







# Konvexná optimalizácia



Konvexná optimalizácia - letný semester 2017

M. Trnovská, KAMŠ, FMFI UK

### Význam konvexnej optimalizácie

.... To čo už dávno vieme z prednášok nelineárneho programovania.....  
(alebo by sme mali, ale sme zabudli)

- Množina prípustných riešení je konvexná.
- Každé lokálne minimum je globálnym minimom.
- Existujú algoritmy, ktoré vedia **spoľahlivo a efektívne** riešiť aj veľké úlohy.
- Existujú **solvre a modelovacie nástroje**, v ktorých sú tieto algoritmy implementované - stačí len správne definovať úlohu.
- Problém - identifikovať / naformulovať úlohu ako úkolu konvexnej optimalizácie → KONVEXNÁ ANALÝZA.

## *Konvexná optimalizácia*

---

- Prekvapivo veľa úloh sa dá naformulovať ako konvexná úloha
- **Aplikácie konvexnej optimalizácie:** inžinierske, finančné (optimalizácia portfólia, preferencie) optimálny dizajn (topologický, experimentálny), aproximácia a fitovanie dát, štatistika, siete, spracovanie signálu (obraz, zvuk), optimálne riadenie, geometrické úlohy (lineárna a nelineárna separácia bodov) - dokonca **modelovanie vesmíru**
- Nekonvexné úlohy - mnohé algoritmy sú založené na riešení konvexných podúloh
- Konvexná relaxácia nekonvexných úloh - získa sa odhad na optimálnu hodnotu

*"In fact the great watershed in optimization isn't between linearity and nonlinearity, but convexity and nonconvexity"*

T. Rockafellar

## **Témy predmetu konvexná optimalizácia**

- História, význam konvexnej optimalizácie
- Úloha konvexného programovania v užšom a širšom zmysle (kónické úlohy)
- Konvexné množiny
- Konvexné funkcie
- Trocha maticovej analýzy - blokové matice, Schurov doplnok, pseudoinverzie
- Triedy úloh konvexnej optimalizácie, transformácie úloh
- Podmienky optimality a dualita
- Aplikácie konvexnej optimalizácie a modelovací systém CVX
- Úvod do metód vnútorného bodu

### **Využitie konvexnej optimalizácie**

- Topologický dizajn - Problém Eiffelovej veže





- TRUSS - mechanická konštrukcia zložená z priečok a uzlov, na ktoré pôsobí zát'až
- Optimalizuje sa "pevnosť konštrukcie"

## *Konvexná optimalizácia*

---

- **Vstup:** pozície uzlov, zát'až na uzly, celková hmotnosť (objem) konštrukcie
- **Premenné úlohy:** váhy pridelené jednotlivým priečkam
- **Úloha:** nájsť optimálne rozloženie váh tak, aby bola konštrukcia čo najpevnejšia - aby bola potenciálna energia reprezentujúca poddajnosť konštrukcie minimálna
- M. P. Bendsøe, O. Sigmund: Topology Optimization - Theory, Methods and Applications





**Fig. 4.6.** The flexibility in choice of ground structure. Optimal design of a well-known structure. Left hand picture shows the ground structure and the right hand picture the optimal topology for a single downward load at the top of the structure. The example shows that it is crucial to consider multiple load cases for realistic structures. By courtesy of M. Kocvara and J. Zowe.

- **Kozmológia: Rekonštrukcia "ranného" vesmíru**



- Y. Breiner, U. Frisch, M. Hénon, G. Loeper, S. Matatrese, R. Mohayaee, A. Sobolevski: **Reconstruction of the early Universe as a convex optimization problem**, *Monthly Notices of the Royal Astronomical Society*, 2003.



Mon. Not. R. Astron. Soc. **346**, 501–524 (2003)

## Reconstruction of the early Universe as a convex optimization problem

Y. Brenier,<sup>1</sup> U. Frisch,<sup>2,3\*</sup> M. Hénon,<sup>2</sup> G. Loeper,<sup>1</sup> S. Matarrese,<sup>4</sup> R. Mohayaee<sup>2</sup>  
and A. Sobolevskii<sup>2,5</sup>

<sup>1</sup>CNRS, UMR 6621, Université de Nice-Sophia-Antipolis, Parc Valrose, 06108 Nice Cedex 02, France

<sup>2</sup>CNRS, UMR 6529, Observatoire de la Côte d'Azur, BP 4229, 06304 Nice Cedex 4, France

<sup>3</sup>Institute for Advanced Study, Einstein Drive, Princeton, NJ 08540, USA

<sup>4</sup>Dipartimento di Fisica 'G. Galilei' and INFN, Sezione di Padova, via Marzolo 8, 35131-Padova, Italy

<sup>5</sup>Department of Physics, M. V. Lomonossov Moscow University, Leninskie Gory, 119992 Moscow, Russia

Accepted 2003 August 10. Received 2003 August 1; in original form 2003 April 10

### ABSTRACT

We show that the deterministic past history of the Universe can be uniquely reconstructed from knowledge of the present mass density field, the latter being inferred from the three-dimensional distribution of luminous matter, assumed to be tracing the distribution of dark matter up to a known bias. Reconstruction ceases to be unique below those scales – a few Mpc – where multistreaming becomes significant. Above  $6 h^{-1}$  Mpc we propose and implement an effective Monge–Ampère–Kantorovich method of unique reconstruction. At such scales the Zel'dovich approximation is well satisfied and reconstruction becomes an instance of optimal mass transportation, a problem which goes back to Monge. After discretization into  $N$  point masses one obtains an assignment problem that can be handled by effective algorithms with not more than  $O(N^3)$  time complexity and reasonable CPU time requirements. Testing against  $N$ -body cosmological simulations gives over 60 per cent of exactly reconstructed points.

We apply several interrelated tools from optimization theory that were not used in cosmological reconstruction before, such as the Monge–Ampère equation, its relation to the mass transportation problem, the Kantorovich duality and the auction algorithm for optimal assignment. A self-contained discussion of relevant notions and techniques is provided.

Downloaded from <http://mnras.oxfordjournals.org/> by guest

- Spracovanie obrazu



$$\text{Min} \quad \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|Wx\|_1$$

- $b$  - rozmazaný  $k \times l$  obrázok (signál) reprezentovaný ako  $M = kl$  rozmerný vektor
- $A$  -  $M \times N$  lineárna transformácia reprezentujúca "rozmazanie"
- $W$  ortogonálna matica reprezentujúca vlnkovú transformáciu (wavelet) - popisuje aké frekvencie sa v danom čase nachádzajú v signále.

## Konvexná optimalizácia

Observed Image



Reconstructed Image (lambda=0.001)



```
[M,N]= size (A); lambda=0.001;
```

```
cvx_begin
```

```
    variable x(n)
```

```
    maximize ( square_pos ( norm (A*x-b) ) + lambda*norm (W*x , 1 )
```

```
cvx_end
```

# *Konvexná optimalizácia*

---

## Po absolvovaní predmetu by mal študent:

- vedieť základy **konvexnej analýzy** potrebnej na
  - identifikovanie konvexnej úlohy
  - "konvexifikáciu" nekonvexných úloh
- utvrdiť si poznatky týkajúce sa **Lagrangeovej duality a podmienok optimality** pre konvexné úlohy + rozšírenie poznatkov na zovšeobecnené konvexné úlohy
- oboznámiť sa s **kónickými konvexnými úlohami** a ich významom
- poznať rôzne praktické **aplikácie** konvexnej optimalizácie z prednášok a z "vlastnej skúsenosti" (ktorú získa vypracovaním **projektu**)
- byť oboznámený s modelovacím systémom **CVX**
- poznať myšlienku, teoretické a praktické aspekty **metód vnútorného bodu**.

## **Pravidlá hodnotenia predmetu:**

- Celkové hodnotenie predmetu závisí od domácej úlohy a hodnotenia projektu, ktorý sa vypracováva **v skupinách** (1-3 študenti). Každá skupina po vypracovaní projektu určí podiel práce jednotlivých členov na projekte číslom (váhou) z intervalu  $[0, 1]$  (pričom celkový súčet musí byť 1).
- Domáce úlohy sú vypracované podrobne a čitateľne, so zdôvodnením jednotlivých krokov. Môžu byť vypracované v Latex-u. Riešenia domácej úlohy obsahujú aj zadanie domácej úlohy (ak treba, pošlem kód). Všetko, čo bolo spomenuté na slajdoch možno použiť ako fakt. (4x15 bodov)
- Projekt je spracovaný ako pdf prezentácia, v závere semestra sa projekty prezentujú na prednáške. (30+10 bodov, ktorými sa študenti hodnotia navzájom).

## Konvexná optimalizácia

---

- **Hodnotenie člena skupiny** s váhou  $w$  je

$$\frac{w \cdot x}{w_{max}} + y,$$

kde  $w_{max}$  je maximálna váha v skupine,  $x$  je získaný počet bodov skupiny za projekt a  $y$  je počet bodov za naštudovanie a prezentáciu článku.

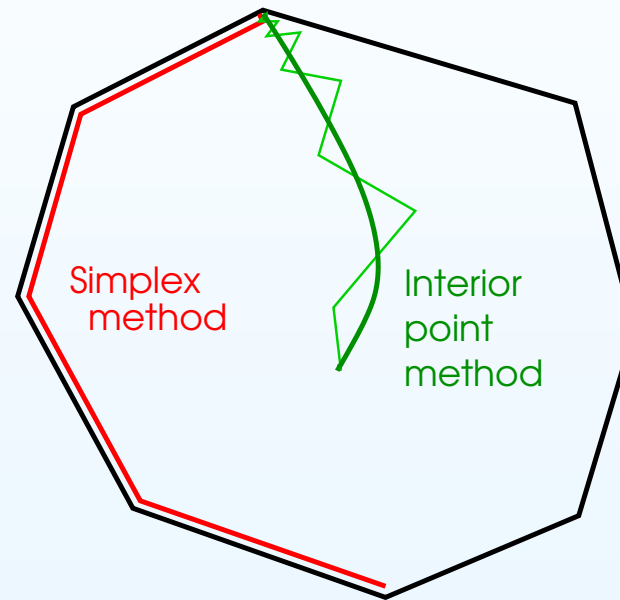

- Znáмка za predmet **konvexná optimalizácia**:

body	známka
100-90	A
81-90	B
71-80	C
61-70	D
51-60	E

### **História modernej konvexnej optimalizácie**

- 1947 - G. B. Dantzig - simplexová metóda
- 1968 - Fiacco & McCormick - metóda SUMT
- 1972 - Klee & Minty cube
- 1979 - Leonid Khachian - elipsoidná metóda - 1. polynomiálny algoritmus pre LP, v praxi pomalý
- 1984 - Narendra Karmarkar - "projektívny" algoritmus pre LP - polynomiálny aj rýchly, začiatok moderných metód vnútorného bodu

# Konvexná optimalizácia





- **1988** - Nesterov, Nemirovski - zovšeobecnenie MVB na všeobecné konvexné úlohy
- **1992** - vznik semidefinitného programovania - prvé efektívne algoritmy
- **2000-.....** - kónické programovanie (SOCP), aplikácie v ďalších oblastiach (optimálny dizajn, spracovanie obrazu,.....), metódy pre nehladnké konvexné úlohy,.....

### Úloha konvexného programovania v užšom zmysle:

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

- $f_i(x) : \mathbb{R}^n \rightarrow \mathbb{R}, i = 0, 1, \dots, m$  - konvexné funkcie
- $h_i(x) : \mathbb{R}^n \rightarrow \mathbb{R}, i = 1, \dots, p$  - afínne funkcie

Množina prípustných riešení

$$\mathcal{P} = \{x \mid f_i(x) \leq 0, i = 1, \dots, m, h_i(x) = 0, i = 1, \dots, p.\}$$

je konvexná (lebo ... ?)

### Zovšeobecnenie úlohy konvexného programovania

Nech  $\mathcal{C} \subseteq \mathbb{R}^n$  je konvexná množina

$$\min_{x \in \mathcal{C}} f_0(x)$$

Množina  $\mathcal{C}$  by mala byť vhodne popísaná, aby sa úloha dala analyzovať a bolo možné navrhnúť metódy na riešenie.

**Príklad:**  $\mathcal{C} = \mathcal{S}_+^2 = \{X \in \mathbb{R}^{2 \times 2} \mid X = X^T, X \text{ je k.s.d}\}$  - konvexná množina

$$X = \begin{pmatrix} x & y \\ y & z \end{pmatrix} \in \mathcal{S}_+^2 \Leftrightarrow x \geq 0, (z \geq 0, ) y^2 - xz \leq 0$$

- nekonvexné ohraňenie

### Semidefinitné programovanie

-  $C, A_1, \dots, A_m \in \mathcal{S}^n, b \in \mathbb{R}^m$

- štandardný tvar úlohy SDP:

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

- SDP s ohraničeniami typu LMI

$$\begin{aligned} \max \quad & b^T y \\ & y_1 A_1 + \dots + y_m A_m \preceq C \end{aligned}$$

### Príklad: Markowitzovo portfólio

$n$	počet aktív
$x_i$	(relatívne) množstvo aktíva $i$ ( $i = 1, 2, \dots, n$ )
$p_i$	výnos aktíva $i$
$\bar{p} = E(p)$	očakávaný výnos
$\Sigma = E((p - \bar{p})(p - \bar{p})^T)$	kovariančná matica výnosov
$x^T \Sigma x$	variancia portfólia $x$ - miera rizika

Klasická úloha:

$$\begin{aligned} \min_x \quad & x^T \Sigma x \\ & \bar{p}^T x \geq r_{min} \\ & \mathbf{1}^T x = 1, \quad x \geq 0 \end{aligned}$$

- konvexná kvadratická úloha s lineárnymi ohraničeniami

### Alternatívna úloha:

Dané je portfólio  $x$  a čiastková informácia o kovariančnej matici  $\Sigma$  - napr.

- $L_{ij} \leq \Sigma_{ij} \leq U_{ij}$ ,
- $\Sigma_{ii}$  - sú známe, o  $\Sigma_{ij}, i \neq j$  máme neúplnú (resp. žiadnu) informáciu
- navyše  $l_{ij} \leq \frac{\Sigma_{ij}}{\sqrt{(\Sigma_{ii}\Sigma_{jj})}} \leq u_{ij}$

Hľadáme "najhoršie možné riziko" v rámci daných ohraničení:

$$\begin{aligned} \max_{\Sigma} \quad & x^T \Sigma x \\ & L_{ij} \leq \Sigma_{ij} \leq U_{ij} \\ & \Sigma \succeq 0 \end{aligned}$$

- úloha semidefinitného programovania, lebo

$$x^T \Sigma x = \text{tr}(x^T \Sigma x) = \text{tr}(\Sigma x x^T).$$

## Úloha kónického lineárneho programovania (KLP)

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

kde  $K$  je konvexný kužeľ

1. konvexná množina

2. kužeľ -  $x \in K \Rightarrow \alpha x \in K \forall \alpha \geq 0$

1.+2. -  $x, y \in K \Rightarrow \alpha x + \beta y \in K \forall \alpha, \beta \geq 0$

Známe triedy:

$K$	$\mathbb{R}_+^n$	$\mathcal{S}_+^n$	$K_{\ \cdot\ _2}$	$\mathcal{C}_+^n$
úloha	LP	SDP	SOCP	CPP

# Konvexná optimalizácia

SDP:

$$\mathcal{S}_+^n = \{X \in \mathcal{S}^n \mid y^T X y \geq 0 \forall y\}$$


SOCP:

$$K_{\|\cdot\|_2} = \{(x, x_0) \in \mathbb{R}^{n+1} \mid \|x\|_2 \leq x_0\}$$


CPP:

$$\mathcal{C}_+^n = \{X \in \mathcal{S}^n \mid z^T X z \geq 0, \forall z \geq 0\}$$


SDP



SOCP



CPP





### Kónické lineárne programovanie = “zjednocujúci” pohľad na konvexnú optimalizáciu

Každú úlohu konvexného programovania v užšom zmysle:

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

možno naformulovať ako úlohu KLP !

- Epigraf konvexnej funkcie  $Epi(f) = \{(x, t) \in \mathbb{R}^{n+1} \mid f(x) \leq t\}$  je konvexná množina.
- Pre konvexnú množinu  $C$  definujeme konvexný kužeľ

$$K_C = \{(x, s) \mid s > 0, \frac{x}{s} \in C\} \cup \{0\},$$

zrejme  $x \in C \Leftrightarrow (x, 1) \in K_C$ .

## Vlastné kužele

- $K$  - vlastný kužel' (uzavretý, konvexný, špicatý, neprázdne vnútro)
- $x \succeq_K y \Leftrightarrow x - y \in K$
- $\succeq_K$  - v čiastočné usporiadanie (r, as,t), invariantné vzhl'adom na sčítovanie, nezáporné škálovanie a limity, NIE je lineárne usporiadanie.
- $x \succ_K y \Leftrightarrow x - y \in \text{int}K$  (ar, t)

$$\begin{aligned} \min \quad & c^T x \\ & Ax = b \\ & x \succeq_K 0 \end{aligned}$$

# *Konvexná optimalizácia*

---