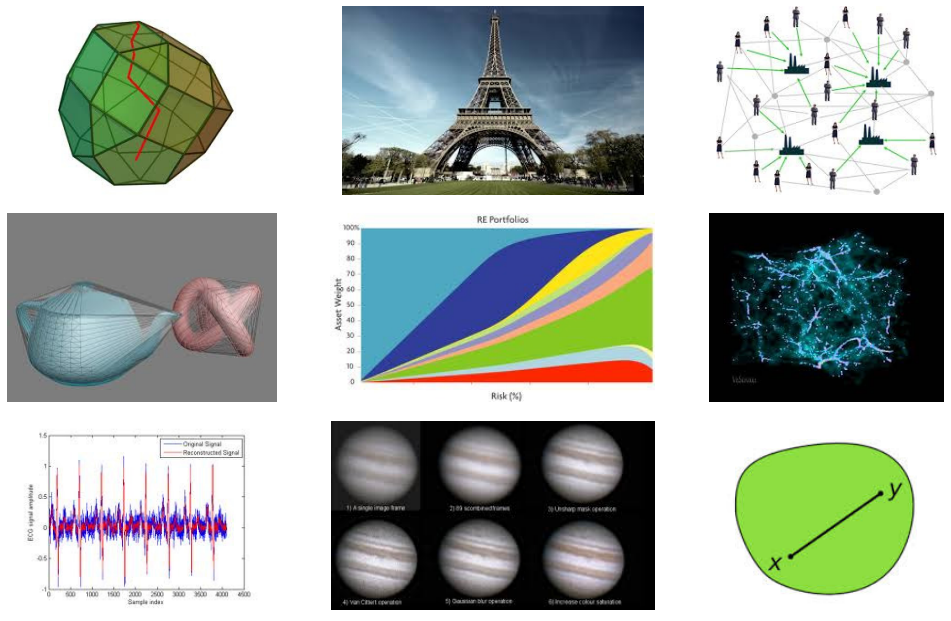


Konvexná optimalizácia - letný semester 2020

M. Trnovská, KAMŠ, FMFI UK



Téma 2: Zovšeobecnenie konvexných úloh

Úloha **konvexného programovania v štandardnom tvare** (úloha konvexného programovania v užšom zmysle)

$$\begin{aligned} \min \quad & f_0(x), \\ & f_i(x) \leq 0, \quad i = 1, \dots, m, \\ & Ax = b, \end{aligned} \tag{1}$$

Úloha konvexného programovania v širšom zmysle

$$\begin{aligned} \min \quad & f_0(x) \\ & x \in \mathcal{C}, \end{aligned} \tag{2}$$

kde $f_0(x)$ je konvexná funkcia a \mathcal{C} je nejaká konvexná množina.

- Každá úloha tvaru (1) má tvar úlohy (2), keďže príslušná množina prípustných riešení \mathcal{P} je konvexná.
- Nie každá úloha tvaru (2) sa dá vyjadriť v tvare (1), ako to ukazuje nasledujúci príklad.

Príklad: Uvažujme množinu 2×2 symetrických kladne semidefinitných matíc:

$$\mathcal{C} = \mathcal{S}_+^2 = \{X \in M_{2,2}(\mathbb{R}), X = X^T, X \succeq 0\},$$

ktorá je zrejme konvexná (overte). Máme danú úlohu

$$\begin{aligned} \min \quad & f_0(X) \\ & X \in \mathcal{S}_+^2, \\ & +\text{lineárne ohraničenia.} \end{aligned} \tag{3}$$

Každej symetrickej 2×2 matici možno jednoznačne priradiť trojrozmerný vektor:

$$X = \begin{pmatrix} x_1 & x_2 \\ x_2 & x_3 \end{pmatrix} \mapsto \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix},$$

Kladnú semidefinitnosť symetrickej matice X možno charakterizovať podmienkami $x_1 \geq 0, x_3 \geq 0$ a $\det(X) \geq 0$.

Úlohu (3) by sme mohli ekvivalentne prepísať ako

$$\begin{aligned} \min \quad & f_0(x_1, x_2, x_3) \\ & x_2^2 - x_1x_3 \leq 0, \\ & x_1 \geq 0, x_3 \geq 0, \\ & +\text{lineárne ohraničenia.} \end{aligned}$$

Dá sa však ľahko overiť, že funkcia

$$f_1(x_1, x_2, x_3) = x_2^2 - x_1x_3$$

v ohraničeniach nie je konvexná.

Príklad:

Uvažujme úlohu optimalizácie portfólia, kde je daná kladne definitná kovariančná matica výnosov Σ , vektor priemerných výnosov p a minimálny akceptovateľný výnos portfólia r_{min} . Premennou je vektor x , ktorého zložka x_i predstavuje relatívne množstvo aktíva i . Úlohou je minimalizovať varianciu portfólia $x^T \Sigma x$ (ktorá predstavuje mieru rizika):

$$\begin{aligned} \min \quad & x^T \Sigma x \\ & p^T x \geq r_{min}, \\ & \sum_{i=1}^n x_i = 1, x \geq 0, \end{aligned}$$

Takáto úloha je úlohou (kvadratického) konvexného programovania v užšom zmysle.

Príklad:

Alternatívne by však daným vstupom do úlohy mohlo byť dané portfólio x a čiastková informácia o kovariančnej matici Σ ukrytá v symetrických maticiach L, U . Zaujímať nás bude najhoršie možné “riziko” pre dané portfólio v rámci našich ohtaničení. To vedie na úlohu s maticovou premennou Σ :

$$\begin{aligned} \max \quad & x^T \Sigma x, \\ & L_{ij} \leq \Sigma_{ij} \leq U_{ij}, i, j = 1, \dots, n, \\ & \Sigma \succeq 0. \end{aligned}$$

Všimnime si, že účelová funkcia v tejto úlohe je lineárna, $x^T \Sigma x = \text{tr}(\Sigma x x^T)$ a množinou prípustných riešení je prienik konvexnej množiny kladne semidefinitných matíc s boxom určeným maticami L a U .

Úloha kónického lineárneho programovania (KLP)

$$\begin{aligned} \min \quad & c^T x, \\ & Ax = b, \\ & x \in K, \end{aligned} \tag{4}$$

kde K je nejaký konvexný kužel.

Úloha (4) sa dá chápať ako zovšeobecnenie úlohy lineárneho programovania, ktoré je zrejme podriedou takýchto úloh pre voľbu $K = \mathbb{R}_+^n$.

Konvexný kužel

Množina K sa nazýva **konvexný kužel**, ak súčasne platí

$$(k1) \quad \forall x \in K, \forall \alpha \geq 0 : \alpha x \in K;$$

$$(k2) \quad \forall x, y \in K : x + y \in K.$$

Vlastnosti (k1), (k2) z vyššie uvedenej definície sú ekvivalentné s vlastnosťou

$$(k3) \quad \forall x, y \in K, \forall \alpha, \beta \geq 0 : \alpha x + \beta y \in K.$$

Bod x nazveme **vnútorným bodom** kužela $K \subseteq \mathbb{R}^n$ ak

$$\forall v \in \mathbb{R}^n, \exists \varepsilon > 0 : x + \varepsilon v \in K.$$

Množinu všetkých vnútorných bodov kužela K budeme označovať $\text{int}K$.

Množina $\text{int}K$ má nasledovné vlastnosti:

$$(k1') \quad \forall x \in \text{int}K, \forall \alpha > 0 : \alpha x \in \text{int}K;$$

$$(k2') \quad \forall x, y \in \text{int}K : x + y \in \text{int}K.$$

Zachovávajúce operácie:

- Ak K_1, K_2 sú konvexné kužele, tak ich karteziánsky súčin $K_1 \times K_2$ je konvexný kužel.
- Ak $K_1, K_2 \subseteq \mathbb{R}^n$ sú konvexné kužele, tak ich Minkovského súčet $K_1 + K_2$ je konvexný kužel.
- Ak K je konvexný kužel a \mathcal{A} je lineárne zobrazenie, tak $\mathcal{A}(K)$ je konvexný kužel.
- Ak $K_1, K_2 \subseteq \mathbb{R}^n$ sú konvexné kužele, tak ich prienik $K_1 \cap K_2$ je konvexný kužel.



Príklady konvexných kužeľov

Normový kužeľ:

$$K_{\|\cdot\|} = \{(x, x_0) \in \mathbb{R}^{n-1} \times \mathbb{R} \mid \|x\| \leq x_0\} \subset \mathbb{R}^n.$$

Z vlastností normy vyplýva, že takto definovaná množina je konvexný kužeľ. Špeciálne pre Euklidovskú normu l_2 získame tzv. kužeľ 2. rádu:

$$K_2 = \{(x, x_0) \in \mathbb{R}^{n-1} \times \mathbb{R} \mid \|x\|_2 \leq x_0\} \subset \mathbb{R}^n.$$



Kužel' (symetrických) kladne semidefinitných (\mathcal{S}_+^n), kopolitívnych (\mathcal{C}_+^n) a kompletne pozitívnych (\mathcal{P}_+^n) matíc:

$$\mathcal{S}_+^n = \{X \in M_{n,n}(\mathbb{R}) \mid X = X^T, z^T X z \geq 0, \forall z\},$$



$$\mathcal{C}_+^n = \{X \in M_{n,n}(\mathbb{R}) \mid X = X^T, z^T X z \geq 0, \forall z \geq 0\}$$

a

$$\mathcal{P}_+^n = \{X \in M_{n,n}(\mathbb{R}) \mid X = BB^T, B_{ij} \geq 0 \forall i, j\}$$

$$= \left\{ \sum_{i=1}^l b_i b_i^T \mid b_i \in \mathbb{R}_+^n, l \in \mathbb{N} \right\}.$$

Zrejme platí: $\mathcal{P}_+^n \subseteq \mathcal{S}_+^n \subseteq \mathcal{C}_+^n$.



Monotónny nezáporný kužel:

$$K_{m+} = \{x \in \mathbb{R}^n \mid x_1 \geq x_2 \geq \dots \geq x_n \geq 0\},$$

t.j. kužel nezáporných vektorov s usporiadanými zložkami.

Kužel' Euklidovských matíc. Symetrická matica $D \in \mathcal{S}^n$ sa nazýva Euklidovská, ak existujú body x_1, \dots, x_n také, že $D_{ij} = \|x_i - x_j\|_2^2$. Zrejme $D_{ij} \geq 0, D_{ii} = 0$. Známy výsledok hovorí, že matica D je euklidovská práve vtedy, keď $D_{ii} = 0$ a $z^T D z \leq 0, \forall z : \sum_{i=1}^n z_i = 0$, inak povedané D má na diagonále nuly a je záporne semidefinitná na podpriestore $[\mathbf{1}]^\perp$.

Maskovanie štandardných konvexných úloh do tvaru KLP

V nasledujúcom si ukážeme, ako možno úlohu tvaru (1), t.j. úlohu

$$\begin{aligned} \min \quad & f_0(x) \\ & f_i(x) \leq 0, \quad i = 1, \dots, m, \\ & Ax = b, \end{aligned}$$

previesť na tvar úlohy (4), konkrétne na nasledujúcu KLP úlohu:

$$\begin{aligned} \min \quad & t \\ & (x, t, s) \in K_{\mathcal{F}}, \\ & Ax = b, s = 1, \end{aligned}$$

kde kužel $K_{\mathcal{F}}$ je definovaný predpisom (5) pre $C = \mathcal{F}$,

$$\mathcal{F} = \{(x, t) \mid f_0(x) \leq t, f_i(x) \leq 0, i = 1, \dots, m\}$$

Vnorení konvexnej množiny do konvexného kužela

Každú konvexnú množinu $C \in \mathbb{R}^n$ možno vnoriť do konvexného kužela

$$K_C = \left\{ (x, s) \in \mathbb{R}^n \times \mathbb{R} \mid s > 0, \frac{x}{s} \in C \right\} \cup \{0\}. \quad (5)$$

Zrejme platí $x \in C$ práve vtedy, keď $(x, 1) \in K_C$.

Tvrdenie:

Množina K_C definovaná vzťahom (5) je konvexný kužel.

Dôkaz:

.....

Úloha programovania nad kuželmi 2. rádu (SOCP)

Keď v úlohe (4) zvolíme za kužel K normový kužel 2. rádu K_2 , dostaneme tzv. úlohu programovania nad kuželmi 2. rádu (v anglickej literatúre označovanej skratkou SOCP) v štandardnom tvare:

$$\begin{aligned} \min \quad & c^T x \\ & Ax = b, \\ & \|\bar{x}\|_2 \leq x_0, \\ & x = (\bar{x}; x_0) \in \mathbb{R}^{n-1} \times \mathbb{R}. \end{aligned} \tag{6}$$

Niekedy sa zvykne formulovať úloha SOCP aj v tzv. duálnom tvare:

$$\begin{aligned} \min \quad & c^T x \\ & \|Fx + g\|_2 \leq h^T x + \gamma. \end{aligned} \tag{7}$$

Úloha semidefinitného programovania (SDP)

Dané sú symetrické matice C, A_1, \dots, A_m . Úlohou semidefinitného programovania s premennou $X \in \mathcal{S}^n$ v štandardnom tvare je úloha

$$\begin{aligned} \min \quad & \text{tr}(CX) \\ & \text{tr}(A_i X) = b_i, \quad i = 1, \dots, m, \\ & X \succeq 0. \end{aligned} \tag{8}$$

Ukážeme, že úloha SDP je naozaj úloha v tvare (4). Vezmime lineárne zobrazenie $svec : \mathcal{S}^n \rightarrow \mathbb{R}^{\frac{n(n+1)}{2}}$

$$svec(X) = (x_{11}, \sqrt{2}x_{12}, \dots, \sqrt{2}x_{1n}, x_{22}, \sqrt{2}x_{23}, \dots, x_{nn})^T,$$

ktoré zobrazuje \mathcal{S}^n na priestor $\mathbb{R}^{\frac{n(n+1)}{2}}$ s rovnakou dimenziou (je izomorfizmom medzi priestormi \mathcal{S}^n a $\mathbb{R}^{\frac{n(n+1)}{2}}$).

Zrejme pre $X, Y \in \mathcal{S}^n$ platí

$$\text{tr}(XY) = \text{svec}(X)^T \text{svec}(Y).$$

Ak teda definujeme

$\mathbf{x} = \text{svec}(X)$, $\mathbf{c} = \text{svec}(C)$, $\mathbf{a}_i = \text{svec}(A_i)$, $i = 1, \dots, m$,
maticu \mathbf{A} rozmeru $m \times \frac{n(n+1)}{2}$ s riadkovým priestorom $S(\mathbf{A}^T) = \text{span}[\mathbf{a}_1, \dots, \mathbf{a}_m]$
kužel $\mathbf{K} = \text{svec}(\mathcal{S}_+^n)$,

tak úlohu (8) vieme ekvivalentne prepísať ako

$$\begin{aligned} \min \quad & \mathbf{c}^T \mathbf{x} \\ & \mathbf{A} \mathbf{x} = b, \\ & \mathbf{x} \in \mathbf{K}. \end{aligned}$$

Niekedy sa zvykne formulovať úloha SDP aj v tzv. duálnom tvare:

$$\begin{aligned} \min \quad & b^T y \\ & C - \sum_{i=1}^m A_i y_i \succeq 0, \quad i = 1, \dots, m, \end{aligned} \tag{9}$$

ktorá sa dá ekvivalentne prepísať ako

$$\begin{aligned} \min \quad & b^T y \\ & \mathbf{c} - \mathbf{A}^T y \in \mathbf{K}. \end{aligned}$$

Ohraničenie v úlohe (9) sa v anglickej literatúre zvykne označovať ako LMI (linear matrix inequality).