aligned}$$

Je to konvexní úloha, právě když  $\mathbf{A}$  je pozitivně semidefinitní.

**Speciální případ:** chybí podmínky typu nerovnosti ( $\mathbf{C}, \mathbf{d}$  nulové):  
podmínka optimality prvního řádu je soustava lineárních rovnic.

**Příklad:** Řešení přeúčtené soustavy s omezeními typu lineárních rovností:

$$\min \{ \|\mathbf{A} \mathbf{x} - \mathbf{b}\|_2^2 \mid \mathbf{C} \mathbf{x} = \mathbf{d}, \mathbf{x} \in \mathbb{R}^n \}$$

# Kvadratické programování (QP)

Funkce  $f$  je kvadratická, funkce  $g_i, h_i$  jsou afinní.

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} \\ \text{za podm.} \quad & \mathbf{C} \mathbf{x} \leq \mathbf{d} \\ & \mathbf{E} \mathbf{x} = \mathbf{f} \end{aligned}$$

Je to konvexní úloha, právě když  $\mathbf{A}$  je pozitivně semidefinitní.

**Speciální případ:** chybí podmínky typu nerovnosti ( $\mathbf{C}, \mathbf{d}$  nulové):  
podmínka optimality prvního řádu je soustava lineárních rovnic.

**Příklad:** Řešení přeürčené soustavy s omezeními typu lineárních rovností:

$$\min \{ \|\mathbf{A} \mathbf{x} - \mathbf{b}\|_2^2 \mid \mathbf{C} \mathbf{x} = \mathbf{d}, \mathbf{x} \in \mathbb{R}^n \}$$

**Příklad** pro nenulové  $\mathbf{C}, \mathbf{d}$ : Řešení přeürčené soustavy s intervalovými omezeními

$$\min \{ \|\mathbf{A} \mathbf{x} - \mathbf{b}\|_2^2 \mid \mathbf{c} \leq \mathbf{x} \leq \mathbf{d}, \mathbf{x} \in \mathbb{R}^n \}$$

## Příklad na QP: Support Vector Machine (SVM)

Pro dané  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \in \mathbb{R}^n \times \{-1, +1\}$  hledáme **oddělující nadrovinu**, tedy hledáme  $\mathbf{a} \in \mathbb{R}^n$  a  $b \in \mathbb{R}$  tak, aby

$$\mathbf{a}^T \mathbf{x}_i > b \quad \text{pro } y_i = +1$$

$$\mathbf{a}^T \mathbf{x}_i < b \quad \text{pro } y_i = -1$$

neboli

$$y_i(\mathbf{a}^T \mathbf{x}_i - b) > 0 \quad i = 1, \dots, m$$

## Příklad na QP: Support Vector Machine (SVM)

Pro dané  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \in \mathbb{R}^n \times \{-1, +1\}$  hledáme **oddělující nadrovinu**, tedy hledáme  $\mathbf{a} \in \mathbb{R}^n$  a  $b \in \mathbb{R}$  tak, aby

$$\mathbf{a}^T \mathbf{x}_i > b \quad \text{pro } y_i = +1$$

$$\mathbf{a}^T \mathbf{x}_i < b \quad \text{pro } y_i = -1$$

neboli

$$y_i(\mathbf{a}^T \mathbf{x}_i - b) > 0 \quad i = 1, \dots, m$$

Vydělením  $(\mathbf{a}, b)$  vhodným kladným číslem je toto ekvivalentní

$$y_i(\mathbf{a}^T \mathbf{x}_i - b) \geq 1, \quad i = 1, \dots, m \quad (\star)$$



## Příklad na QP: Support Vector Machine (SVM)

Pro dané  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \in \mathbb{R}^n \times \{-1, +1\}$  hledáme **oddělující nadrovinu**, tedy hledáme  $\mathbf{a} \in \mathbb{R}^n$  a  $b \in \mathbb{R}$  tak, aby

$$\mathbf{a}^T \mathbf{x}_i > b \quad \text{pro } y_i = +1$$


$$\mathbf{a}^T \mathbf{x}_i < b \quad \text{pro } y_i = -1$$

neboli

$$y_i(\mathbf{a}^T \mathbf{x}_i - b) > 0 \quad i = 1, \dots, m$$

Vydělením  $(\mathbf{a}, b)$  vhodným kladným číslem je toto ekvivalentní

$$y_i(\mathbf{a}^T \mathbf{x}_i - b) \geq 1, \quad i = 1, \dots, m \quad (\star)$$



Aby šířka pásu byla co největší, minimalizujeme  $\|\mathbf{a}\|_2^2 = \mathbf{a}^T \mathbf{a}$  za podmíněk  $(\star)$ .<sub>12/23</sub>

# Kvadratické programování s kvadratickými omezeními (QCQP)

Funkce  $f, g_i$  jsou kvadratické,  $h_i$  jsou afinní.

Je to konvexní úloha, právě když funkce  $f, g_i$  jsou konvexní.

# Kvadratické programování s kvadratickými omezeními (QCQP)

Funkce  $f, g_i$  jsou kvadratické,  $h_i$  jsou afinní.

Je to konvexní úloha, právě když funkce  $f, g_i$  jsou konvexní.

**Příklad:** Nejmenší koule obsahující zadané body  $\mathbf{a}_1, \dots, \mathbf{a}_m \in \mathbb{R}^n$ :

$$\min_{\mathbf{x} \in \mathbb{R}^n} \max_{i=1}^m \|\mathbf{x} - \mathbf{a}_i\|_2$$

Je ekvivalentní QCQP úloze

$$\begin{aligned} \min \quad & y \\ \text{za podm.} \quad & \|\mathbf{x} - \mathbf{a}_i\|_2^2 \leq y \end{aligned}$$

# Programování na kuželu druhého řádu (SOCP)

$f, h_1, \dots, h_\ell$  afinní a

$$g_i(\mathbf{x}) = \|\mathbf{A}_i \mathbf{x} + \mathbf{b}_i\|_2 - (\mathbf{c}_i^T \mathbf{x} + d_i)$$

Podmínka  $g_i(\mathbf{x}) \leq 0$  se dá psát jako

$$\begin{bmatrix} \mathbf{A}_i \\ \mathbf{c}_i \end{bmatrix} \mathbf{x} + \begin{bmatrix} \mathbf{b}_i \\ d_i \end{bmatrix} \in K_2^{m_i}$$

kde  $\mathbf{A}_i \in \mathbb{R}^{m_i \times n}$  a

$$K_2^{m_i} = \{ (\mathbf{x}, y) \in \mathbb{R}^{m_i+1} \mid \|\mathbf{x}\|_2 \leq y \}$$

je epigraf eukleidovské normy  $\|\cdot\|_2$  (**kužel druhého řádu**) na  $\mathbb{R}^{m_i}$ .

# Programování na kuželu druhého řádu (SOCP)

$f, h_1, \dots, h_\ell$  afinní a

$$g_i(\mathbf{x}) = \|\mathbf{A}_i \mathbf{x} + \mathbf{b}_i\|_2 - (\mathbf{c}_i^T \mathbf{x} + d_i)$$

Podmínka  $g_i(\mathbf{x}) \leq 0$  se dá psát jako

$$\begin{bmatrix} \mathbf{A}_i \\ \mathbf{c}_i \end{bmatrix} \mathbf{x} + \begin{bmatrix} \mathbf{b}_i \\ d_i \end{bmatrix} \in K_2^{m_i}$$

kde  $\mathbf{A}_i \in \mathbb{R}^{m_i \times n}$  a

$$K_2^{m_i} = \{ (\mathbf{x}, y) \in \mathbb{R}^{m_i+1} \mid \|\mathbf{x}\|_2 \leq y \}$$

je epigraf eukleidovské normy  $\|\cdot\|_2$  (**kužel druhého řádu**) na  $\mathbb{R}^{m_i}$ .

- Když  $\mathbf{A}_i = \mathbf{0}$  pro všechna  $i$ , SOCP se redukuje na LP.
- Když  $\mathbf{c}_i = \mathbf{0}$  pro všechna  $i$ , SOCP se redukuje na QCQP.

## Příklad: Geometrický medián (Fermat-Weberův problém)


Pro zadané body  $\mathbf{a}_1, \dots, \mathbf{a}_m \in \mathbb{R}^n$  najděte minimum funkce

$$f(\mathbf{x}) = \sum_{i=1}^m \|\mathbf{x} - \mathbf{a}_i\|_2$$

SOCP formulace:

$$\begin{aligned} \min \quad & y_1 + \dots + y_m \\ \text{za podmíněk} \quad & \|\mathbf{x} - \mathbf{a}_i\|_2 \leq y_i, \quad i = 1, \dots, m. \end{aligned}$$

Existuje na to speciální algoritmus (Weiszfeldův).



Varignon frame

# Semidefinitní programování (SDP)

## Věta

Množina všech pozitivně semidefinitních matic pevného rozměru  $n \times n$  je konvexní kužel.

**Důkaz:** Pro každé  $\mathbf{x} \in \mathbb{R}^n$  a  $\alpha, \beta \geq 0$  platí  $\mathbf{x}^T(\alpha\mathbf{A} + \beta\mathbf{B})\mathbf{x} = \alpha\mathbf{x}^T\mathbf{A}\mathbf{x} + \beta\mathbf{x}^T\mathbf{B}\mathbf{x} \geq 0$ .

# Semidefinitní programování (SDP)

## Věta

Množina všech pozitivně semidefinitních matic pevného rozměru  $n \times n$  je konvexní kužel.

**Důkaz:** Pro každé  $\mathbf{x} \in \mathbb{R}^n$  a  $\alpha, \beta \geq 0$  platí  $\mathbf{x}^T(\alpha\mathbf{A} + \beta\mathbf{B})\mathbf{x} = \alpha\mathbf{x}^T\mathbf{A}\mathbf{x} + \beta\mathbf{x}^T\mathbf{B}\mathbf{x} \geq 0$ .

Úloha SDP:

$$\begin{aligned} & \min \quad \langle \mathbf{C}, \mathbf{X} \rangle \\ & \text{za podmíněk} \quad \langle \mathbf{A}_i, \mathbf{X} \rangle = b_i, \quad i = 1, \dots, m \\ & \quad \quad \quad \mathbf{X} \in \mathbb{R}^{n \times n} \text{ je pozitivně semidefinitní} \end{aligned}$$

Tedy minimalizujeme lineární funkci p.s.d. matice za podmíněk lineárních rovností.



# Semidefinitní programování (SDP)

## Věta

Množina všech pozitivně semidefinitních matic pevného rozměru  $n \times n$  je konvexní kužel.

**Důkaz:** Pro každé  $\mathbf{x} \in \mathbb{R}^n$  a  $\alpha, \beta \geq 0$  platí  $\mathbf{x}^T(\alpha\mathbf{A} + \beta\mathbf{B})\mathbf{x} = \alpha\mathbf{x}^T\mathbf{A}\mathbf{x} + \beta\mathbf{x}^T\mathbf{B}\mathbf{x} \geq 0$ .

Úloha SDP:

$$\begin{aligned} \min \quad & \langle \mathbf{C}, \mathbf{X} \rangle \\ \text{za podmíněk} \quad & \langle \mathbf{A}_i, \mathbf{X} \rangle = b_i, \quad i = 1, \dots, m \\ & \mathbf{X} \in \mathbb{R}^{n \times n} \text{ je pozitivně semidefinitní} \end{aligned}$$

Tedy minimalizujeme lineární funkci p.s.d. matice za podmíněk lineárních rovností.

- Pro diagonální matice  $\mathbf{A}_i, \mathbf{C}$  se SDP redukuje na LP.
- SOCP lze reprezentovat pomocí SDP (neuvádíme).

# Semidefinitní programování (SDP)

## Věta

Množina všech pozitivně semidefinitních matic pevného rozměru  $n \times n$  je konvexní kužel.

**Důkaz:** Pro každé  $\mathbf{x} \in \mathbb{R}^n$  a  $\alpha, \beta \geq 0$  platí  $\mathbf{x}^T(\alpha\mathbf{A} + \beta\mathbf{B})\mathbf{x} = \alpha\mathbf{x}^T\mathbf{A}\mathbf{x} + \beta\mathbf{x}^T\mathbf{B}\mathbf{x} \geq 0$ .

Úloha SDP:

$$\begin{aligned} \min \quad & \langle \mathbf{C}, \mathbf{X} \rangle \\ \text{za podmíněk} \quad & \langle \mathbf{A}_i, \mathbf{X} \rangle = b_i, \quad i = 1, \dots, m \\ & \mathbf{X} \in \mathbb{R}^{n \times n} \text{ je pozitivně semidefinitní} \end{aligned}$$

Tedy minimalizujeme lineární funkci p.s.d. matice za podmíněk lineárních rovností.

- Pro diagonální matice  $\mathbf{A}_i, \mathbf{C}$  se SDP redukuje na LP.
- SOCP lze reprezentovat pomocí SDP (neuvádíme).
- Souhrn:

$$\text{LP} \subset \text{QP} \subset \text{QCQP} \subset \text{SOCP} \subset \text{SDP}$$

Stephen Boyd and  
Lieven Vandenberghe

## Convex Optimization

CAMBRIDGE

Convex optimization problems arise frequently in many different fields. This book provides a comprehensive introduction to the subject, covering the theory, many applications and examples, and numerical methods. The book begins with the basic elements of convex sets and functions, describes various classes of convex optimization problems, and then treats duality theory. The second part covers a wide variety of applications, in estimation, approximation, statistics, computational geometry, and other areas. The last part of the book presents numerical methods for convex optimization problems, moving from basic methods for unconstrained problems to interior-point methods.

The focus of the book is on recognizing and formulating convex optimization problems, and then solving them efficiently. It contains many worked examples and homework exercises and will appeal to students, researchers, and practitioners in fields such as engineering, computer science, mathematics, finance, and economics.

**Stephen Boyd** received his Ph.D. from the University of California, Berkeley. Since 1985 he has been a member of the Electrical Engineering Department at Stanford University, where he is now the Samsung Professor of Engineering and Director of the Information Systems Laboratory. He has won numerous awards for research and teaching, and is a Fellow of the IEEE. He is the co-author of two previous books, *Linear Controller Design: Limits of Performance* and *Linear Matrix Inequalities in System and Control Theory*.

**Lieven Vandenberghe** received his Ph.D. from the Katholieke Universiteit Leuven, Belgium, and is Professor of Electrical Engineering at the University of California, Los Angeles. He has published widely in the field of optimization, and is co-editor of the *Handbook of Semidefinite Programming*.

CAMBRIDGE  
UNIVERSITY PRESS

[www.cambridge.org](http://www.cambridge.org)

ISBN 978-0-521-83378-3



9 780521 833783 >

## Příklad: Interface solveru SEDUMI na řešení LP, SOCP, SDP

```
% X = SEDUMI(A,b,c,K) minimizes c'*x subject to A*x = b and x is restricted to
% a self-dual cone, defined by structure K. The fields of K can be
% K.f, K.l, K.q, K.s (Free, Linear, Quadratic, Semi-definite).
%
% (1) K.f is the number of FREE, i.e. UNRESTRICTED primal components.
%     These are ALWAYS the first components in x.
%
% (2) K.l is the number of NONNEGATIVE components. E.g. if K.f=2, K.l=8
%     then x(3:10) >=0.
%
% (3) K.q lists the dimensions of LORENTZ (quadratic, second-order cone)
%     constraints. E.g. if K.l=10 and K.q = [3 7] then
%         x(11) >= norm(x(12:13)),
%         x(14) >= norm(x(15:20)).
%     These components ALWAYS immediately follow the K.l nonnegative ones.
%
% (4) K.s lists the dimensions of POSITIVE SEMI-DEFINITE (PSD) constraints
%     E.g. if K.l=10, K.q = [3 7] and K.s = [4 3], then
%         mat( x(21:36),4 ) is PSD,
%         mat( x(37:45),3 ) is PSD.
%     These components are ALWAYS the last entries in x.
```

**Co s nekonvexními úlohami?**

---

## Některé nekonvexní úlohy jsou 'snadné' ...

**Příklad:** Minimalizace (ne nutně p.s.d.) kvadratické formy na sféře:

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} \\ \text{za podmínky} \quad & \mathbf{x}^T \mathbf{x} = 1 \end{aligned}$$

## Některé nekonvexní úlohy jsou 'snadné' ...

**Příklad:** Minimalizace (ne nutně p.s.d.) kvadratické formy na sféře:

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} \\ \text{za podmínky} \quad & \mathbf{x}^T \mathbf{x} = 1 \end{aligned}$$

**Příklad:** QP s jediným omezením:

$$\begin{aligned} \min \quad & f(\mathbf{x}) \\ \text{za podmínky} \quad & g(\mathbf{x}) \leq 0 \end{aligned}$$

kde  $f, g: \mathbb{R}^n \rightarrow \mathbb{R}$  jsou dané (ne nutně konvexní) kvadratické funkce. Tato úloha jde převést na SDP (neuvádíme).

**Příklad:** Minimalizace (ne nutně p.s.d.) kvadratické formy na hyperkrychli:

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} \\ \text{za podmínky} \quad & \mathbf{x} \in [-1, 1]^n \end{aligned}$$

Pro  $\mathbf{A} = -\mathbf{I}$  má úloha  $2^n$  lokálních minim (vrcholy hyperkrychle).

Pro obecné  $\mathbf{A}$  je úloha NP-těžká (důkaz neuvádíme).



**Příklad:** Minimalizace (ne nutně p.s.d.) kvadratické formy na hyperkrychli:

$$\begin{aligned} \min \quad & \mathbf{x}^T \mathbf{A} \mathbf{x} \\ \text{za podmínky} \quad & \mathbf{x} \in [-1, 1]^n \end{aligned}$$

Pro  $\mathbf{A} = -\mathbf{I}$  má úloha  $2^n$  lokálních minim (vrcholy hyperkrychle).

Pro obecné  $\mathbf{A}$  je úloha NP-těžká (důkaz neuvádíme).

**Příklad:** Celočíselné lineární programování

$$\begin{aligned} \min \quad & \mathbf{c}^T \mathbf{x} \\ \text{za podmíněk} \quad & \mathbf{A} \mathbf{x} \geq \mathbf{b} \\ & \mathbf{x} \in \{0, 1\}^n \end{aligned}$$

Podmínky  $x_i \in \{0, 1\}$  lze napsat jako nekonvexní kvadratické rovnosti  $x_i(1 - x_i) = 0$ .

# Konvexní relaxace nekonvexní úlohy

Je-li  $X \subseteq Y \subseteq \mathbb{R}^n$ , pak

$$\underbrace{\min\{\mathbf{c}^T \mathbf{x} \mid \mathbf{x} \in X\}}_{\text{původní úloha}} \geq \underbrace{\min\{\mathbf{c}^T \mathbf{x} \mid \mathbf{x} \in Y\}}_{\text{relaxovaná úloha}}$$

Nahradíme původní (složitou, nekonvexní) množinu  $X$  její (jednoduchou, konvexní) nadmnožinou  $Y$ .

Viděli jsme dříve pro 0-1 LP, kde

$$X = \{\mathbf{x} \in \{0, 1\}^n \mid \mathbf{Ax} \geq \mathbf{b}\}$$

$$Y = \{\mathbf{x} \in [0, 1]^n \mid \mathbf{Ax} \geq \mathbf{b}\}$$

Užitečnost:

- Poskytne dolní mez na hodnotu globálního minima nerelaxované úlohy.
- Projekce opt. argumentu relaxované úlohy na množinu  $X$  může být 'dobrou' aproximací opt. argumentu původní úlohy.  
(Viděli jsme pro nejmenší vrcholové pokrytí, kde projekce byla zaokrouhlení.)

# Co s nekonvexními úlohami?

Obecně dvě cesty:

- Nalezení globálního optima, ale obecně (worst-case) v čase exponenciálním ve velikosti úlohy (**globální optimalizace**).
  - hierarchie stále těsnějších konv. relaxací (Sherali-Adams hierarchy pro 0-1 LP)
  - metoda sečných nadrovin (cutting-plane method)
  - metoda větví a mezí (branch-and-bound)

- Nalezení přibližného optima (tzv. sub-optima) v krátkém čase.

Heuristiky (každá použitelná jen na určitý typ úloh):

- najde lokální (v nějakém smyslu) optimum (lokální optimalizace, alternující optimalizace / optimalizace po blocích souřadnic, majorize-minimize methods)
- konv. relaxace + projekce na původní přípustnou množinu
- přírodou inspirované heuristiky (evoluční/genetické algoritmy, simulované žíhání, kolonie mravenců, ...)
- tabu search
- continuation/homotopy methods
- stochastické metody

# Taxonomie optimalizačních algoritmů

- iterační (opakují stejnou iteraci) – neiterační
- deterministické – stochastické
- přesné – přibližné
- lokální – globální
- centralizované – distribuované (např. výpočty v počítačových sítích, rozvodných elektrických sítích, na mnoha jádrech procesoru, ...)
- sekvenční – paralelní (překryv s centralizované – distribuované)
- heuristické:
  - lokální hledání (hill climbing)
  - hladové (greedy) algoritmy
  - tabu search
  - motivované přírodou: genetické/evoluční, simulované žíhání, kolonie mravenců