

# Konvexná optimalizácia

## Podmienky optimality

## Prednáška šiesta: Podmienky optimality

Máme primárno-duálnu dvojicu úloh:

$$\left. \begin{array}{l} \text{Min } f_0(x) \\ f_i(x) \leq 0, \quad i = 1, \dots, m \\ h_i(x) = 0, \quad i = 1, \dots, p \end{array} \right\} (P), \quad \left. \begin{array}{l} \text{Max } G(u, v) \\ u \geq 0 \end{array} \right\} (D),$$

s príslušnou Lagrangeovou funkciou

$$L(x, u, v) = f_0(x) + \sum_{i=1}^m u_i f_i(x) + \sum_{i=1}^p v_i h_i(x),$$

pričom

$$G(u, v) = \inf_x L(x, u, v).$$

**KKT (Karush-Kuhn-Tucker) podmienky optimality:**

$$f_i(x^*) \leq 0, \quad i = 1, \dots, m,$$

$$h_i(x^*) = 0, \quad i = 1, \dots, p,$$

$$u_i^* \geq 0, \quad i = 1, \dots, m,$$

$$u_i f_i(x^*) = 0, \quad i = 1, \dots, m$$

$$\nabla f_0(x^*) + \sum_{i=1}^m u_i^* \nabla f_i(x^*) + \sum_{i=1}^p v_i^* \nabla h_i(x^*) = 0.$$

## Prednáška šiesta: Podmienky optimality

---

Ak  $x^*$  je optimálne riešenie (P) a  $(u^*, v^*)$  je optimálne riešenie (D) a  $p^* = d^*$ , tak zrejme

$$f_0(x^*) = L(x^*, u^*, v^*) = G(u^*, v^*).$$

### Dôsledky:

- Komplementarita -  $u_i f_i(x^*) = 0, i = 1, \dots, m$
- Ak sú funkcie  $f_0, f_1, \dots, f_m, h_1, \dots, h_p$  diferencovateľné, tak z toho, že  $x^*$  minimalizuje  $L(x, u^*, v^*)$  dostávame, že  $\nabla_x L(x^*, u^*, v^*) = 0$ .

Platí pre **ľubovoľnú** úlohu matematického programovania so **silnou dualitou** a diferencovateľnými funkciami:

Ak  $x^*$  a  $(u^*, v^*)$  sú optimálne riešenia (P), (D), tak spĺňajú systém KKT podmienok.

## Prednáška šiesta: Podmienky optimality

---

Pre konvexné úlohy s diferencovateľnými funkciami platí:

Ak body  $x^*$  a  $(u^*, v^*)$  spĺňajú systém KKT podmienok, tak  $x^*$  je optimálne pre (P) a  $(u^*, v^*)$  je optimálne pre (D).

Za predpokladu

- konvexnosti úlohy,
- diferencovateľnosti funkcií  $f_0, f_1, \dots, f_m, h_1, \dots, h_p$
- splnenia Slaterovej podmienky

KKT podmienky sú **nutnými aj postačujúcimi** podmienkami optimality.

**Význam:**

- V niektorých prípadoch je možné analyticky riešiť systém KKT podmienok a získať optimálne riešenia.
- Mnohé algoritmy konvexnej optimalizácie sú založené na riešení systému KKT podmienok.

## Príklad: "Water filling"

Uvažujme úlohu konvexného programovania:

$$\left. \begin{array}{l} \text{Min} \quad - \sum_{i=1}^n \ln(\alpha_i + x_i) \\ \mathbf{1}^T x = 1, \\ x \geq 0, \end{array} \right\} (WF)$$

kde  $\alpha_i > 0$  sú dané.

- $n$  komunikačných (prenosových) kanálov
- $x_i$  - výkon pridelený  $i$ -temu kanálu (vo Wattoch)
- $\ln(\alpha_i + x_i)$  kapacita prenosového kanála
- Úloha: prerozdeliť celkový výkon vysielača medzi komunikačné kanály tak aby sa maximalizovala celková kapacita.

### Lagrangeova funkcia:

$$L(x, u, v) = - \sum_{i=1}^n \ln(\alpha_i + x_i) - u^T x + v(\mathbf{1}^T x - 1)$$

### KKT podmienky:

- Prípustnosť:  $\mathbf{1}^T x = 1, x \geq 0, u \geq 0$ ;
- Komplementarita:  $u_i x_i = 0, i = 1, \dots, m$ ;
- $\nabla_x L(x, u, v) = -\frac{1}{\alpha_i + x_i} - u_i + v = 0$

Premennú  $u$  možno z podmienok **eliminovat'**:  $u = v - \frac{1}{\alpha_i + x_i}$

- Prípustnosť:  $\mathbf{1}^T x = 1, x \geq 0, v \geq \frac{1}{\alpha_i + x_i}$ ;
- Komplementarita:  $x_i \left( v - \frac{1}{\alpha_i + x_i} \right) = 0, i = 1, \dots, m$ ;

## Prednáška šiesta: Podmienky optimality

---

- Ak  $v < \frac{1}{\alpha_i}$  tak  $x_i = \frac{1}{v} - \alpha_i$ .
- Ak  $v \geq \frac{1}{\alpha_i}$ , tak  $x_i = 0$ . Teda

$$x_i = \max \left\{ 0, \frac{1}{v} \right\}, \quad i = 1, \dots, m$$

a


$$\sum_{i=1}^n \max \left\{ 0, \frac{1}{v} \right\} = 1.$$

Funkcia vľavo je po častiach lineárna a rastúca v  $\frac{1}{v}$  a teda rovnica má jediné riešenie.

**Vyriešením rovnice vyššie nájdeme riešenie systému KKT podmienok a teda (keďže úloha je konvexná) aj optimálne riešenie úlohy (WF) a k nej duálnej úlohy.**



## Prednáška šiesta: Podmienky optimality



**"Water filling" metóda:** máme nádrž s  $n$  rôznymi úrovňami, výška každej úrovne je daná hodnotou  $\alpha_i$ . Nádrž sa naplní vodou, ktorej celkové množstvo je 1. Úroveň hladiny je potom rovná optimálnej hodnote  $1/v^*$  a výška hladiny nad  $i$ -tou úrovňou je rovná optimálnej hodnote  $x_i$ .

## PERTURBÁCIA A ANALÝZA CITLIVOSTI

$$\left. \begin{array}{l} \text{Min } f_0(x) \\ f_i(x) \leq r_i, \quad i = 1, \dots, m, \\ h_i(x) = s_i, \quad i = 1, \dots, p. \end{array} \right\} (P(r, s))$$

- $r_i > 0$  - relaxácia i-teho ohraničenia
- $r_i < 0$  - zúženie/stesnenie i-teho ohraničenia
- Optimálna hodnota perturbovanej úlohy  $(P(r,s))$ :

$$p^*(r, s) = \inf \{ f_0(x) \mid f_i(x) \leq r_i, i = 1, \dots, m, h_i(x) = s_i, i = 1, \dots, p \}$$

- $p^*(0, 0) = p^*$
- Ak je  $(P)$  konvexná úloha, tak  $p^*(r, s)$  je konvexná funkcia  $(r, s)$

## Prednáška šiesta: Podmienky optimality

Predpokladajme, že pre neperturovanú úlohu platí  $d^* = p^*$  a duálne optimum sa nadobúda. Nech  $(u^*, v^*)$  je optimálne riešenie duálnej úlohy k neperturovanej primárnej úlohe. Potom platí:


$$p^*(r, s) \geq p^*(0, 0) - (u^*)^T r - (v^*)^T s$$

### Dôsledky:

- Ak je  $u_i^*$  veľké a zvolíme  $r_i < 0$ , tak hodnota  $p^*(r, s)$  prudko vzrastie.
- Ak je  $v_i^*$  veľké a kladné a zvolíme  $s_i < 0$  alebo ak je  $v_i^*$  veľké a záporné a zvolíme  $s_i > 0$ , tak hodnota  $p^*(r, s)$  prudko vzrastie.
- Ak je  $u_i^*$  malé a zvolíme  $r_i > 0$ , tak hodnota  $p^*(r, s)$  príliš neklesne.
- Ak je  $v_i^*$  malé a kladné a zvolíme  $s_i > 0$  alebo ak je  $v_i^*$  malé a záporné a zvolíme  $s_i < 0$ , tak hodnota  $p^*(r, s)$  príliš neklesne.

## Prednáška šiesta: Podmienky optimality

$$\left. \begin{array}{l} \text{Min } f_0(x) \\ f_1(x) \leq r \end{array} \right\}$$



Optimálna hodnota  $p^*(r)$  perturbovanej konvexnej úlohy s jediným ohraňčením  $f_1(x) \leq r$  je konvexnou funkciou  $r$ . Afínna funkcia  $p^*(0) - u^*r$  je dolným ohraňčením na funkciu  $p^*(r)$ .

### Lokálna analýza citlivosti

- Predpokladajme, že  $p^*(r, s)$  je diferencovateľná v  $r = 0, s = 0$ .
- Položme  $r = te_i, s = 0$ . Potom

$$\lim_{t \rightarrow 0} \frac{p^*(te_i, 0) - p^*(0, 0)}{t} = \frac{\partial p^*(0, 0)}{\partial r_i}$$

- Pre  $t > 0$  máme

$$\frac{p^*(te_i, 0) - p^*(0, 0)}{t} \geq -u_i^*$$

- Pre  $t < 0$  máme

$$\frac{p^*(te_i, 0) - p^*(0, 0)}{t} \leq -u_i^*$$

- Teda

$$\frac{\partial p^*(0, 0)}{\partial r_i} = -u_i^*$$

- Analogicky dostaneme

$$\frac{\partial p^*(0, 0)}{\partial s_i} = -v_i^*$$

## Prednáška šiesta: Podmienky optimality

---

Teda platí:

$$\frac{\partial p^*(0,0)}{\partial r_i} = -u_i^*, \quad \frac{\partial p^*(0,0)}{\partial s_i} = -v_i^*$$

Ak  $x^*$  je optimálne riešenie (P):

- $f_i(x^*) < 0$  - neaktívne ohraničenie,  $u_i^* = 0$
- $f_i(x^*) = 0$  - aktívne ohraničenie -
  - $u_i^*$  malé - uvoľnenie / zúženie i-teho ohraničenia nemá veľký vplyv na  $p^*$ .
  - $u_i^*$  veľké - uvoľnenie / zúženie i-teho ohraničenia má veľký vplyv na  $p^*$ .