

# Optimalizace

## 12. Konvexní funkce a konvexní optimalizace

---

Tom Werner, Tom Kroupa

FEL ČVUT

# Konvexní funkce

---


# Konvexní funkce

**Definice:** Necht'  $X \subseteq \mathbb{R}^n$  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

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



**Důsledek:** Je-li  $f$  konvexní diferencovatelná a  $f'(\mathbf{x}) = \mathbf{0}$ , pak  $\mathbf{x}$  je volné globální minimum  $f$  na  $\mathbb{R}^n$ .

## 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  $\{\mathbf{x} \in X \mid f(\mathbf{x}) \leq y\}$ .

## 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.

# Některé operace zachovávající konvexitu

## Nezáporné lineární kombinace:

Jsou-li  $f_1, \dots, f_k$  konvexní funkce a  $\alpha_1, \dots, \alpha_k \geq 0$ , pak funkce  $\alpha_1 f_1 + \dots + \alpha_k f_k$  je konvexní.

## Skládání funkcí:

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

**Maximum:** Necht'  $f_i: \mathbb{R}^n \rightarrow \mathbb{R}$  jsou konvexní funkce pro všechna  $i \in I$ . Pak

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

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  $f_i$ .

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

## Příklady:

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

# 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  $X$ .

## 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!

# Konvenční 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 konvenční, jestliže funkce  $f, g_1, \dots, g_m$  jsou konvenční a  $h_1, \dots, h_\ell$  jsou afinní.

**Důkaz:** Množina přípustných řešení je průnik konvenčních 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 konvenční úlohu.

Příklad: Množina

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

je konvenční, 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.

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

**Příklad:** Řešení přeурčené 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:** Řešení přeурčené lineární soustavy s intervalovými omezeními ('box constraints'):

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

**Příklad:** Řešení soustavy lineárních nerovnic s nejmenší normou:

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

## Příklad: Support Vector Machine (SVM)



Dány dvojice  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \in \mathbb{R}^n \times \{-1, +1\}$ .

Hledáme **oddělující nadrovinu**: hledáme  $\mathbf{a} \in \mathbb{R}^n$  a  $b \in \mathbb{R}$  tak, aby

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

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

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

**Úloha SVM**: hledá oddělující nadrovinu maximalizující šířku pásu, tj. minimalizující  $\|\mathbf{a}\|_2^2 = \mathbf{a}^T \mathbf{a}$ .

# 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

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

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  $\mathbf{x}^T(\alpha\mathbf{A} + \beta\mathbf{B})\mathbf{x} = \alpha\mathbf{x}^T\mathbf{A}\mathbf{x} + \beta\mathbf{x}^T\mathbf{B}\mathbf{x} \geq 0$ .


Úloha SDP:

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

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

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

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



## 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.
```

# Modelovací jazyky pro optimalizaci (příklady)

CVX:

- Pouze konvexní úlohy (*disciplined convex programming, DCP*)
- Verze pro Matlab, Python, ...
- Příklad: úloha

$$\begin{aligned} \min \quad & \| \mathbf{Ax} - \mathbf{b} \| \\ \text{za podm.} \quad & \mathbf{Cx} = \mathbf{d} \\ & \| \mathbf{x} \|_{\infty} \leq 1 \end{aligned}$$

se v CVX (Matlab) modeluje takto:

```
cvx_begin
    variable x(n);
    minimize( norm(A*x-b) );
    subject to
        C*x == d;
        norm(x,Inf) <= 1;
cvx_end
```

YALMIP:

- Konvexní i nekonvexní úlohy (mnohem víc možností než CVX), ale (samozřejmě) jen lokální optima.
- V Matlabu

**Co s nekonvexními úlohami?**

---

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

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

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

**Příklad:** QCQP 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:** Celočíselné lineární programování

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

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

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

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

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