

# Lineární a nelineární programování (Učební text)

J. Rohn<sup>1</sup>

20. května 1997

<sup>1</sup>Sepsání tohoto textu bylo podpořeno z grantu GAUK 195/96

# Kapitola 1

## Simplexová metoda

### 1.1 Základní pojmy

Základní problém:

$$\min\{c^T x; Ax = b, x \geq 0\} \quad (\text{P})$$

(historie, motivační příklady atd. - na cvičení)

Značení:  $c^T x$ ,  $A$ ,  $A^T$ ,  $(AB)^T = B^T A^T$ , speciálně  $(Ax)^T = x^T A^T$ ;  $(A^{-1})^T = (A^T)^{-1}$  je-li  $A$  čtvercová atd.;  $x \geq y$ ,  $x \geq 0$ ;  $x^T y = y^T x$  (komutativnost); je-li  $x \geq y$  a  $z \geq 0$ , potom  $z^T x \geq z^T y$ .  $A_j$  je  $j$ -tý sloupec matice  $A$ , spec.  $(AC)_j = AC_j$ ;  $I$  je jednotková matice,  $e_j = I_j$ .

Definice: přípustné řešení, optimální řešení, bázické řešení:  $\{A_j; x_j > 0\}$  lin. nezávislá

### 1.2 Bázická řešení

**Věta 1** *Má-li (P) optimální řešení, potom má i bázické optimální řešení.*

**Důkaz** Ukážeme, že ke každému optimálnímu řešení, které není bázické, existuje optimální řešení s *menším* počtem kladných složek. Opakováním dojdeme k bázickému.

1. Nechť  $x$  je optimální, není bázické. Nechť  $J = \{j; x_j > 0\}$ , potom  $\sum_{j \in J} A_j y_j = 0$ ,  $y_{j_0} \neq 0$ . Dodefinujeme  $y_j = 0$  pro  $j \notin J$ , potom  $Ay = 0$ , a lze předpokládat  $y_{j_0} < 0$ , jinak  $y := -y$ . Potom

$$x_j = 0 \Rightarrow j \notin J \Rightarrow y_j = 0. \quad (1.1)$$

2. Dokážeme, že  $c^T y = 0$ . Sporem:
- a) je-li  $c^T y < 0$ , zvolme  $\alpha > 0$ , aby  $x + \alpha y \geq 0$  (to je možné vzhledem k (1.1)), potom  $A(x + \alpha y) = Ax = b$ , tedy  $x + \alpha y$  příp., a  $c^T(x + \alpha y) = c^T x + \alpha c^T y < c^T x$  spor.
- b) pro  $c^T y > 0$  analogicky zvolíme  $\alpha < 0$ , aby  $x + \alpha y \geq 0$ , potom  $x + \alpha y$  přípustné a  $c^T(x + \alpha y) < c^T x$  spor.
3. Položme  $x' = x + \varepsilon^* y$ , kde

$$\varepsilon^* = \min \left\{ \frac{-x_j}{y_j}; y_j < 0 \right\}.$$

Rozborem případů vzhledem k (1.1) je  $x' \geq 0$ ,  $Ax' = b$ ,  $c^T x' = c^T x$ , tedy  $x'$  je optimální. Dále  $\varepsilon^* = \frac{-x_k}{y_k}$ , tj.  $x'_k = 0$ ,  $y_k < 0 \Rightarrow k \in J$ , ale  $x'_j \neq 0 \Rightarrow x_j \neq 0$  &  $x_j > 0 \forall j \in J$ , tedy  $x'$  má aspoň o 1 kladnou složku méně.

■

Nechť  $A$  je matice  $m \times n$ ,  $m \leq n$ , a necht'  $B = (B_1, \dots, B_m)$  je uspořádaná  $m$ -tice vzájemně různých čísel z  $\{1, \dots, n\}$ . Potom symbolem  $A_B$  značíme matici

$$A_B = (A_{B_1}, \dots, A_{B_m})$$

tj.  $(A_B)_j = A_{B_j} \forall j$ . Podobně  $x_B = (x_{B_1}, \dots, x_{B_m})^T$ , tj.  $(x_B)_j = x_{B_j}$ . Podobně  $c_B$ . Pro doplněk  $N = \{1, \dots, n\} - \{B_1, \dots, B_m\}$ ,  $N = (N_1, \dots, N_{n-m})$  podobně  $A_N, x_N, c_N$ .

**Věta 2** *Nechť  $m \leq n$  a necht' řádky matice  $A$  jsou lineárně nezávislé. Potom  $x$  je bázeickým přípustným řešením právě když existuje  $B = (B_1, \dots, B_m)$  tak, že  $A_B$  je regulární,  $A_B x_B = b$  má řešení  $x_B \geq 0$ , a  $x_N = 0$ .*

**Důkaz**  $\Rightarrow$  Je-li  $x$  bázeické, je  $\{A_j; x_j > 0\}$  lineárně nezávislá a lze ji doplnit na  $m$ -prvkovou bázi. Necht'  $B$  jsou indexy prvků této báze, potom  $A_B$  je regulární,  $Ax = A_B x_B = b$ ,  $x_B \geq 0$ ,  $x_N = 0$ .  $\Leftarrow$ : Jestliže to platí, potom  $\{A_j; x_j > 0\} \subseteq \{A_j; j \in B\}$ , tedy sloupce lineárně nezávislé a řešení je bázeické. ■

**Značení** Pro  $B = (B_1, \dots, B_m)$ , jestliže  $A_B$  je regulární a  $A_B y = b$  má řešení  $y \geq 0$ , potom definujeme  $x^B$  předpisem

$$\begin{aligned} (x^B)_B &= y \\ (x^B)_N &= 0 \end{aligned}$$

Jinak (je-li  $A_B$  singulární nebo  $y \not\geq 0$ ) není  $x^B$  definováno.  
 Upozornění:  $x^B$  nezávisí na uspořádání množiny  $B$ .

**Příklad Pro**

$$\begin{aligned}x_1 + 2x_2 + 3x_3 &= 6 \\4x_1 + 5x_2 + 6x_3 &= 15\end{aligned}$$

je  $x^{(1,3)}$  dáno požadavky

$$\begin{aligned}x_1 + 3x_3 &= 6 \\4x_1 + 6x_3 &= 15\end{aligned}$$

z toho

$$x^{(1,3)} = \left(\frac{3}{2}, 0, \frac{3}{2}\right)^T$$

a podobně

$$\begin{aligned}x^{(1,2)} &= (0, 3, 0)^T \\x^{(2,3)} &= (0, 3, 0)^T\end{aligned}$$

Upozornění: z  $a \geq b$ ,  $x \geq 0$  plyne  $a^T x \geq b^T x$ . Rovněž  $(AC)_s = AC_s$ .

### 1.3 Kritérium optimality a neomezenosti

**Věta 3** (*kritérium optimality*). Nechť pro jisté  $B$  platí

$$c^T - c_B^T A_B^{-1} A \geq 0^T.$$

Potom  $x^B$  je optimální řešení úlohy (P).

**Důkaz** Nechť  $x$  je libovolné přípustné řešení úlohy (P). Potom z

$$c^T \geq c_B^T A_B^{-1} A$$

přenásobením plyne

$$c^T x \geq c_B^T A_B^{-1} A x = c_B^T A_B^{-1} b = c_B^T x_B^B = c_B^T x_B^B + c_N^T x_N^B = c^T x^B,$$

tedy  $x^B$  je optimální. ■

Pro danou (pevně zvolenou) bázi  $B$  označíme

$$\begin{aligned}\bar{A} &= A_B^{-1}A = (\bar{a}_{ij}) \\ \bar{b} &= x_B^B = A_B^{-1}b = (\bar{b}_i) \\ \bar{c} &= c^T - c_B^T A_B^{-1}A = (\bar{c}_j) \\ \bar{h} &= -c_B^T x_B^B = -c_B^T A_B^{-1}b.\end{aligned}$$

Potom kritérium optimality je  $\bar{c} \geq 0^T$ . Platí  $\bar{c}_B = c_B^T - c_B^T A_B^{-1}A_B = 0_B^T$ .

**Věta 4** (*kritérium neomezenosti*). *Nechť pro dané  $B$  existuje  $s$  tak, že  $\bar{c}_s < 0$  a  $\bar{A}_s \leq 0$  (tj.  $\bar{a}_{js} \leq 0 \forall j$ ). Potom*

$$\inf\{c^T x; Ax = b, x \geq 0\} = -\infty,$$

*tj. hodnota účelové funkce není na množině přípustných řešení zdola omezená.*

**Důkaz** Protože  $\bar{c}_s < 0$ , je  $s \notin B$ . Označme  $z = \bar{A}_s = (A_B^{-1}A)_s = A_B^{-1}A_s \leq 0$ , potom  $-A_B z + A_s = 0$ , tedy zavedeme-li  $y$  vztahy  $y_B = -z$ ,  $y_s = +1$ ,  $y_j = 0$  jinak, je  $Ay = 0$ ,  $y \geq 0$ ,  $y \neq 0$ , takže  $A(x^B + \alpha y) = b$ ,  $x^B + \alpha y \geq 0$  pro každé  $\alpha \geq 0$ , a platí

$$\begin{aligned}c^T(x^B + \alpha y) &= c^T x^B + \alpha(c^T y) = c^T x^B + \alpha \left( c_B^T y_B + c_s y_s + \sum_{j \notin B, j \neq s} c_j y_j \right) = \\ &= c^T x^B + \alpha (c_s - c_B^T A_B^{-1} A_s) = c^T x^B + \alpha \bar{c}_s,\end{aligned}$$

tedy

$$c^T(x^B + \alpha y) = c^T x^B + \alpha \bar{c}_s \xrightarrow{\alpha \rightarrow \infty} -\infty$$

a tedy  $\inf\{\dots\} = -\infty$ . ■

## 1.4 Simplexová tabulka

Připomeňme pojem elementárních operací:

- 1) násobení  $i$ -tého řádku číslem  $\alpha \neq 0$ ,
- 2) násobení  $i$ -tého řádku číslem  $\alpha$  a přičtení k jinému řádku  $j \neq i$ .

Pro  $i, j \in \{1, \dots, m\}$ ,  $\alpha \in R^1$  definujme  $P_{ij}(\alpha)$  jako matici, která vznikne z jednotkové matice  $I$  nahrazením  $ji$ -tého prvku číslem  $\alpha$ . Snadno nahlédneme, že elementární operace 1) je ekvivalentní vynásobením zleva maticí  $P_{ii}(\alpha)$  pro kterou  $\det P_{ii}(\alpha) = \alpha \neq 0$ , a elementární operace 2) je ekvivalentní vynásobením zleva maticí  $P_{ij}(\alpha)$  s  $\det P_{ij}(\alpha) = 1$ . Tedy výsledek  $\tilde{A}$  posloupnosti elementárních operací s maticí  $A$  lze psát ve tvaru

$$\tilde{A} = P_{i_k j_k}(\alpha_k) \cdot \dots \cdot P_{i_1 j_1}(\alpha_1)A,$$

a položíme-li  $\tilde{P} = P_{i_k j_k}(\alpha_k) \cdot \dots \cdot P_{i_1 j_1}(\alpha_1)$ , je

$$\tilde{A} = \tilde{P}A$$

kde  $\tilde{P}$  je regulární matice, neboť  $\det \tilde{P} = (\det P_{i_k j_k}(\alpha_k)) \cdot \dots \cdot (\det P_{i_1 j_1}(\alpha_1)) \neq 0$ .

**Věta 5** *Nechť matice*

$$\begin{pmatrix} A & b \\ c^T & 0 \end{pmatrix}$$

*je elementárními úpravami (včetně posledního řádku, ale s pivoty jen v části A) převedena tak, že v  $B_j$ -tém sloupci vznikne  $j$ -tý sloupec jednotkové matice ( $j = 1, \dots, m$ ). Potom má výsledná matice tvar*

$$\begin{pmatrix} \bar{A} & \bar{b} \\ \bar{c} & -\bar{h} \end{pmatrix},$$

kde

$$\begin{aligned} \bar{A} &= A_B^{-1}A, \\ \bar{b} &= A_B^{-1}b = x_B^B, \\ \bar{c} &= c^T - c_B^T A_B^{-1}A, \\ \bar{h} &= c_B^T x_B^B = c^T x^B. \end{aligned}$$

**Důkaz** Kdyby některá  $P_k$  měla tvar  $\begin{pmatrix} 1 & & & \\ & \ddots & & \\ & & 1 & \dots & \alpha \\ & & & \ddots & \\ & & & & 1 \end{pmatrix}$ , potom by se k  $i$ -tému

řádku připočítával násobek posledního, což je ve sporu. Proto  $P_j = \begin{pmatrix} 0 \\ 0 \\ \dots \\ \vdots \\ 1 \end{pmatrix} \forall j$ ,

tedy  $P = \begin{pmatrix} 0 \\ 0 \\ \dots \\ \vdots \\ 1 \end{pmatrix}$ , protože  $\begin{pmatrix} 0 \\ 0 \\ \dots \\ \vdots \\ 1 \end{pmatrix} \begin{pmatrix} 0 \\ 0 \\ \dots \\ \vdots \\ 1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ \dots \\ \vdots \\ 1 \end{pmatrix}$  Tedy výsledná

matice má tvar

$$\begin{pmatrix} P & 0 \\ y^T & 1 \end{pmatrix} \begin{pmatrix} A & b \\ c^T & 0 \end{pmatrix} = \begin{pmatrix} PA & Pb \\ y^T A + c^T & y^T b \end{pmatrix}.$$

Podle předpokladu je  $(PA)_{B_j} = PA_{B_j} = P(A_B)_j = (PA_B)_j = I_j \Rightarrow PA_B = I \Rightarrow P = A_B^{-1}$ , a  $0_B^T = (y^T A + c^T)_B = y^T A_B + c_B^T \Rightarrow y^T A_B = -c_B^T \Rightarrow y^T = -c_B^T A_B^{-1}$ , tedy výsledná matice má tvar

$$\begin{pmatrix} A_B^{-1}A & A_B^{-1}b \\ c^T - c_B^T A_B^{-1}A & -c_B^T A_B^{-1}b \end{pmatrix} = \begin{pmatrix} \bar{A} & \bar{b} \\ \bar{c} & -\bar{h} \end{pmatrix}.$$

■

## 1.5 Algoritmus

Myšlenka algoritmu: přejít od  $B = (B_1, \dots, B_{r-1}, B_r, B_{r+1}, \dots, B_m)$  k  $B' = (B_1, \dots, B_{r-1}, s, B_{r+1}, \dots, B_m)$ , tj. v  $s$ -tém sloupci se má objevit  $r$ -tý sloupec jednotkové matice, tedy pivotace s pivotem  $\bar{a}_{rs}$ .

$$\begin{array}{ccc|ccc} \vdots & & & \vdots & & & \vdots \\ \dots & \bar{a}_{rs} & \dots & \bar{b}_r & \dots & 1 & \dots & \frac{\bar{b}_r}{\bar{a}_{rs}} \\ \vdots & & & \vdots & & & & \vdots \\ \dots & \bar{a}_{js} & \dots & \bar{b}_j & \dots & 0 & \dots & \bar{b}_j - \bar{a}_{js} \frac{\bar{b}_r}{\bar{a}_{rs}} \\ \vdots & & & \vdots & & & & \vdots \\ \hline \dots & \bar{c}_s & \dots & -\bar{h} & \dots & 0 & \dots & -\bar{h} - \bar{c}_s \frac{\bar{b}_r}{\bar{a}_{rs}} \end{array} \longrightarrow$$

Požadavky:

1.  $\bar{a}_{rs} > 0$ , aby  $\frac{\bar{b}_r}{\bar{a}_{rs}} \geq 0$ ;
2. zachování bázičnosti  
 $\frac{\bar{b}_r}{\bar{a}_{rs}} \geq 0$  (viz 1);  $\bar{b}_j - \bar{a}_{js} \frac{\bar{b}_r}{\bar{a}_{rs}} \geq 0$ : splněno pro  $\bar{a}_{js} \leq 0$

$$\bar{a}_{js} > 0 : \frac{\bar{b}_j}{\bar{a}_{js}} \geq \frac{\bar{b}_r}{\bar{a}_{rs}} \quad \text{tedy} \quad \frac{\bar{b}_r}{\bar{a}_{rs}} = \min \left\{ \frac{\bar{b}_j}{\bar{a}_{js}}; \bar{a}_{js} > 0 \right\}$$

3. klesání úč. funkce:

$$-\bar{h} - \bar{c}_s \frac{\bar{b}_r}{\bar{a}_{rs}} = - \left( \bar{h} + \bar{c}_s \frac{\bar{b}_r}{\bar{a}_{rs}} \right);$$

aby klesla, musí být  $\bar{c}_s \frac{\bar{b}_r}{\bar{a}_{rs}} \leq 0$ , tedy  $\bar{c}_s < 0$ .

## Pravidla pro výběr

$$\bar{c}_s < 0$$
$$\frac{\bar{b}_r}{\bar{a}_{rs}} = \min \left\{ \frac{\bar{b}_j}{\bar{a}_{js}}; \bar{a}_{js} > 0 \right\}, \quad \bar{a}_{rs} > 0.$$

Shrneme-li dosavadní poznatky, můžeme formulovat tento algoritmus:

**Algoritmus** (simplexová metoda; Dantzig 1947)

*opt:* = false; *neom:* = false;

nalezní výchozí přípustné báze a sestav tabulku;

**repeat**

**if**  $\bar{c} \geq 0$  **then** *opt:* = true

**else**

        vyber  $s$ , aby  $\bar{c}_s < 0$ ;

**if**  $\bar{A}_s \leq 0$  **then** *neom:* = true

**else**

            vyber  $r$ , aby  $\frac{\bar{b}_r}{\bar{a}_{rs}} = \min \left\{ \frac{\bar{b}_j}{\bar{a}_{js}}; \bar{a}_{js} > 0 \right\}, \bar{a}_{rs} > 0$ ;

            proved' eliminaci s pivotem  $\bar{a}_{rs}$ ;

$B_r := s$

**until** (*opt* or *neom*);

**if** *opt* **then**  $\{x^B$  je optimální řešení}

**else** {úloha je neomezená}

(pozn. opt řešení  $x^B$  je v tabulce dáno jako  $x_B^B = \bar{b}$ ,  $x_N^B = 0$ ). Výběr  $r$ ,  $s$  nejednoznačný, může se zacyklit. Heuristické pravidlo  $\bar{c}_s = \min_j \bar{c}_j < 0$ .

## 1.6 Konečnost simplexového algoritmu

**Blandovo pravidlo** (Bland 1977)

**Výběr**  $s$ :  $s = \min\{j; \bar{c}_j < 0\}$

**Výběr**  $r$ : ze všech  $r$ , pro které platí

$$\frac{\bar{b}_r}{\bar{a}_{rs}} = \min \left\{ \frac{\bar{b}_j}{\bar{a}_{js}}; \bar{a}_{js} > 0 \right\}, \quad \bar{a}_{rs} > 0$$

vyber to, pro které má  $B_r$  nejmenší hodnotu tj.

$$B_r = \min \left\{ B_k; \frac{\bar{b}_k}{\bar{a}_{ks}} = \min \left\{ \frac{\bar{b}_j}{\bar{a}_{js}}; \bar{a}_{js} > 0 \right\}, \bar{a}_{ks} > 0 \right\}$$



**Příklad**  $4 \times 7$  (viz výpisy). Zacyklení resp. konečný výpočet.

**Cyklem** rozumíme konečnou posloupnost kroků simplexového algoritmu, která začíná i končí stejnou bází. Determinističnost Blandova pravidla způsobuje, že se pak cyklus stále opakuje.

**Tvrzení** V průběhu cyklu:

1. zůstává poslední sloupec beze změny,
2. v každém kroku pro řádek  $r$  obsahující pivota platí  $\bar{b}_r = 0$

**Důkaz** Nastává-li cyklus mezi  $B^1$  a  $B^2$ , pak  $c^T x^{B^1} \geq c^T x' \geq c^T x'' \geq \dots \geq c^T x^{B^2} = c^T x_1^B \Rightarrow$  všude rovnost. Jelikož  $-\bar{h} := -\bar{h} - \frac{\bar{b}_r \bar{c}_s}{\bar{a}_{rs}}$ , musí být  $\bar{b}_r \bar{c}_s = 0$ , a jelikož  $\bar{c}_s < 0$ , je  $\bar{b}_r = 0$ . Dále,  $\bar{b}_j := \bar{b}_j - \frac{\bar{b}_r \bar{a}_{js}}{\bar{a}_{rs}} = \bar{b}_j$ , podobně  $\bar{h}$ , tedy celý poslední sloupec tabulky se nemění. ■

$$\left| \begin{array}{ccc|c} \vdots & & & \vdots \\ \dots & \bar{a}_{rs} & \dots & \bar{b}_r \\ \vdots & & & \vdots \\ \dots & \bar{a}_{js} & \dots & \bar{b}_j \\ \vdots & & & \vdots \\ \hline \dots & \bar{c}_s & \dots & -\bar{h} \end{array} \right|$$

**Věta 6** Simplexový algoritmus je při použití Blandova pravidla konečný.

**Důkaz** Předpokládejme, že se pro jistou úlohu zacyklí. Označme  $T$  množinu všech indexů  $s$ , vstupujících do báze během cyklu, a necht'  $q = \max T$ . Necht'  $q$  vstupuje a vystupuje v tabulkách

$$\begin{array}{c|ccc|c} B_0 & & & \vdots \\ & \dots & & \\ \hline & \dots & y_q < 0 & \dots \end{array} \quad \begin{array}{c|ccc|c} k = B_p & \dots & \bar{a}_{ps} & \dots & \bar{b}_p \\ \vdots & & \vdots & & \vdots \\ q = B_r & \dots & \bar{a}_{rs} & \dots & \bar{b}_r \\ \hline & \dots & \bar{c}_s < 0 & \dots & \end{array}$$

Definujme  $z$  předpisem  $z_B = \bar{A}_s$  (tj.  $z_{B_j} = \bar{a}_{js} \forall j$ ),  $z_s = -1$ ,  $z_j = 0$  jinak, tedy  $z_B = A_B^{-1} A_s$ ,  $A_B z_B + (-1) A_s = A z = 0$ , a máme

$$\begin{aligned} yz &= (c^T - c_{B_0} A_{B_0}^{-1} A) z = c^T z = c_B^T z_B + c_s z_s = c_B^T A_B^{-1} A_s - c_s \\ &= -(c_s - c_B^T A_B^{-1} A_s) = -\bar{c}_s > 0, \end{aligned}$$

tzn., že existuje  $k$ , že  $y_k z_k > 0$ .  $y_k \neq 0 \Rightarrow k \notin B_0$ ;  $z_k \neq 0 \Rightarrow$  buď  $k \in B$ , nebo  $k = s$  tj. buď je v bázi, nebo právě vstupuje  $\Rightarrow k \in T$ . Dále pro  $y_q z_q = y_q \bar{a}_{rs} < 0$ , tedy  $k \neq q$ . Dokážeme, že  $q < k$ , to bude spor s volbou  $q$ .

Protože  $y_k z_k > 0$ , je buď a)  $y_k < 0, z_k < 0$ , nebo b)  $y_k > 0, z_k > 0$ .

a) Je-li  $y_k < 0$ , potom  $k$  připadalo v úvahu pro vstup, ale nebylo vybráno  $\Rightarrow q < k$ .

b) Je-li  $y_k > 0, z_k > 0$ , potom  $z_k = z_{B_p} = \bar{a}_{ps} > 0$ . Protože  $y_k > 0, k$  nebylo v bázi  $B_0$ , ale je v  $B$ , tedy muselo vstoupit a tedy  $\bar{b}_p = 0$ , tj.

$$0 = \frac{\bar{b}_p}{\bar{a}_{ps}} = \min \left\{ \frac{\bar{b}_j}{\bar{a}_{js}}; \bar{a}_{js} > 0 \right\}.$$

Tedy  $p$  bylo vhodné pro výběr, ale nebylo vybráno, tj. podle Blandova pravidla  $B_r < B_p$  tj.  $q < k$ .

V obou případech je  $q < k$ , tedy jsme našli  $k \in T, k > q$ , kde  $q = \max T$ , a to je spor. ■

Sestavení výchozí tabulky:

Lze rovnou předpokládat, že  $b \geq 0$ , jinak pro každé  $b_i < 0$  nahradíme rovnici  $(Ax)_i = b_i$  rovnicí  $-(Ax)_i = -b_i > 0$ . Uvažujme pomocnou úlohu

$$\min \{0^T x + e^T x'; Ax + Ix' = b, x \geq 0, x' \geq 0\} \quad (1.2)$$

s počátečním bázeickým řešením  $x' = b, x = 0$ . Aby to mělo tvar tabulky, musíme vynulovat část pod  $x'$ . Účelová funkce  $\geq 0 \Rightarrow$  není neomezená. Tedy po konečně mnoha krocích nalezneme optimální řešení a optimální hodnotu  $h^*$ .

$h^* > 0 \Rightarrow$  neexistuje bázeické př. řešení  $\Rightarrow$  algoritmus končí

$h^* = 0 \Rightarrow$  máme př. řešení a z něho lze pokračovat k optimálnímu.

**Věta 7** Pro každou úlohu  $(P)$  nastává právě jedna ze tří možností:

(i) úloha nemá přípustné řešení,

(ii) úloha má optimální řešení,

(iii) účelová funkce je na množině přípustných řešení neomezená zdola

**Důkaz** Fáze I i II jsou podle Věty 6 konečné a proto po konečném počtu kroků dojde k jednomu ze tří možných zastavení. ■

## 1.7 Ukázka zacyklení

1	1.000	0.000	0.000	0.000	0.600	-6.400	4.800	0.000
2	0.000	1.000	0.000	0.000	0.200	-1.800	0.600	0.000
3	0.000	0.000	1.000	0.000	0.400	-1.600	0.200	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.000	0.000	0.000	0.000	-0.400	-0.400	1.800	0.000

5	1.667	0.000	0.000	0.000	1.000	-10.667	8.000	0.000
2	-0.333	1.000	0.000	0.000	0.000	0.333	-1.000	0.000
3	-0.667	0.000	1.000	0.000	0.000	2.667	-3.000	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.667	0.000	0.000	0.000	0.000	-4.667	5.000	0.000

5	-9.000	32.000	0.000	0.000	1.000	0.000	-24.000	0.000
6	-1.000	3.000	0.000	0.000	0.000	1.000	-3.000	0.000
3	2.000	-8.000	1.000	0.000	0.000	0.000	5.000	0.000
4	1.000	-3.000	0.000	1.000	0.000	0.000	3.000	1.000
	-4.000	14.000	0.000	0.000	0.000	0.000	-9.000	0.000

5	0.600	-6.400	4.800	0.000	1.000	0.000	0.000	0.000
6	0.200	-1.800	0.600	0.000	0.000	1.000	0.000	0.000
7	0.400	-1.600	0.200	0.000	0.000	0.000	1.000	0.000
4	-0.200	1.800	-0.600	1.000	0.000	0.000	0.000	1.000
	-0.400	-0.400	1.800	0.000	0.000	0.000	0.000	0.000

1	1.000	-10.667	8.000	0.000	1.667	0.000	0.000	0.000
6	0.000	0.333	-1.000	0.000	-0.333	1.000	0.000	0.000
7	0.000	2.667	-3.000	0.000	-0.667	0.000	1.000	0.000
4	0.000	-0.333	1.000	1.000	0.333	0.000	0.000	1.000
	0.000	-4.667	5.000	0.000	0.667	0.000	0.000	0.000

1	1.000	0.000	-24.000	0.000	-9.000	32.000	0.000	0.000
2	0.000	1.000	-3.000	0.000	-1.000	3.000	0.000	0.000
7	0.000	0.000	5.000	0.000	2.000	-8.000	1.000	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.000	0.000	-9.000	0.000	-4.000	14.000	0.000	0.000

1	1.000	0.000	0.000	0.000	0.600	-6.400	4.800	0.000
2	0.000	1.000	0.000	0.000	0.200	-1.800	0.600	0.000
3	0.000	0.000	1.000	0.000	0.400	-1.600	0.200	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.000	0.000	0.000	0.000	-0.400	-0.400	1.800	0.000

5	1.667	0.000	0.000	0.000	1.000	-10.667	8.000	0.000
2	-0.333	1.000	0.000	0.000	0.000	0.333	-1.000	0.000
3	-0.667	0.000	1.000	0.000	0.000	2.667	-3.000	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.667	0.000	0.000	0.000	0.000	-4.667	5.000	0.000

Výběr s: minimální prvek v krit. řádku, v případě rovnosti první zleva  
Výběr r: podle obvyklého pravidla, v případě rovnosti první shora

1	1.000	0.000	0.000	0.000	0.600	-6.400	4.800	0.000
2	0.000	1.000	0.000	0.000	0.200	-1.800	0.600	0.000
3	0.000	0.000	1.000	0.000	0.400	-1.600	0.200	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.000	0.000	0.000	0.000	-0.400	-0.400	1.800	0.000

5	1.667	0.000	0.000	0.000	1.000	-10.667	8.000	0.000
2	-0.333	1.000	0.000	0.000	0.000	0.333	-1.000	0.000
3	-0.667	0.000	1.000	0.000	0.000	2.667	-3.000	0.000
4	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
	0.667	0.000	0.000	0.000	0.000	-4.667	5.000	0.000

5	-9.000	32.000	0.000	0.000	1.000	0.000	-24.000	0.000
6	-1.000	3.000	0.000	0.000	0.000	1.000	-3.000	0.000
3	2.000	-8.000	1.000	0.000	0.000	0.000	5.000	0.000
4	1.000	-3.000	0.000	1.000	0.000	0.000	3.000	1.000
	-4.000	14.000	0.000	0.000	0.000	0.000	-9.000	0.000

5	0.000	-4.000	4.500	0.000	1.000	0.000	-1.500	0.000
6	0.000	-1.000	0.500	0.000	0.000	1.000	-0.500	0.000
1	1.000	-4.000	0.500	0.000	0.000	0.000	2.500	0.000
4	0.000	1.000	-0.500	1.000	0.000	0.000	0.500	1.000
	0.000	-2.000	2.000	0.000	0.000	0.000	1.000	0.000

5	0.000	0.000	2.500	4.000	1.000	0.000	0.500	4.000
6	0.000	0.000	0.000	1.000	0.000	1.000	0.000	1.000
1	1.000	0.000	-1.500	4.000	0.000	0.000	4.500	4.000
2	0.000	1.000	-0.500	1.000	0.000	0.000	0.500	1.000
	0.000	0.000	1.000	2.000	0.000	0.000	2.000	2.000

Optimální řešení: 4 1 0 0 4 1 0

Výpočet příkladu na zacyklení Blandovým pravidlem. Liší se od 4. tabulky.

## 1.8 Množina optimálních řešení

**Věta 8** *Nechť v tabulce*

$$\left| \begin{array}{c|c} \bar{A} & \bar{b} \\ \hline \bar{c} \geq 0 & -\bar{h} \end{array} \right|$$

*je nalezeno optimální řešení. Potom množina všech optimálních řešení je popsána soustavou*

$$\begin{aligned} \bar{A}x^* &= \bar{b} \\ \bar{c}x^* &= 0 \\ x^* &\geq 0. \end{aligned}$$

**Důkaz**  $\Rightarrow$  Je-li  $x^*$  optimální řešení, potom je přípustné, tedy z  $Ax^* = b$  plyne  $\bar{A}x^* = A_B^{-1}Ax^* = A_B^{-1}b = \bar{b}$ , a  $\bar{c}x^* = (c^T - c_B^T A_B^{-1}A)x^* = c^T x^* - c_B^T A_B^{-1}b =$

$c^T x^* - \bar{h} = 0$ .  $\Leftarrow$  Naopak, z  $\bar{A}x^* = \bar{b}$  plyne  $Ax^* = b$ , tedy  $x^*$  je přípustné, a  $\bar{c}x^* = c^T x^* - c_B^T x_B^B = c^T x^* - \bar{h} = 0$  tedy  $c^T x^* = \bar{h}$ , kde  $\bar{h}$  je optimální hodnota  $\Rightarrow x^*$  optimální. ■

**Věta 9** *Je-li v poslední tabulce*

$$\bar{c}_j > 0 \quad \text{pro všechna } j \in N$$

*[tj.  $\bar{c}_N > 0$ ], potom úloha má právě jedno optimální řešení.*

**Důkaz** Každé optimální řešení  $x^*$  splňuje  $\bar{c}x^* = \sum_{j \in N} c_j x_j^* = 0$ , tedy podle předpokladu je  $x_j^* = 0 \quad \forall j \in N$ . To znamená, že pro poslední bázi  $B$  je  $Ax^* = A_B x_B^* + A_N x_N^* = A_B x_B^* = b$ , tedy  $x_B^* = A_B^{-1} b$  a  $x_N^* = 0$ , tj.  $x^* = x^B$  a řešení je jediné. ■

# Kapitola 2

## Teorie duality

K úloze

$$\min\{c^T x; Ax = b, x \geq 0\} \quad (P)$$

uvažujme duální úlohu

$$\max\{b^T y; A^T y \leq c\}. \quad (D)$$

### 2.1 Věta o dualitě

**Věta 10** (slabá věta o dualitě). *Jsou-li  $x, y$  přípustná řešení (P), (D), potom platí*

$$c^T x \geq b^T y.$$

*Navíc, platí-li pro jistou dvojici přípustných řešení*

$$c^T x^* = b^T y^*,$$

*potom  $x^*$  je optimální řešení (P) a  $y^*$  je optimální řešení (D).*

**Důkaz** Platí

$$c^T x = x^T c \geq x^T A^T y = (Ax)^T y = b^T y$$

Je-li  $c^T x^* = b^T y^*$ , potom pro každé přípustné řešení  $x$  je  $c^T x \geq b^T y^* = c^T x^*$ , tedy  $x^*$  je optimální řešení (P), a  $\forall$  přípustné řešení  $y$  je  $b^T y^* = c^T x^* \geq b^T y$ , tedy  $y^*$  je optimální řešení (D). ■

**Věta 11** Je-li  $x^B$  bázičké optimální řešení nalezené v posledním kroku simplexového algoritmu, potom

$$y^* = (A_B^T)^{-1}c_B$$

je optimálním řešením (D) a platí  $c^T x^B = b^T y^*$ .

**Důkaz** V poslední tabulce je  $\bar{c} := c^T - c_B^T A_B^{-1} A \geq 0$ , tedy  $c^T - [(A_B^T)^{-1}c_B]^T A = c^T - y^{*T} A \geq 0$ , tj.  $A^T y^* \leq c$ ,  $y^*$  je přípustné řešení (D). Dále  $c^T x^B = c_B^T x_B^B = c_B^T A_B^{-1} b = [(A_B^T)^{-1}c_B]^T b = y^{*T} b = b^T y^*$  a podle Věty 10 je  $y^*$  optimální řešení (D). ■

**Věta 12** (o dualitě). Úloha (P) má optimální řešení, právě když úloha (D) má optimální řešení. V tom případě mají obě stejnou optimální hodnotu.

**Důkaz**

1. Má-li (P) optimální řešení, potom podle Věty 6 simplexová metoda po konečně mnoha krocích najde optimální tabulku, v ní lze podle Věty 11 nalézt optimální řešení (D) a optimální hodnoty se rovnají.
2. Naopak, má-li

$$\max\{b^T y; A^T y \leq c\} \tag{D}$$

optimální řešení, potom i

$$\min\{-b^T y_1 + b^T y_2 + 0^T y_3; A^T y_1 - A^T y_2 + y_3 = c, y_1, y_2, y_3 \geq 0\}$$

má optimální řešení, tedy ho má i úloha

$$\min\left\{\left(\begin{array}{c} -b \\ b \\ 0 \end{array}\right)^T \left(\begin{array}{c} y_1 \\ y_2 \\ y_3 \end{array}\right); (A^T, -A^T, I) \left(\begin{array}{c} y_1 \\ y_2 \\ y_3 \end{array}\right) = c, \left(\begin{array}{c} y_1 \\ y_2 \\ y_3 \end{array}\right) \geq 0\right\}$$

a podle toho, co jsme dokázali dříve, má optimální řešení k ní duální úloha

$$\max\left\{c^T x'; \left(\begin{array}{c} A \\ -A \\ I \end{array}\right) x' \leq \left(\begin{array}{c} -b \\ b \\ 0 \end{array}\right)\right\}$$

tj.

$$\max\{c^T x'; Ax' = -b, x' \leq 0\}$$

a tedy má optimální řešení i úloha ( $x := -x'$ )

$$\min\{c^T x; Ax = b, x \geq 0\}.$$



■

**Věta 13** Jsou-li obě úlohy (P), (D) přípustné, potom obě mají optimální řešení a mají stejnou optimální hodnotu.

**Důkaz** (P) je přípustná a podle Věty 10 je  $c^T x \geq b^T y_0 \forall$  příp. ř.  $x$ , tedy je omezená zdola, tedy podle Věty 7 má optimální řešení, proto podle Věty 12 i (D) má optimální řešení a mají stejnou optimální hodnotu. ■

**Věta 14** Vektory  $x, y$  jsou optimální řešení úloh (P), (D) právě když splňují soustavu

$$\begin{aligned} Ax &= b, \\ A^T y &\leq c, \\ c^T x &= b^T y, \\ x &\geq 0. \end{aligned}$$

**Důkaz** Jsou-li optimální řešení, potom splňují soustavu podle Věty 12. Naopak, platí-li to, potom jsou to přípustná řešení pro která  $c^T x = b^T y$  a podle Věty 10 jsou to optimální řešení. ■

**Věta 15** Jestliže (P) má v poslední tabulce optimální řešení  $x^B$  a platí  $x_B^B > 0$ , potom (D) má jediné optimální řešení  $y^* = (A_B^T)^{-1} c_B$ .

**Důkaz** Pro libovolné optimální řešení  $y$  platí  $c^T x^B = b^T y = x^{BT} A^T y \Rightarrow \underbrace{x^{BT}}_{>0} \underbrace{(c - A^T y)}_{\geq 0} = 0 \Rightarrow (c - A^T y)_B = c_B^T - y^T A_B = 0 \Rightarrow A_B^T y = c_B \Rightarrow y = (A_B^T)^{-1} c_B$ ; o tomto vektoru víme z Věty 11, že je optimální. ■

## 2.2 Úlohy s nerovnostmi

Uvažujme úlohy

$$\min\{c^T x; Ax \geq b, x \geq 0\} \quad (P')$$

$$\max\{b^T y; A^T y \leq c, y \geq 0\} \quad (D')$$

**Věta 16** *Slabá věta o dualitě (Věta 10) platí ve stejném znění i pro úlohy (P'), (D').*

**Důkaz**  $c^T x = x^T c \geq x^T A^T y = (Ax)^T y \geq b^T y$ ; podobně dál. ■

**Věta 17** *Věta o dualitě (Věta 12) platí ve stejném znění i pro úlohy (P'), (D').*

**Důkaz** (P') má optimální řešení

$$\Leftrightarrow \min \left\{ c^T x + 0^T x'; Ax - x' = b, x \geq 0, x' \geq 0 \right\} \quad \text{má optimální řešení}$$

$$\stackrel{V12}{\Leftrightarrow} \max \left\{ b^T y; \begin{pmatrix} A^T \\ -I \end{pmatrix} y \leq \begin{pmatrix} c \\ 0 \end{pmatrix} \right\} \quad \text{má optimální řešení}$$

$$\Leftrightarrow \max \left\{ b^T y; A^T y \leq c, y \geq 0 \right\} \quad \text{má optimální řešení, což je (D').}$$

■

**Věta 18** *(podmínky optimality lineárního programování). Přípustná řešení  $x, y$  úloh (P'), (D') jsou jejich optimální řešení, právě když*

$$\begin{aligned} x^T(c - A^T y) &= 0, \\ y^T(Ax - b) &= 0. \end{aligned}$$

**Důkaz**  $\Rightarrow$  Jsou-li optimální, potom  $c^T x = b^T y$  a podle slabé věty (Věta 16)  $c^T x = (Ax)^T y = b^T y$ , tedy  $x^T(c - A^T y) = 0 = y^T(Ax - b)$ .

$\Leftarrow$  Naopak, platí-li tyto podmínky, potom  $c^T x = x^T A^T y = y^T Ax = b^T y$ , a podle Věty 16 jsou to optimální řešení. ■

Co znamená ve složkách:

$$(\forall i) \quad x_i > 0 \Rightarrow (A^T y)_i = c_i$$

$$(\forall j) \quad y_j > 0 \Rightarrow (Ax)_j = b_j$$

## 2.3 Farkasova věta

**Věta 19** *(Farkasova věta, Farkasovo lemma) Soustava*

$$\begin{aligned} Ax &= b, \\ x &\geq 0 \end{aligned}$$

má řešení, právě když platí

$$(\forall y)(A^T y \geq 0 \Rightarrow b^T y \geq 0).$$

**Důkaz**  $\Rightarrow$  Necht'  $Ax = b$ ,  $x \geq 0$ ,  $A^T y \geq 0$ . Potom  $b^T y = y^T b = y^T Ax = (A^T y)^T x \geq 0$ .

$\Leftarrow$  Necht' to platí. Uvažujme úlohu

$$\min \{0^T x; Ax = b, x \geq 0\} \quad (P)$$

a k ní duální úlohu

$$\max \{b^T y; A^T y \leq 0\}. \quad (D)$$

(D) je přípustná, protože  $y = 0$  je přípustné. Dále, účelová funkce je omezená: je-li  $A^T y \leq 0$ , potom  $A^T(-y) \geq 0 \Rightarrow b^T(-y) \geq 0 \Rightarrow b^T y \leq 0$ , tedy (D) má optimální řešení, a podle věty o dualitě (Věta 12) má i (P) optimální řešení,  $Ax = b$ ,  $x \geq 0$ . ■

**Důsledek**  $Ax = b$ ,  $x \geq 0$  nemá přípustné řešení právě když existuje  $y_0$  tak, že  $A^T y_0 \geq 0$  &  $b^T y_0 < 0$ .

**Věta 20** Je-li úloha (P) přípustná, potom má optimální řešení právě když platí

$$(\forall x \geq 0)(Ax = 0 \Rightarrow c^T x \geq 0).$$

**Důkaz** (P) má optimální řešení  $\Leftrightarrow$  (D) je přípustná  $\Leftrightarrow A^T y \leq c$  má řešení  $\Leftrightarrow$

$$A^T(y_1 - y_2) + y_3 = c \text{ má nezáporné řešení} \Leftrightarrow (A^T, -A^T, I) \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = c, \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} \geq 0$$

$$\text{má řešení} \Leftrightarrow (\forall x) \left[ \begin{pmatrix} A \\ -A \\ I \end{pmatrix} x \geq 0 \Rightarrow c^T x \geq 0 \right] \Leftrightarrow (\forall x) [Ax = 0, x \geq 0 \Rightarrow c^T x \geq 0].$$

■

**Věta 21** Je-li (P) přípustná, potom je neomezená právě když  $(\exists x_0 \geq 0)(Ax_0 = 0 \text{ \& } c^T x_0 < 0)$ .

**Důkaz** Optimální  $\Leftrightarrow \dots$ , neomezená  $\Leftrightarrow (\dots) \Leftrightarrow (\exists x_0 \geq 0)(Ax_0 = 0 \text{ \& } c^T x_0 < 0)$ .

■

# Kapitola 3

## Aplikace lineárního programování

### 3.1 Teorie her

#### 3.1.1 Základní pojmy

**Pojmy:** čisté strategie, výplatní matice. Příklad: stříh, šachy. Smíšené str.:  $x \geq 0$ ,  $e^T x = 1$  podobně  $y$ . Nechť se hraje  $N$  her. Potom pravděpodobnost střetu  $i$ -té a  $j$ -té str. je  $x_i y_j$ , počet  $x_i y_j N$ , výplata  $\sum_{ij} a_{ij} x_i y_j N = (x^T A y) N$ , průměrný zisk  $x^T A y$ .

Optimální strategie (pakliže existují)

$$x^T A y^* \leq x^{*T} A y^* \leq x^{*T} A y \quad \forall \text{ smíšené strategie } x, y$$

Především ukážeme, že existují-li optimální smíšené strategie  $x^*$ ,  $y^*$ , potom číslo

$$\omega = x^{*T} A y^*$$

je na jejich volbě nezávislé a nazývá se cena hry. Nechť

$$x^T A \tilde{y} \leq \tilde{x}^T A \tilde{y} \leq \tilde{x}^T A y \quad \forall x, y \text{ smíšené}$$

Potom  $x^{*T} A \tilde{y} \leq \tilde{x}^T A \tilde{y} \leq \tilde{x}^T A y^* \leq x^{*T} A y^* \leq x^{*T} A \tilde{y} \Rightarrow$  všude rovnosti  $\Rightarrow$

$$\tilde{x}^T A \tilde{y} = x^{*T} A y^*.$$

### 3.1.2 Existence optimálních smíšených strategií

Označme  $e = (1, 1, \dots, 1)^T$ ,  $E = \begin{pmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & \dots & 1 \\ \vdots & & & \\ 1 & 1 & \dots & 1 \end{pmatrix}$ .

**Věta 22** Pro danou hru zadanou výplatní maticí  $A$ , necht'  $\alpha$  je libovolné číslo splňující  $\alpha > \max_{ij}(-a_{ij})$  a necht'  $\bar{A} = A + \alpha E$ . Potom dvojice duálních úloh lineárního programování

$$\min\{e^T x; \bar{A}^T x \geq e, x \geq 0\} \quad (P')$$

$$\max\{e^T y; \bar{A}y \leq e, y \geq 0\} \quad (D')$$

má optimální řešení. Necht'  $x_0, y_0$  jsou libovolná optimální řešení  $(P')$ ,  $(D')$ . Potom

$$x^* = \frac{x_0}{e^T x_0}, \quad y^* = \frac{y_0}{e^T y_0}$$

jsou optimální strategie obou hráčů,

$$\omega = x^{*T} A y^*$$

je cena hry a množiny optimálních strategií obou hráčů jsou dány vztahy

$$X_{\text{opt}} = \{x; A^T x \geq \omega e, e^T x = 1, x \geq 0\},$$

$$Y_{\text{opt}} = \{y; A y \leq \omega e, e^T y = 1, y \geq 0\}.$$

**Důkaz** Z  $\alpha > \max_{ij}(-a_{ij}) \geq -a_{ij}$  plyne  $a_{ij} + \alpha > 0 \forall ij$ , tedy  $\bar{A} = A + \alpha E > 0$ .

Úloha  $(D')$  je přípustná ( $y = 0$  je přípustné) a pro každé  $j$  platí  $\bar{a}_{ij} y_j \leq (\bar{A}y)_j \leq 1$ , tedy  $0 \leq y_j \leq \frac{1}{\bar{a}_{ij}} \Rightarrow$  množina přípustných řešení  $(D')$  je omezená  $\Rightarrow (D')$  má optimální řešení  $\Rightarrow (P')$  má optimální řešení.

Necht'  $x_0, y_0$  jsou optimální řešení  $(P')$ ,  $(D')$ . Potom podle věty o dualitě je  $e^T x_0 = e^T y_0$  a z  $\bar{A}^T x_0 \geq e$  plyne  $x_0 \neq 0$ , tedy  $e^T x_0 > 0$ , tudíž vektory  $x^* = \frac{x_0}{e^T x_0}$ ,  $y^* = \frac{y_0}{e^T y_0}$  jsou nezáporné a  $e^T x^* = \frac{e^T x_0}{e^T x_0} = 1 = e^T y^*$ , tedy jsou to smíšené strategie.

Necht'  $x, y$  jsou libovolné smíšené strategie. Potom z  $\bar{A}y_0 \leq e$  plyne  $x^T \bar{A}y_0 \leq e^T x = 1$ , tedy  $x^T \bar{A}y^* \leq \frac{1}{e^T y_0}$  a analogicky z  $\bar{A}^T x_0 \geq e$  plyne  $y^T \bar{A}^T x_0 \geq e^T y = 1$ , tj.  $x_0^T \bar{A}y \geq 1$ ,  $x^{*T} \bar{A}y = \frac{1}{e^T x_0}$ , celkem

$$x^T \bar{A} y^* \leq \frac{1}{e^T x_0} \leq x^{*T} \bar{A} y.$$

Avšak  $x^T \bar{A} y^* = x^T (A + \alpha E) y^* = x^T A y^* + \alpha$ , analogicky  $x^{*T} \bar{A} y = x^{*T} A y + \alpha$ , tedy  $x^T A y^* \leq x^{*T} A y \forall$  smíšené strategie  $x, y$  a dosazením  $y := y^*, x := x^*$  máme

$$x^T A y^* \leq x^{*T} A y^* \leq x^{*T} A y,$$

tedy podle definice jsou  $x^*, y^*$  optimální strategie obou hráčů.

Je-li  $\tilde{y}$  libovolná optimální strategie, potom z  $x^T A \tilde{y} \leq \omega$  plyne pro  $x = (0, \dots, 1, \dots, 0)$ , že  $(A \tilde{y})_i \leq \omega \forall i$ , tedy  $A \tilde{y} \leq \omega e$ , a ovšem  $e^T \tilde{y} = 1, \tilde{y} \geq 0$ , tedy  $\tilde{y} \in Y_{\text{opt}}$ . Naopak, nechť  $\tilde{y} \in Y_{\text{opt}}$ . Potom z  $A \tilde{y} \leq \omega e$  plyne pro každou smíšenou strategii  $x$ , že  $x^T A \tilde{y} \leq \omega(x^T e) = \omega$ , tedy

$$x^T A \tilde{y} \leq \omega \leq x^{*T} A y$$

a podle definice jsou  $\tilde{y}, x^*$  optimální smíšené strategie, tedy  $\tilde{y}$  je optimální smíšená strategie. Tím jsme dokázali, že  $Y_{\text{opt}}$  je množina všech optimálních smíšených strategií hráče 2, podobně  $X_{\text{opt}}$  pro hráče 1. ■

**Věta 23** (von Neumann). Každá konečná maticová hra má optimální smíšené strategie obou hráčů.

**Důkaz** Pro každou hru s maticí  $A$  lze najít  $\alpha > \max_{ij}(-a_{ij})$  a potom podle Věty 22 existují optimální smíšené strategie. ■

## 3.2 Dopravní problém

$$\min \left\{ \sum_{i=1}^m \sum_{j=1}^n c_{ij} x_{ij}; \sum_{j=1}^n x_{ij} = a_i (i = 1, \dots, m), \right. \\ \left. \sum_{i=1}^m x_{ij} = b_j (j = 1, \dots, n), x_{ij} \geq 0 \forall i, j \right\} \quad (\text{DP})$$

je to tedy problém rozvozu (např. uhlí) od zdrojů ke spotřebitelům. Zřejmě je to LP problém. Obecně lze spíše očekávat omezení tvaru  $\sum_j x_{ij} \leq a_i, \sum_i x_{ij} \geq b_j$ , ale lze doplnit na rovnosti zavedením fiktivních zdrojů resp. spotřebitelů.

### 3.2.1 Podmínky přípustnosti a optimality

**Věta 24** Platí:

- (i) (DP) je přípustný právě když  $\sum_i a_i = \sum_j b_j$ ,
- (ii) je-li (DP) přípustný, má optimální řešení,
- (iii) přípustné řešení  $x$  (DP) je jeho optimálním řešením, právě když existují  $p \in R^m, q \in R^n$  taková, že

$$\begin{aligned} p_i + q_j &\leq c_{ij} && \forall ij \\ x_{ij}(c_{ij} - p_i - q_j) &= 0 && \forall ij \end{aligned}$$

**Důkaz**

- (i) (DP) má řešení  $\Rightarrow \sum_i a_i = \sum_i \sum_j x_{ij} = \sum_j \sum_i x_{ij} = \sum_j b_j$ . Naopak, pro  $s = \sum_i a_i = \sum_j b_j$  definujeme  $x_{ij} = a_i b_j / s \forall ij$ , potom  $x \geq 0, \sum_j x_{ij} = (a_i/s) \sum_j b_j = a_i$ , podobně  $\sum_i x_{ij} = b_j$ , tedy  $x$  je přípustné.
- (ii) Je-li (DP) přípustný, potom  $\forall ij$  je  $0 \leq x_{ij} \leq \sum_j x_{ij} = a_i \leq s$ , tedy množina přípustných řešení je omezená a tudíž účelová funkce na ní nabývá minima.
- (iii) Matice soustavy má v  $ij$ -tém sloupci 1 v  $i$ -tém a  $(m+j)$ -tém řádku, jinde 0. Píšeme-li duální vektor ve tvaru  $y = \begin{pmatrix} p \\ q \end{pmatrix}$ , potom duální soustava je  $p_i + q_j \leq c_{ij}$  a podmínka optimality dává  $x_{ij}(c_{ij} - p_i - q_j) = 0$ .

■

### 3.2.2 Algoritmus

Označme  $\bar{c}_{ij} = c_{ij} - p_i - q_j$ . Myšlenka algoritmu: Dodržovat duální přípustnost  $\bar{c} \geq 0$  a podmínku optimality  $\bar{c}_{ij} x_{ij} = 0 \forall ij$ , rozvážet po povolených cestách ( $x_{ij} > 0 \Rightarrow \bar{c}_{ij} = 0$ ). Základní myšlenka: Jsou-li  $\bar{a}_i, \bar{b}_j$  množství, která zbývá vyvézt,  $\bar{a}_i > 0, \bar{b}_j > 0$ , konstruuj posloupnost  $i = i_1 j_1 i_2 j_2, \dots, i_k j_k = j$  takovou, že  $\bar{c}_{i_1 j_1} = 0, x_{i_1+1 j_1} > 0$ , potom po této cestě lze rozvést a  $\sum_i \bar{a}_i$  se sníží.

Tabulka pro řešení (DP):

	$\bar{b}_1$	$\bar{b}_2$	$\bar{b}_3$	$\dots$	$\bar{b}_n$
$\bar{a}_1$	$\bar{c}_{11}$	$\bar{c}_{12}$	$\bar{c}_{13}$	$\dots$	
$\bar{a}_2$	$\bar{c}_{21}$	$x_{22}$	$\dots$		
$\vdots$	$\vdots$				
$\bar{a}_m$					

$\bar{a}_i \dots$  dosud nerozvezené množství

$\bar{b}_j \dots$  dosud nedodané množství

Protože  $\bar{c}_{ij}x_{ij} = 0$ , píšeme  $x_{ij}$  pro vyzn.  $x$ ; bez rámečku je to  $\bar{c}_{ij}$ .

**Algoritmus** (duální algoritmus pro řešení (DP)).

0. Začni s tabulkou, kde  $\bar{a}_i = a_i$ ,  $\bar{b}_j = b_j$ ,  $\bar{c}_{ij} = c_{ij} - \min_k c_{ik}$ ,  $x_{ij} = 0 \forall ij$ .

1. Sestav  $I, J$  jako nejmenší množiny indexů s vlastnostmi

$$\begin{aligned} \bar{a}_i > 0 &\Rightarrow i \in I \\ i \in I, \bar{c}_{ij} = 0 &\Rightarrow j \in J \\ j \in J, x_{ij} > 0 &\Rightarrow i \in I. \end{aligned}$$

2. Je-li  $\bar{b}_j = 0 \forall j \in J$ , vypočti

$$\Delta = \min\{\bar{c}_{ij}; i \in I, j \notin J\},$$

polož

$$\begin{aligned} \bar{c}_{ij} &:= \bar{c}_{ij} - \Delta \quad \text{pro } i \in I, j \notin J \\ \bar{c}_{ij} &:= \bar{c}_{ij} + \Delta \quad \text{pro } i \notin I, j \in J \end{aligned}$$

a jdi na krok 1.

3. Jinak nalezni  $j \in J$  pro které  $\bar{b}_j > 0$  a sestav řetěz

$$i = i_1 j_1 i_2 j_2 \dots i_t j_t = j$$

takový, že  $\bar{a}_i > 0$ ,  $\bar{c}_{i_j l} = 0 \forall l$ ,  $x_{i_{l+1} j_l} > 0 \forall l$ . Vypočti  $\varepsilon = \min\{\bar{a}_i, \bar{b}_j, \min_l x_{i_{l+1} j_l}\}$

a polož  $\bar{a}_i := \bar{a}_i - \varepsilon$ ,  $\bar{b}_j := \bar{b}_j - \varepsilon$ ,  $x_{i_l j_l} := x_{i_l j_l} + \varepsilon$ ,  $x_{i_{l+1} j_l} := x_{i_{l+1} j_l} - \varepsilon \forall l$ .

4. Je-li  $\bar{a} = \bar{b} = 0$  stop! Optimální řešení. Jinak jdi na 1.

Dokážeme, že v každém kroku platí:

1.  $\bar{c}_{ij} = c_{ij} - p_i - q_j$  pro jisté  $p, q$ ,



2.  $\bar{c}_{ij} \geq 0 \forall ij,$
3.  $\bar{c}_{ij}x_{ij} = 0 \forall ij,$
4.  $\sum_j x_{ij} + \bar{a}_i = a_i, \sum_i x_{ij} + \bar{b}_j = b_j \forall ij,$
5.  $x \geq 0.$

ad 1): na začátku položíme  $p_i = \min_k c_{ik}, q_j = 0 \forall ij,$  potom má ten tvar. Jinak k úpravě dochází je v kroku 6. Nechť indukci  $\bar{c}_{ij} = c_{ij} - p_i - q_j.$  Položíme  $p'_i = p_i + \Delta$  pro  $i \in I, p'_i = p_i$  pro  $i \notin I, q'_j = q_j - \Delta$  pro  $j \in J, q'_j = q_j$  pro  $j \notin J,$  potom  $\bar{c}'_{ij} = c_{ij} - p'_i - q'_j.$

ad 2) Na začátku evidentně  $\bar{c} \geq 0.$  Při úpravě: je-li  $i \in I, j \notin J,$  je  $\Delta \leq \bar{c}_{ij},$  tedy  $\bar{c}'_{ij} = c_{ij} - \Delta \geq 0,$  je-li  $i \notin I, j \in J,$  potom  $\Delta \geq 0$  a tedy  $\bar{c}'_{ij} = \bar{c}_{ij} + \Delta \geq \bar{c}_{ij} \geq 0.$

ad 3) Indukci: při prvé konstrukci  $x_{ij}$  je zřejmé. Jinak, je-li v kroku 4  $x_{i_1j_1} := x_{i_1j_1} + \varepsilon,$  je v kroku 3  $\bar{c}_{i_1j_1} = 0;$  je-li  $x_{i_{l+1}j_l} := x_{i_{l+1}j_l} - \varepsilon,$  muselo být  $x_{i_{l+1}j_l} > 0$  a tedy indukci  $\bar{c}_{i_{l+1}j_l} = 0.$  V kroku 6:  $\bar{c} := \bar{c} - \Delta \Rightarrow \bar{c}_{ij} > 0 \Rightarrow x_{ij} = 0; \bar{c} := \bar{c} + \Delta \Rightarrow i \notin I, j \in J \Rightarrow x_{ij} = 0$  (jinak  $i \in I).$

ad 4) Zřejmé na začátku. Jinak v kroku 4  $\bar{a}_i := \bar{a}_i - \varepsilon, x_{i_1j_1} := x_{i_1j_1} + \varepsilon$  tedy  $\bar{a}'_i + \sum_j x'_{ij} = \bar{a}_i + \sum_j x_{ij} = a_i,$  podobně ostatní.

ad 5)  $x_{i_{l+1}j_l} := x_{i_{l+1}j_l} - \varepsilon \Rightarrow x_{i_{l+1}j_l} \geq \varepsilon \Rightarrow x'_{i_{l+1}j_l} \geq 0.$

**Věta 25** *Nechť počáteční data  $a_i, b_j, c_{ij}$  jsou celočíselná a necht' úloha je přípustná, tj.  $\sum a_i = \sum b_j.$  Potom algoritmus po konečném počtu kroků dává celočíselné optimální řešení úlohy (DP) a všechny průběžné tabulky jsou rovněž celočíselné.*

**Důkaz** Celočíslnost tabulek plyne z použití pouze operací  $+, -, \min.$  V bodu 4 algoritmu je  $\varepsilon \geq 1,$  tedy po aktualizaci  $\sum \bar{a}_i$  klesne aspoň o 1. Kroky 3, 4 se tedy nemohou provádět více než  $(\sum a_i)$ -krát. Dochází-li k návratu z 6 na 1, potom pro nové množiny  $I', J'$  konstruované v kroku 1 především  $\Delta > 0$  ( $i \in I, j \notin J \Rightarrow \bar{c}_{ij} > 0,$  jinak  $j \in J$ ). Dále, je-li  $i \in I, \bar{c}_{ij} = 0,$  potom i  $\bar{c}'_{ij} = 0$  ( $\bar{c}'_{ij} > 0 \Rightarrow i \notin I, j \in J,$  spor); je-li  $j \in J, x_{ij} > 0,$  je opět  $x_{ij} > 0,$  tedy  $i \in I.$  Jinými slovy,  $I \subseteq I', J \subseteq J'.$  Ale pro  $\Delta = \bar{c}_{i_0j_0}$  je  $i_0 \in I, j_0 \notin J, \bar{c}'_{i_0j_0} = \bar{c}_{i_0j_0} - \Delta = 0,$  tedy  $j_0 \in J';$  proto  $J \subseteq J', J \neq J'.$  Tedy po nejvýše  $n$  návratech od 6 k 1 musí projít a snížit  $\sum a_i,$  z toho plyne konečnost.

Tedy po konečně mnoha krocích dojde k řešení, kde  $\bar{c} \geq 0, \bar{c}_{ij}x_{ij} = 0 \forall ij,$   
 $\sum_j x_{ij} = a_i, \sum_i x_{ij} = b_j \Rightarrow$  optimální. ■

# Kapitola 4

## Problém lineární komplementarity

### 4.1 $P$ -matice

$A : n \times n$ ,  $I \subseteq \{1, \dots, n\}$ ,  $I = (i_1, \dots, i_m)$ ,  $i_1 < i_2 < \dots < i_m$ . Matice tvaru

$$A_I = \begin{pmatrix} a_{i_1 i_1} & a_{i_1 i_2} & \dots & a_{i_1 i_m} \\ a_{i_2 i_1} & a_{i_2 i_2} & \dots & a_{i_2 i_m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{i_m i_1} & a_{i_m i_2} & \dots & a_{i_m i_m} \end{pmatrix}$$

se nazývá hlavní submatice matice  $A$ ,  $\det A_I$  hlavní minor.

**Definice 1**  $A$  je  $P$ -matice, jestliže všechny její hlavní minory jsou kladné.

**Důsledek** Je-li  $A = (a_{ij})$   $P$ -matice, potom  $\det A > 0$ ,  $a_{ii} > 0 \forall i$ . Je-li  $A$   $P$ -matice, potom každá  $A_I$  je  $P$ -matice.

**Lemma 1** Jestliže  $A$  je  $P$ -matice a  $T$  je nezáporná diagonální matice, potom  $A + T$  je  $P$ -matice.

**Důkaz** Nejdříve nechť

$$T = \begin{pmatrix} 0 & & & 0 \\ & \ddots & & \\ & & t_{ii} & \\ & & & \ddots \\ 0 & & & & 0 \end{pmatrix},$$

potom pro  $i \notin I$  je  $\det(A + T)_I = \det A_I$ , pro  $i \in I$  je  $\det(A + T)_I = \det A_I + t_{ii} \det A_{I-\{i\}} \geq \det A_I > 0$ . Pro obecnou diagonální matici  $T$  indukci. ■

**Věta 26** (Fiedler, Pták 1962). *A je P-matice právě když pro každé  $x \neq 0$  existuje  $i$  tak, že  $x_i(Ax)_i > 0$ .*

**Důkaz**  $\Rightarrow$  Nechť  $A$  je  $P$ -matice a nechť existuje  $x \neq 0$  tak, že  $x_i(Ax)_i \leq 0 \forall i$ . Nechť  $I = \{i; x_i \neq 0\}$ ,  $x_I = (x_i)_{i \in I}$ ,  $y_I = ((Ax)_i)_{i \in I}$ , potom  $y_I = A_I x_I$  a  $y_i x_i \leq 0 \forall i \in I$ , tj. existuje diagonální  $T \geq 0$ , že  $y_I = -T x_I$  (tj.  $t_{ii} = -\frac{y_i}{x_i} = -\frac{y_i x_i}{x_i^2}$ ,  $i \in I$ ), tedy  $-T x_I = A_I x_I$ ,  $(A_I + T)x_I = 0 \Rightarrow \det(A_I + T) = 0$ , spor s lemmatem.

Naopak, nechť  $(\forall x \neq 0) (\exists i) x_i(Ax)_i > 0$ , a uvažujme libovolnou  $A_I$ . Nechť  $\lambda$  je libovolné reálné vlastní číslo  $A_I$ , tj.  $A_I x = \lambda x$ ,  $x \neq 0$ . Dodefinujme  $\tilde{x}_i = 0$  pro  $i \notin I$ ,  $\tilde{x}_i = x_i$  pro  $i \in I$ , potom  $\tilde{x}_i(A\tilde{x})_i > 0$  pro jisté  $i$ , tedy  $i \in I$ ,  $(A\tilde{x})_i = (A_I x)_i \Rightarrow x_i(A_I x)_i > 0 \Rightarrow 0 < x_i(A_I x)_i = \lambda x_i^2 \Rightarrow \lambda > 0$ . Všechna reálná vlastní čísla  $A_I$  kladná  $\Rightarrow$

$$\det A_I = \prod_i \lambda_i = \prod_{\lambda_i \in R} \lambda_i \cdot \prod_{\text{Im} \lambda_j > 0} (\lambda_j \bar{\lambda}_j) > 0$$

(neboť determinant matice je roven součinu jejích vlastních čísel). ■

**Věta 27** (Coxson 1994). *Problém ověření, zda daná matice  $A$  je P-matice, je NP-těžký.*

**Důkaz** vybočuje z rámce této přednášky a proto jej zde neuvádíme.

**Věta 28** *Symetrická matice  $A$  je P-matice právě tehdy, když je pozitivně definitní.*

**Důkaz**  $\Rightarrow$ :  $P$ -matice  $\Rightarrow$  vedoucí hlavní minory  $> 0 \Rightarrow$  pozitivně definitní podle Sylvesterova kritéria.

$\Leftarrow$ : pos. def.  $\Rightarrow \forall x \neq 0 \sum_i x_i(Mx)_i = x^T Mx > 0 \Rightarrow x_i(Mx)_i > 0$  pro jisté  $i$ . ■

## 4.2 Problém lineární komplementarity

$$\left. \begin{array}{l} y = Mz + q \\ y^T z = 0 \\ y \geq 0, z \geq 0 \end{array} \right\} \quad (\text{LCP})$$

kde  $M$  je čtvercová. S vyloučením  $y$  lze psát ekvivalentně

$$\begin{aligned}
Mz + q &\geq 0 \\
z^T(Mz + q) &= 0 \\
z &\geq 0
\end{aligned}$$

resp. jedinou rovnicí

$$x^+ = Mx^- + q$$

kde  $x^+ = (x_i^+)$ ,  $x^- = (x_i^-)$ ,  $\alpha^+ = \max\{\alpha, 0\}$ ,  $\alpha^- = \max\{-\alpha, 0\}$  (stačí  $x = y - z$ ). V základní formulaci je  $y^T z = 0$  ekvivalentní  $y_i z_i = 0 \forall i$ . Naším cílem bude dokázat, že (LCP) má právě jedno řešení pro každou pravou stranu  $q$  právě když  $M$  je  $P$ -matice. Uvedeme i konstruktivní metodu (konečný algoritmus) jak toto řešení najít. V průběhu důkazu použijeme dvě pomocná tvrzení.

### 4.3 Murtyho algoritmus

**Algoritmus** (Murty 1974, pro řešení (LCP) s  $P$ -maticí  $M$ )

0. Sestav tabulku  $B|\bar{A}|\bar{q}$ , kde  $\bar{A} = (I, -M)$ ,  $\bar{q} = q$ ,  $B = (1, \dots, n)$  (tj.  $y_1, \dots, y_n$  jsou v bázi).
1. Je-li  $\bar{q} \geq 0$ , ukonči:  $y, z$  je řešení (LCP).
2. Jinak urči

$$k = \min\{j; \bar{q}_j < 0\}.$$

3. Je-li  $z_k$  v bázi, zvol pivota  $\bar{a}_{kk}$ , jinak zvol pivota  $\bar{a}_{k,n+k}$  [tj. zaveď do báze proměnnou doplňkovou k té, která je v bázi].
4. Proveď eliminaci s tímto pivotem a jdi na 1.

Podstatné rysy jsou tyto:

- a) pro každé  $k$  je právě jedna z proměnných  $y_k, z_k$  v bázi,
- b) jí odpovídající sloupec jednotkové matice má 1 v řádku  $k$ , tj.  $\forall k$  je buď  $y_k = \bar{q}_k$  nebo  $z_k = \bar{q}_k$ .

To se snadno dokáže indukci. To zaručuje  $y^T z = 0$  &  $y = Mz + q$ , tedy ukončí se v okamžiku kdy  $y \geq 0$ ,  $z \geq 0$ .

### Příklad

$$M = \begin{pmatrix} 1 & 2 \\ 0 & 1 \end{pmatrix}, \quad q = \begin{pmatrix} -1 \\ -1 \end{pmatrix}$$

$$\begin{array}{c|ccc|cc} 1 & 1 & 0 & \boxed{-1} & -2 & -1 \\ 2 & 0 & 1 & 0 & -1 & -1 \end{array} \longrightarrow \begin{array}{c|cccc|c} 3 & -1 & 0 & 1 & 2 & 1 \\ 2 & 0 & 1 & 0 & \boxed{-1} & -1 \end{array} \longrightarrow$$

$$\begin{array}{c|ccc|cc} 3 & \boxed{-1} & 2 & 1 & 0 & -1 \\ 4 & 0 & -1 & 0 & 1 & 1 \end{array} \longrightarrow \begin{array}{c|cccc|c} 1 & 1 & -2 & -1 & 0 & 1 \\ 4 & 0 & -1 & 0 & 1 & 1 \end{array}$$

tj. řešení je  $y = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ,  $z = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ .

Na první pohled je nevýhodou algoritmu direktivní volba pivotu; není nijak patrné, že musí být nenulový. Je tomu tak však v případě, že  $M$  je  $P$ -matice [kdyby  $\bar{a}_{kk} > 0$ , potom  $\bar{q}_k := \frac{\bar{q}_k}{\bar{a}_{kk}} < 0$  a záporná složka se neodstraní].

**Věta 29** Jestliže  $M$  je  $P$ -matice, potom v každém kroku Murtyho algoritmu je pivot záporný [tj. algoritmus je proveditelný].

**Důkaz** Uvažujme běžný krok s bází  $B$ , tj.  $B_k \in \{k, n+k\} \forall k$  a nebázickou částí  $N$ ,  $N_k \in \{k, n+k\}$ ,  $B_k \neq N_k \forall k$ . Pivot se vybírá v  $k$ -tém řádku a  $k$ -tém sloupci nebázické části, tedy jako  $(A_B^{-1}A_N)_{kk}$ . Dokážeme, že  $-A_B^{-1}A_N$  je  $P$ -matice; tím je dáno, že diagonální prvky jsou kladné, tedy pivot  $= (A_B^{-1}A_N)_{kk} < 0$ .

Nechť  $y = -A_B^{-1}A_N z$ ,  $z \neq 0$ , tj.  $A_B y + A_N z = 0$ . Definujme  $x \in R^{2n}$  přepíšeme  $x_B = y$ ,  $x_N = z$ , potom  $A_B y + A_N z = (I, -M)x = x_1 - Mx_2 = 0$ . Kdyby  $x_2 = 0$ , potom  $x_1 = 0$ , tedy i  $y = z = 0$  spor. Proto  $x_2 \neq 0$  tedy existuje  $i$ , že  $(x_1)_i(x_2)_i > 0$ . Ale  $(x_1)_i = y_i$ ,  $(x_2)_i = z_i$  je-li  $B_i = i$ , a  $(x_1)_i = z_i$ ,  $(x_2)_i = y_i$  je-li  $B_i = n+i$ , v obou případech  $(x_1)_i(x_2)_i = y_i z_i > 0$ . Tedy  $-A_B^{-1}A_N$  je  $P$ -matice  $\Rightarrow$  pivot záporný. ■

**Lemma 2** Nechť  $M$  je  $P$ -matice a nechť  $(y^1, z^1) \neq (y^2, z^2)$  jsou řešení soustavy

$$\begin{aligned} y &= Mz + q \\ y_i z_i &= 0 \quad (i = 1, \dots, n) \end{aligned}$$

[bez požadavku nezápornosti!]. Potom existuje i tak, že platí

$$y_i^1 z_i^2 + y_i^2 z_i^1 < 0$$

[tj. buď  $y_i^1 z_i^2 < 0$ , nebo  $y_i^2 z_i^1 < 0$ ].

**Důkaz**  $y^1 = Mz^1 + q$ ,  $y^2 = Mz^2 + q$  implikují  $y^1 - y^2 = M(z^1 - z^2)$ . Protože  $z^1 \neq z^2$  (jinak  $(y^1, z^1) = (y^2, z^2)$ ), existuje podle věty 26 index  $i$  tak, že

$$0 < (y_i^1 - y_i^2)(z_i^1 - z_i^2) = y_i^1 z_i^1 - y_i^1 z_i^2 - y_i^2 z_i^1 + y_i^2 z_i^2 = -y_i^1 z_i^2 - y_i^2 z_i^1,$$

tedy  $y_i^1 z_i^2 + y_i^2 z_i^1 < 0$ . ■

**Lemma 3** *Nechť  $S$  je posloupnost s těmito vlastnostmi:*

- (i) každý prvek  $S$  patří do  $\{1, \dots, n\}$ ,
- (ii) mezi každými dvěma výskyty čísla  $k$  v  $S$  existuje výskyt čísla většího než  $k$ .

*Potom  $S$  je konečná a každý prvek  $k \in \{1, \dots, n\}$  se v posloupnosti vyskytne nejvýše  $2^{n-k}$ -krát.*

**Důkaz** Indukcí pro  $k = n, n-1, \dots, 1$ . Podle (ii) se  $k = n$  nemůže vyskytnout více než jednou. Nechť tvrzení je dokázáno pro  $n, \dots, k+1$ . Potom mezi každými dvěma výskyty  $k$  existuje výskyt čísla  $> k$ , tj. výskyt  $k-1 \leq$  součet výskytů čísel větších než  $k \leq 2^{n-(k+1)} + \dots + 2^0 = 2^{n-k-1} + \dots + 1 = 2^{n-k} - 1$ , tj. počet výskytů  $k$  je  $\leq 2^{n-k}$ . Tudíž celková délka posloupnosti  $\leq 2^{n-1} + \dots + 1 = 2^n - 1$ . ■

**Věta 30** *Nechť  $M$  je  $P$ -matice. Potom Murtyho algoritmus dává v konečném počtu kroků jediné řešení (LCP).*

**Důkaz** Podle lemmatu 3: nechť  $S$  je posloupnost čísel  $k$  z kroku 2 algoritmu. Vlastnost (i) je zřejmě splněna. Uvažujme dva nejbližší výskyty  $k$  v  $S$ , nechť odpovídají  $(y^1, z^1)$  a  $(y^2, z^2)$ . Potom pro každé  $i < k$  jsou všechna čísla  $y_i^1, z_i^1, y_i^2, z_i^2$  nezáporná, tj.

$$y_i^1 z_i^2 + y_i^2 z_i^1 \geq 0.$$

Dále dvě z čísel  $y_k^1, z_k^1, y_k^2, z_k^2$  jsou záporná a dvě nulová, tedy opět

$$y_k^1 z_k^2 + y_k^2 z_k^1 \geq 0.$$

Avšak  $(y^1, z^1) \neq (y^2, z^2)$  ( $k$ -tá bázická prom. je různá), tedy podle lemmatu 2 existuje  $i > k$  takové, že

$$y_i^1 z_i^2 + y_i^2 z_i^1 < 0,$$

tj. jedno z nich je  $< 0 \Rightarrow \neq 0 \Rightarrow i$  muselo mezitím být v  $S$ . Tedy podle lemma 3 je  $S$  konečná, každé  $k$  se může vyskytnout nejvýše  $2^{n-k}$ -krát. Tedy (LCP) má řešení.

Jednoznačnost: Nechť  $(y^1, z^1)$ ,  $(y^2, z^2)$  jsou různá řešení (LCP). Potom  $z_1 \neq z_2$  (jinak  $(y_1, z_1) = (y_2, z_2)$ ) a podle lemmatu 2 je buď  $y_i^1 z_i^2 < 0$  nebo  $y_i^2 z_i^1 < 0 \Rightarrow$  jedno z řešení není nezáporné  $\Rightarrow$  spor; tedy řešení jediné. ■

## 4.4 Existence a jednoznačnost řešení (LCP)

**Věta 31** (Samelson, Thrall a Wesler 1958, nezávisle Ingleton 1966, Murty 1972). *(LCP) má pro každou pravou stranu  $q$  právě jedno řešení právě tehdy, když  $M$  je  $P$ -matice.*

**Důkaz**  $\Leftarrow$ : Je-li  $M$   $P$ -matice, potom Murtyho algoritmus dává po konečně mnoha krocích řešení, o kterém je dokázáno, že je jediné.

$\Rightarrow$ : Nechť  $M$  není  $P$ -matice, tedy existuje  $x \neq 0$ , že  $x_i(Mx)_i \leq 0 \forall i$ . Položme  $y = Mx$ , tedy  $y_i x_i \leq 0 \forall i$ , a  $y^+ - y^- = M(x^+ - x^-)$ , tj.  $q := y^+ - Mx^+ = y^- - Mx^-$ . Ukážeme, že  $(y^+, x^+)$  i  $(y^-, x^-)$  jsou vzájemně různá řešení (LCP)  $y = Mx + q$ ,  $y \geq 0$ ,  $x \geq 0$ ,  $y^T x = 0$ . Jestliže  $y_i^+ x_i^+ \neq 0$ , potom  $> 0$ , tedy  $y_i^+ > 0$  a  $x_i^+ > 0$ , tedy  $y_i^- = x_i^- = 0$  a  $y_i x_i = y_i^+ x_i^+ > 0$  spor. Analogicky kdyby  $y_i^- x_i^- > 0$ , potom  $y_i^+ = x_i^+ = 0$ ,  $y_i x_i = (-y_i^-)(-x_i^-) > 0$  spor. Tudíž jsou obě řešení. Kdyby  $x^+ = x^-$ , potom  $\forall i x_i = 0$ , tedy  $x = 0$  spor, neboť  $x \neq 0$ . Tedy  $x^+ \neq x^-$ , tedy obě řešení jsou různá. Není-li  $M$   $P$ -matice, existuje tedy (LCP), který má aspoň dvě různá řešení. ■

Třída  $P$ -matic, pro které Murtyho algoritmus funguje, je příliš úzká, zformulujeme proto jiný algoritmus, který je obecnější, ale může selhat. Popíšeme nejprve tzv. lexikografické pravidlo.

## 4.5 Lexikografické pravidlo

Lexikografické uspořádání vektorů:  $x < y \Leftrightarrow$  existuje  $k \in \{1, \dots, n\}$  tak, že  $x_i = y_i \forall i < k$  &  $x_k < y_k$  (na principu uspořádání slov ve slovníku).

Zřejmě:  $x \neq y \Rightarrow x < y$  nebo  $y < x$ ;  $0 < x$  &  $0 < y \Rightarrow 0 < x + y$ ; mezi konečně mnoha ex. nejmenší, označme ho lexmin;  $y < x$ ,  $\alpha > 0 \Rightarrow \alpha y < \alpha x$ .

Lexikografické pravidlo u algoritmu simplexového typu: v běžném kroku, označme

$\beta_i$   $i$ -tý řádek matice  $\begin{array}{c|c} \bar{b} & A_B^{-1} \\ \hline & \gamma \end{array}$

Pravidlo:

$$\frac{1}{\bar{a}_{rs}}\beta_r = \text{lexmin} \left\{ \frac{1}{\bar{a}_{js}}\beta_j; \bar{a}_{js} > 0 \right\}.$$

**Tvrzení** V každém kroku algoritmu:

- (a) výběr  $r$  je jednoznačný
- (b)  $\beta_j > 0 \forall j$
- (c) jestliže  $s$  vstoupí a  $p$  vystoupí, potom zavedeme-li v dalším kroku  $p$  do báze, potom  $s$  opět vystoupí z báze.
- (d) v simplexovém algoritmu řádek  $\gamma$  lexikograficky roste, z toho vyplývá konečnost.

### Důkaz

- (a) nechť není, tj.  $\frac{1}{\bar{a}_{rs}}\beta_r = \frac{1}{\bar{a}_{js}}\beta_j \Rightarrow \beta_r, \beta_j$  lineárně závislé  $\Rightarrow r$ -tý a  $j$ -tý řádek  $A_B^{-1}$  lineárně závislé - není možné
- (b) na začátku jde o matici  $\begin{array}{c|c} \bar{b} & I \end{array}$  a v každém řádku je první nenulový prvek kladný  $\Rightarrow \beta_j > 0 \forall j$

$$\begin{array}{ccc|ccc} \dots & \bar{a}_{js} & \dots & \beta_j & \dots & 0 & \dots & \beta_j - \frac{\bar{a}_{js}}{\bar{a}_{rs}}\beta_r \\ & \vdots & & \vdots & \longrightarrow & \vdots & & \vdots \\ \dots & \bar{a}_{rs} & \dots & \beta_r & \dots & 1 & \dots & \frac{1}{\bar{a}_{rs}}\beta_r \end{array}$$

Jelikož  $\frac{1}{\bar{a}_{rs}}\beta_r < \frac{1}{\bar{a}_{js}}\beta_j$ , je buď  $\bar{a}_{js} \leq 0$ , potom  $\beta_j - \frac{\bar{a}_{js}}{\bar{a}_{rs}}\beta_r > 0$ , nebo  $\bar{a}_{js} > 0$ , potom  $\frac{1}{\bar{a}_{rs}}\beta_r < \frac{1}{\bar{a}_{js}}\beta_j$  implikuje  $\beta_j - \frac{\bar{a}_{js}}{\bar{a}_{rs}}\beta_r > 0$ .



(c)  $B_r = p$

$$\begin{array}{cccc|c} 0 & \dots & \bar{a}_{js} & \dots & \beta_j \\ \vdots & & \vdots & & \vdots \\ 1 & \dots & \bar{a}_{rs} & \dots & \beta_r \end{array} \longrightarrow \begin{array}{cccc|c} -\frac{\bar{a}_{js}}{\bar{a}_{rs}} & \dots & 0 & \dots & \beta_j - \frac{\bar{a}_{js}}{\bar{a}_{rs}}\beta_r \\ \vdots & & \vdots & & \vdots \\ \frac{1}{\bar{a}_{rs}} & \dots & 1 & \dots & \frac{1}{\bar{a}_{rs}}\beta_r \end{array}$$

Chceme-li zavést zpět proměnnou, která vystoupila z báze, lex. pravidlo dává

$$\text{lexmin} \left\{ \beta_r, \text{lexmin} \left\{ \beta_r - \frac{\bar{a}_{rs}}{\bar{a}_{js}}; \bar{a}_{js} < 0 \right\} \right\} = \beta_r,$$

tedy pivot je opět v řádku  $r$  a tabulka se vrátí do původního stavu.

(d) Na počátku  $\begin{array}{|c|c|} \hline b & I \\ \hline 0 & 0 \\ \hline \end{array} := \gamma$

$$y^T A_B = c_B^T \Rightarrow A_B^T y = c_B \Rightarrow y = (A_B^T)^{-1} c_B$$

tj.

$$\gamma = (-b^T y, -y) = (-b^T (A_B^T)^{-1} c_B, -(A_B^T)^{-1} c_B)$$

$$\begin{array}{|c|c|c|} \hline & & \\ \hline \bar{a}_{rs} & & \beta_r \\ \hline & & \\ \hline \bar{c}_s & & \gamma \\ \hline \end{array}$$

Pro řádek v dalším kroku platí

$$\begin{aligned} \gamma : &= \gamma - \frac{\bar{c}_s}{\bar{a}_{rs}} \beta_r \\ &= \gamma + \left( \frac{-\bar{c}_s}{\bar{a}_{rs}} \right) \beta_r > \gamma, \end{aligned}$$

tedy  $\gamma$  v každém kroku lexikograficky roste a proto se simplexový algoritmus nemůže vrátit do stejné báze, proto je konečný. ■

## 4.6 Lemkeho algoritmus

řeší modifikovaný (LCP)

$$y = Mz + z_0 e + q \quad (4.1)$$

$$y^T z = 0 \quad (4.2)$$

$$y \geq 0, z_0 \geq 0, z \geq 0 \quad (4.3)$$

a směřuje k  $z_0 = 0$  (potom řešení (LCP)). Jde po tzv. téměř komplementárních bázích: bázičké řešení  $(y, z, z_0)$  se nazývá téměř komplementární, jestliže existuje  $k \in \{1, \dots, n\}$  tak, že

- (i)  $\forall j \neq k$  je právě jedna z proměnných  $y_j, z_j$  v bázi,
- (ii)  $y_k$  ani  $z_k$  nejsou v bázi,
- (iii)  $z_0$  je v bázi.

**Algoritmus** (Lemke 1965) [Udržuje (4.2), (4.3), směřuje k (4.1)]

0. Sestav počáteční tabulku  $B|\bar{A}|\bar{b}$ , kde  $B = \{1, \dots, n\}$ ,  $\bar{A} = (I, -M, -e)$ ,  $\bar{b} = q$ . Je-li  $\bar{b} \geq 0$ , stop:  $y = q, z = 0$  je řešení (LCP).
1. Nalezni  $t$ , pro které  $\bar{b}_t = \min_j \bar{b}_j$ , a zaveď  $z_0$  do báze s pivotem v řádku  $t$  [potom  $\bar{b} \geq 0$  a  $z_0$  je v bázi].
2. Nechť  $\bar{A}_s$  je sloupec proměnné doplňkové k té, která právě vystoupila z báze. Je-li  $\bar{A}_s \leq 0$ , stop! "Ray termination" (algoritmus selhává).
3. Jinak urči  $r$  pomocí lexikografického pravidla.
4. Proveď eliminaci s pivotem  $\bar{a}_{rs}$  a polož  $B_r = s$ .
5. Je-li  $z_0 = 0$ , stop! Řešení (LCP). Jinak jdi na krok 2.

Vysvětlení ke kroku 1.

$y_t$	$z_0$			$y_t$	$z_0$	
$\vdots$	$\vdots$	$\vdots$		$\vdots$	$\vdots$	
0	...	-1	$\bar{b}_t$	-1	...	1
$\vdots$	$\vdots$	$\vdots$	$\longrightarrow$	$\vdots$	$\vdots$	$-\bar{b}_t > 0$ (neboť $\bar{b} \not\geq 0, \bar{b}_t = \min_j \bar{b}_j$ )
1		-1	$\bar{b}_j$	-1	0	$\bar{b}_j - b_t \geq 0$ (neboť $\bar{b}_t = \min_j \bar{b}_j$ )
$\vdots$	$\vdots$	$\vdots$		$\vdots$	$\vdots$	$\vdots$

Algoritmus udržuje téměř komplementární řešení. Po provedení 1. kroku jsou  $y_j$ ,  $j \neq t$ , v bázi, a  $z_0$  je v bázi, tedy téměř komplementární řešení, přičemž  $y_t$  vystoupila z báze. Indukcí: je-li to tak, jestliže např.  $y_s$  vystoupí z báze, a  $z_s$  vstupuje, potom nějaká jiná vystupuje a tím vzniká nebázická dvojice  $y_j, z_j$ .

**Věta 32** *Lemkeho algoritmus s použitím lexikografického pravidla je konečný [tj. po konečně mnoha krocích buď dává řešení (LCP), nebo konstatuje "ray termination" a selhává, ačkoliv (LCP) může mít řešení].*

**Důkaz** Předpokládejme, že algoritmus se zacyklí, tj. konstruuje nekonečnou posloupnost téměř komplementárních bází  $B^0, B^1, \dots$ . Definujme

$$p = \min\{j; B^j = B^l \text{ pro jisté } l > j\}.$$

- a) Nechť  $p > 0$ ,  $B^p = B^q$  pro jisté  $q > p$ . Nechť  $y_k, z_k$  není v této bázi. Tzn. že jedna z nich, např.  $y_k$ , vystoupila při přechodu od  $B^{p-1}$  k  $B^p$ . Analogicky pro  $q$ : buď  $y_k$  vystoupila, potom  $B^{p-1} = B^{q-1}$ , nebo vystoupila  $z_k$ , potom  $y_k$  vstupuje a je  $B^{p-1} = B^{q+1}$ , v obou případech spor s definicí  $p$ .
- b) Nechť  $p = 0$ , tj.  $B^0 = B^q$  pro jisté  $q > 0$ . Potom  $y_t, z_t$  nejsou v  $B^q$ , tedy  $B^q$  vzniklo z  $B^{q-1}$  vystoupením jedné z nich z báze. Kdyby  $y_t$  vystoupila z báze, musel by sloupec proměnné  $y_t$  obsahovat kladný prvek. Kdyby  $z_t$  vystoupila z báze, muselo by v dalším kroku  $y_t$  vstoupit do báze, ale to by znamenalo "ray termination", ke kterému nedošlo - v obou případech spor.

$$B^0: \begin{array}{|c|} \hline y_t & z_0 \\ \hline -1 & 0 \\ -1 & 0 \\ \vdots & \vdots \\ -1 & 1 \\ \vdots & \vdots \\ -1 & 0 \\ \hline \end{array}$$

■

**Věta 33** *Nechť  $M$  má tyto dvě vlastnosti [tzv. kópozitivní plus]:*

- (i)  $x^T Mx \geq 0$  pro každé  $x \geq 0$ ,
- (ii) jestliže  $x^T Mx = 0$  pro jisté  $x \geq 0$ , potom  $(M + M^T)x = 0$ .

Potom platí: jestliže soustava

$$\begin{aligned} y &= Mz + q & (*) \\ y &\geq 0, z \geq 0 \end{aligned}$$

má řešení, potom i (LCP) má řešení, které se nalezne Lemkeho algoritmem v konečném počtu kroků [tj. nenastane "ray termination"].

**Důkaz** Předpokládejme, že nastane "ray termination". Ukážeme, že potom existuje  $z' \geq 0$ , že  $M^T z' \leq 0$  a  $q^T z' < 0$ , takže podle Farkasovy věty (\*) nemá řešení.

Nechť tedy v jistém kroku při řešení  $y, z, z_0$  nastane "ray termination", tj.  $\bar{A}_s \leq 0$ . Nechť  $y_k, z_k$  není v bázi. Definujme vektor  $\tilde{x} = \begin{pmatrix} y' \\ z' \\ z'_0 \end{pmatrix}$  prepisem  $\tilde{x}_B = -\bar{A}_s, \tilde{x}_s = 1, \tilde{x}_j = 0$  jinde, takže  $y' = Mz' + z'_0 e$ . Jelikož  $s$ -tá proměnná nebyla v bázi ani její komplement, neporuší se jejím zavedením komplementarita; tedy  $y'^T z' = 0$  a rovněž  $y'^T z = y'^T z' = 0$ .

1. Dokážeme, že  $z' \neq 0$ : předpokládejme  $z' = 0$ , takže  $y' = z'_0 e$ . Kdyby  $z'_0 = 0$ , potom i  $y' = 0$ , ale  $\tilde{x}_s = 1$ . Tedy  $z'_0 > 0, y' > 0$ . Tedy  $n + 1$  kladných, v bázi  $n$  a jedna přidaná - tedy v bázi byly proměnné  $y_j, j \neq s, z_0$ . Tzn. že předtím vystoupila  $z_s$ . Tedy předchozí bázi dostaneme zavedením  $z_s$  do báze. Ale v momentální bázi je  $y = z_0 e + q, y_s = 0 \Rightarrow q_s = -z_0$  a  $q_j = -z_0 + y_j > -z_0 = q_s \forall j \neq s \Rightarrow q_s = \min_j q_j$ , jediné  $\Rightarrow s = t \Rightarrow$  počáteční tabulka  $\Rightarrow$  po zavedení  $z_s$  druhá tabulka  $\Rightarrow$  zacyklení - spor. Tedy  $z' \neq 0$ .
2.  $y' = Mz' + z'_0 e \Rightarrow 0 = z'^T y' = z'^T Mz' + z'_0 (e^T z') \Rightarrow z'^T Mz' = 0, z'_0 = 0 \Rightarrow (M + M^T)z' = 0 \Rightarrow y' = Mz' \geq 0, M^T z' = -Mz' \leq 0$ .
3. Z  $y = Mz + z_0 e + q$  nyní plyne  $0 = z'^T y = z'^T Mz + z_0 (e^T z') + q^T z' = z'^T M^T z' + z_0 (e^T z') + q^T z' = -z'^T y' + z_0 (e^T z') + q^T z' = z_0 (e^T z') + q^T z'$ , tedy  $q^T z' = -z_0 (e^T z') < 0$ .

Tedy  $z' \geq 0, M^T z' \leq 0, q^T z' < 0$  - spor s existencí řešení soustavy (\*). ■

Podrobnější důkaz bodu 1.:

Je-li  $z' = 0$ , potom sloupec  $s$  nebyl v bázi  $\Rightarrow$  nemohl to být sloupec  $z_0. y' = z'_0 e$  a tudíž  $z'_0 > 0$  (jinak  $y' = z' = z'_0 = 0$ ). Tedy  $y' = z'_0 e$ . Tzn. že  $\tilde{x}_s = y'_s$  a  $y'_j, j \neq s, z'_0$  jsou v bázi. Tedy v původní bázi  $y_j, j \neq s, z_0$ . Tedy  $y = z_0 e + q, z$  toho  $q_s = -z_0, q_j = -z_0 + z_j > -z_0 = q_s \Rightarrow q_s = \min_j q_j \Rightarrow s = t$ , takže to je původní

báze.  $y_s$  vstupuje  $\Rightarrow z_s$  vystupuje, tedy zavedením  $z_s$  dostaneme předchozí bázi, ale ta je shodná s tou která následuje po první - ale po ní vystoupilo jisté  $y_j$  nebo  $z_j$ ,  $j \neq s$ , kdežto tady  $z_s$  - tedy jsou obě různé a z toho plyne opakování báze. [Nebo: výstup. pr. jednoznačná, ale tady obě různé - spor.]

Pozitivně definitní matice:  $x^T Ax > 0, \forall x \neq 0$ , semidefinitní:  $x^T Ax \geq 0, \forall x$ .

**Lemma 4** *Nechť  $A$  je pozitivně semidefinitní a nechť  $x^T Ax = 0$  pro jisté  $x$ . Potom  $(A + A^T)x = 0$ .*

**Důkaz** Nejdříve nechť  $A$  je symetrická.  $\forall \lambda \in \mathbb{R}^1$  je

$$\begin{aligned} 0 &\leq (\lambda x + Ax)^T A(\lambda x + Ax) = \lambda^2 x^T Ax + \lambda x^T A^T Ax + \lambda (Ax)^T Ax + (Ax)^T A(Ax) = \\ &= 2\lambda \|Ax\|_2^2 + (Ax)^T A(Ax) \Rightarrow Ax = 0 \Rightarrow (A + A^T)x = 0. \end{aligned}$$

Není-li  $A$  symetrická, potom  $\frac{1}{2}(A + A^T)$  je symetrická a  $x^T \left(\frac{1}{2}(A + A^T)\right) x = x^T Ax \geq 0$ , tedy jestliže  $x^T Ax = 0$ , je i  $x^T \left(\frac{1}{2}(A + A^T)x\right) = 0 \Rightarrow (A + A^T)x = 0$ . ■

**Důsledek** Pozitivně semidefinitní matice je kopozitivní plus.

**Důkaz**  $x^T Mx \geq 0 \forall x$ , tedy i  $\forall x \geq 0$   
 $x^T Mx = 0, x \geq 0 \Rightarrow x^T Mx = 0 \Rightarrow (M + M^T)x = 0$ . ■

# Kapitola 5

## Kvadratické programování

Míníme tím úlohu

$$\min \left\{ \frac{1}{2} x^T D x + c^T x; A x \geq b, x \geq 0 \right\} \quad (\text{QP})$$

(pro  $D = 0$  je to (LP)). Jelikož  $x^T D x = x^T \left( \frac{1}{2} (D + D^T) \right) x$ , lze  $D$  předpokládat symetrickou. Navíc budeme předpokládat, že  $D$  je pozitivně semidefinitní (tj. účelová funkce je konvexní). Nechť  $Q(x) = \frac{1}{2} x^T D x + c^T x$ .  $\forall x, x^*$  platí

$$Q(x) = Q(x^*) + (D x^* + c)^T (x - x^*) + \frac{1}{2} (x - x^*)^T D (x - x^*)$$

(Taylorova věta). Skutečně, pro pravou stranu máme

$$\begin{aligned} & \frac{1}{2} x^{*T} D x^* + c^T x^* + x^T D x^* - x^{*T} D x^* + c^T x - c^T x^* + \frac{1}{2} x^T D x - \frac{1}{2} x^T D x^* \\ & - \frac{1}{2} x^{*T} D x + \frac{1}{2} x^{*T} D x^* = Q(x). \end{aligned}$$

### 5.1 Převedení na LCP

**Věta 34** *Nechť  $D$  je symetrická pozitivně semidefinitní. Potom  $x^*$  je optimální řešení (QP), právě když je optimálním řešením úlohy lineárního programování*

$$\min \left\{ (D x^* + c)^T x; A x \geq b, x \geq 0 \right\}. \quad (\text{LP})$$

**Důkaz** Nechť  $x^*$  je optimální řešení (QP). Potom pro libovolné přípustné řešení  $x$  (QP) a libovolné  $\lambda \in [0, 1]$  z konvexity množiny přípustných řešení plyne

$$\begin{aligned}
Q(x^*) &\leq Q(x^* + \lambda(x - x^*)) = Q(x^*) + (Dx^* + c)^T \lambda(x - x^*) + \frac{1}{2} \lambda^2 (x - x^*)^T D (x - x^*) \\
&\Rightarrow (Dx^* + c)^T (x - x^*) + \frac{1}{2} \lambda (x - x^*)^T D (x - x^*) \geq 0 \quad \forall \lambda \in (0, 1] \\
&\Rightarrow (Dx^* + c)^T (x - x^*) \geq 0 \Rightarrow (Dx^* + c)^T x^* \leq (Dx^* + c)^T x
\end{aligned}$$

kde  $x$  je libovolné přípustné řešení (LP)  $\Rightarrow x^*$  optimální řešení (LP). Naopak, nechť  $x^*$  je optimální řešení (LP). Potom pro libovolné přípustné řešení (QP) je

$$Q(x) = Q(x^*) + (Dx^* + c)^T (x - x^*) + \frac{1}{2} (x - x^*)^T D (x - x^*) \geq Q(x^*),$$

tedy  $x^*$  je optimální řešení (QP). ■

**Věta 35** *Nechť  $D$  je symetrická pozitivně semidefinitní. Potom  $x^*$  je optimálním řešením (QP) právě když existuje  $p^*$  tak, že  $z = \begin{pmatrix} x^* \\ p^* \end{pmatrix}$  je řešením problému lineární komplementarity*

$$\begin{aligned}
y &= Mz + q \\
y &\geq 0, z \geq 0 \\
y^T z &= 0
\end{aligned} \tag{LCP}_{QP}$$

kde

$$M = \begin{pmatrix} D & -A^T \\ A & 0 \end{pmatrix}, \quad q = \begin{pmatrix} c \\ -b \end{pmatrix}$$

**Důkaz 1)** Nechť  $x^*$  je optimální řešení (QP), potom je i optimální řešení

$$\min \{ (Dx^* + c)^T x; Ax \geq b, x \geq 0 \}$$

a tedy existuje optimální řešení duální úlohy (ozn.  $p^*$ )

$$\max \{ b^T p; A^T p \leq Dx^* + c, p \geq 0 \},$$

tedy platí  $Ax^* \geq b$ ,  $x^* \geq 0$ ,  $Dx^* + c - A^T p^* \geq 0$ ,  $p^* \geq 0$ ,

$$p^{*T} (Ax^* - b) = 0,$$

$$x^{*T}(Dx^* + c - A^T p^*) = 0.$$

Označíme-li

$$z = \begin{pmatrix} x^* \\ p^* \end{pmatrix}, \quad y = \begin{pmatrix} Dx^* - A^T p^* + c \\ Ax^* - b \end{pmatrix},$$

je  $y \geq 0$ ,  $z \geq 0$ ,  $y^T z = 0$  a

$$y = \begin{pmatrix} D & -A^T \\ A & 0 \end{pmatrix} z + \begin{pmatrix} c \\ -b \end{pmatrix}$$

tj.  $x^*$ ,  $p^*$  splňují  $(LCP_{QP})$ . Naopak, je-li to tak, je

$$Dx^* - A^T p^* + c \geq 0, \quad Ax^* - b \geq 0, \quad x^* \geq 0, \quad p^* \geq 0,$$

$$x^{*T}(Dx^* - A^T p^* + c) = 0 = p^{*T}(Ax^* - b),$$

což jsou podmínky optimality pro (LP) a úlohu k ní duální. Tedy  $x^*$  řeší (LP) a podle předchozí věty i (QP). ■

## 5.2 Algoritmus

Matice  $M = \begin{pmatrix} D & -A^T \\ A & 0 \end{pmatrix}$  splňuje

$$\begin{pmatrix} x \\ p \end{pmatrix}^T \begin{pmatrix} D & -A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} x \\ p \end{pmatrix} = \begin{pmatrix} x \\ p \end{pmatrix}^T \begin{pmatrix} Dx - A^T p \\ Ax \end{pmatrix} = x^T Dx \geq 0$$

je tedy pozitivně semidefinitní a podle důsledku lemmatu 4 je kopolitivní plus.

**Věta 36** *Nechť  $D$  je symetrická pozitivně semidefinitní. Potom:*

1. *Má-li (QP) optimální řešení, potom se nalezne Lemkeho algoritmem aplikovaným na úlohu  $(LCP_{QP})$  [tj. nenastane "ray termination"].*
2. *Nastane-li při řešení  $(LCP_{QP})$  "ray termination", potom buď (QP) nemá přípustné řešení, nebo je účelová funkce na množině přípustných řešení (QP) neomezená.*



**Poznámka** Přípustnost lze testovat fází I simplexového algoritmu. Tedy existují 3 možnosti ukončení jako u lineárního programování.

**Důkaz** Protože  $\begin{pmatrix} D & -A^T \\ A & 0 \end{pmatrix}$  je kopozitivní plus, má-li (QP) optimální řešení, potom i  $(\text{LCP}_{\text{QP}})$  má řešení, tedy se nalezne Lemkeho algoritmem.

Nechť tedy skončí v "ray termination" a předpokládejme, že (QP) je přípustný. Dokážeme, že (QP) je v tom případě neomezený. Jelikož končí v "ray termination", nemá podle věty o Lemkeho algoritmu soustava

$$y = \begin{pmatrix} D & -A^T \\ A & 0 \end{pmatrix} z + \begin{pmatrix} c \\ -b \end{pmatrix}, \quad \begin{pmatrix} y \\ z \end{pmatrix} \geq 0,$$

tj. soustava

$$\begin{pmatrix} I & 0 & -D & A^T \\ 0 & I & -A & 0 \end{pmatrix} \begin{pmatrix} y \\ z \end{pmatrix} = \begin{pmatrix} c \\ -b \end{pmatrix}, \quad \begin{pmatrix} y \\ z \end{pmatrix} \geq 0$$

řešení. To podle Farkasovy věty znamená, že existují  $d_1, d_2$ , že

$$d_1 \geq 0, \quad d_2 \geq 0, \quad -Dd_1 - A^T d_2 \geq 0, \quad Ad_1 \geq 0, \quad c^T d_1 - b^T d_2 < 0,$$

tj.

$$Dd_1 + A^T d_2 \leq 0, \quad Ad_1 \geq 0, \quad c^T d_1 - b^T d_2 < 0, \quad d_1 \geq 0, \quad d_2 \geq 0.$$

Dokážeme, že

$$Dd_1 = 0, \quad c^T d_1 < 0.$$

Především

$$0 \geq d_1^T (Dd_1 + A^T d_2) = \underbrace{d_1^T Dd_1}_{\geq 0} + \underbrace{(Ad_1)^T}_{\geq 0} \underbrace{d_2}_{\geq 0} \geq 0$$

$\Rightarrow d_1^T Dd_1 = 0 \Rightarrow Dd_1 = 0 \Rightarrow A^T d_2 \leq 0$ . Dále z přípustnosti  $Ax \geq b, x \geq 0$ , plyne opět podle Farkasovy věty,  $(\forall y)(A^T y \geq 0, y \leq 0 \Rightarrow b^T y \geq 0)$ , tj.  $(\forall y)(A^T y \leq 0, y \geq 0 \Rightarrow b^T y \leq 0)$ . Protože  $A^T d_2 \leq 0, d_2 \geq 0$ , je  $b^T d_2 \leq 0$ , tedy z  $c^T d_1 - b^T d_2 < 0$  plyne  $c^T d_1 < b^T d_2 \leq 0 \Rightarrow c^T d_1 < 0$ .

Nyní, z přípustnosti plyne, že  $Ax \geq b$ ,  $x \geq 0$  má řešení  $x_0 \geq 0$ . Potom  $A(x_0 + \lambda d_1) = Ax_0 + \lambda Ad_1 \geq Ax_0 \geq b$ ,  $x_0 + \lambda d_1 \geq 0$ , tedy  $x_0 + \lambda d_1$  je přípustné  $\forall \lambda \geq 0$  a

$$\begin{aligned} Q(x_0 + \lambda d_1) &= Q(x_0) + (Dx_0 + c)^T \lambda d_1 + \frac{1}{2} \lambda^2 d_1^T D d_1 = \\ &= Q(x_0) + \lambda c^T d_1 \xrightarrow{\lambda \rightarrow \infty} -\infty, \end{aligned}$$

tedy  $Q$  je na  $\{x_0 + \lambda d_1; \lambda \geq 0\}$  neomezená zdola. ■

Jsou tedy možná 3 různá ukončení.

### Algoritmus

1. Sestav  $(LCP_{QP})$  a řeš Lemkeho algoritmem.
2. Algoritmus dává řešení  $z^* = \begin{pmatrix} x^* \\ p^* \end{pmatrix}$  - stop:  $x^*$  je optimální řešení.
3. Skončí-li v "ray termination", ověř neprázdnost množiny přípustných řešení  $X$  fází I simplexového algoritmu.
4.  $X \neq \emptyset$  - stop: (QP) neomezená.
5.  $X = \emptyset$  - stop: úloha nepřípustná.

# Kapitola 6

## Konvexní množiny a funkce

### 6.1 Konvexní množiny

Úvod: značení vektorů (sloupcové),  $x^T y$ ,  $(AB)^T = B^T A^T$ .

Normy: 1)  $\|x\| \geq 0$  &  $\|x\| = 0 \Leftrightarrow x = 0$ , 2)  $\|x + y\| \leq \|x\| + \|y\|$ , 3)  $\|\lambda x\| = |\lambda| \cdot \|x\|$ .

Příklady:  $\|x\|_1 = \sum_i x_i$ ,  $\|x\|_2 = \sqrt{x^T x}$ ,  $\|x\|_\infty = \max_i |x_i|$ .

**Tvrzení:** zobrazení  $x \mapsto \|x\|$  je spojitě. **D.:**  $|\|x\| - \|y\|| \leq \|x - y\|$

**Věta** o nabývání inf, sup na kompaktní množině

**Věta 37** Jsou-li  $\|x\|_\alpha$ ,  $\|x\|_\beta$  libovolné normy v  $R^n$ , potom existují konstanty  $c > 0$ ,  $d > 0$  takové, že

$$c \|x\|_\beta \leq \|x\|_\alpha \leq d \|x\|_\beta$$

pro každé  $x \in R^n$ .

**Důkaz** Necht'  $d = \max_{\|x\|_\beta=1} \|x\|_\alpha$ . Nejdřív pro  $\|x\|_\beta = \|x\|_2$ :  $\{x; \|x\|_2 = 1\}$  je kompaktní, tedy se nabývá;  $\forall x \neq 0$ ,  $\|\frac{x}{\|x\|_2}\|_2 = 1 \Rightarrow \|\frac{x}{\|x\|_2}\|_\alpha \leq d \Rightarrow \|x\|_\alpha \leq d \|x\|_2$  podobně dolní mez. Nyní

$$\begin{aligned} c \|x\|_2 &\leq \|x\|_\alpha \leq d \|x\|_2 \\ c \|x\|_2 &\leq \|x\|_\beta \leq d' \|x\|_2 \\ \frac{c}{d} \|x\|_\beta &\leq \|x\|_\alpha \leq \frac{d}{c} \|x\|_\beta \end{aligned}$$

■

**Důsledek:** Konvergence v  $R^n$  nezávisí na normě ( $\|x_n - x^*\|_\alpha \rightarrow 0 \Rightarrow \|x_n - x^*\|_\beta \rightarrow 0$ ). Obvykle proto používáme eukleidovskou normu.

Okolí:  $B(x, \varepsilon) = \{x'; \|x' - x\|_2 < \varepsilon\}$ .  $x \in C^0$ : ex.  $\varepsilon > 0$ , že  $B(x, \varepsilon) \subset C$ .  
 $x \in \text{Ext}(C)$ : ex.  $\varepsilon > 0$ , že  $B(x, \varepsilon) \cap C = \emptyset$ . Jinak  $\partial C$  (hranice).  $\overline{C} = C \cup \partial C$ .

$\overline{x, y} = \{x + t(y - x); t \in [0, 1]\} = \{ty + (1 - t)x; t \in [0, 1]\} = \{\lambda y + \mu x; \lambda + \mu = 1, \lambda \geq 0, \mu \geq 0\}$ .  $C \subset R^n$  se nazývá konvexní, jestliže  $x \in C, y \in C \Rightarrow \overline{x, y} \subset C$ .  
 Evidentní: průnik konvexních je konvexní, sjednocení obecně ne.

**Věta 38** *Je-li  $C$  konvexní, jsou i  $C^0$  a  $\overline{C}$  konvexní.*

(bez důkazu)

**Věta 39** *(o oddělitelnosti konvexních množin). Necht  $C_1, C_2$  jsou neprázdné konvexní disjunktí množiny. Potom existuje  $c \neq 0$  a číslo  $\alpha$  tak, že*

$$\forall x_1 \in C_1 \quad \forall x_2 \in C_2, \quad c^T x_1 \geq \alpha \geq c^T x_2 \quad (\text{lze i bez } \alpha)$$

*Jinými slovy  $C_1, C_2$  patří do opačných poloprostorů oddělených nadrovinou  $\{x; c^T x = \alpha\}$ .*

**Důkaz 1)** Necht  $C_2 = \{a\}$ ,  $a \notin \overline{C_1}$ . Zvolme  $b \in C_1$ , potom  $\{x; \|x - a\| \leq \|b - a\|\} \cap \overline{C_1} = B(a; \|b - a\|) \cap \overline{C_1}$  kompaktní, tedy funkce  $\|x - a\|$  na ní nabývá infima  $x^*$ , tj.

$$\|x^* - a\| = \min \{ \|x - a\|; x \in \overline{C_1} \}.$$

Necht  $x \in \overline{C_1}$ , potom  $\forall t \in [0, 1]$ ,

$$\begin{aligned} \|x^* + t(x - x^*) - a\| &\geq \|x^* - a\| \\ \|x^* - a + t(x - x^*)\|^2 &\geq \|x^* - a\|^2 \\ (x^* - a + t(x - x^*))^T (x^* - a + t(x - x^*)) &\geq (x^* - a)^T (x^* - a) \\ t^2 \|x - x^*\|^2 + 2t(x - x^*)^T (x^* - a) &\geq 0 \\ t \|x - x^*\|^2 + 2(x - x^*)^T (x^* - a) &\geq 0 \quad \forall t \in (0, 1) \end{aligned}$$

$$\frac{1}{2} \lim_{t \rightarrow 0^+} (t \|x - x^*\|^2 + 2(x - x^*)^T (x^* - a)) = (x - x^*)^T (x^* - a) \geq 0$$

Položíme-li tedy  $c := x^* - a$ , je

$$c^T x \geq c^T x^* \quad \forall x \in \overline{C_1}, \quad \text{tedy i} \quad \forall x \in C_1$$

ale

$$(x^* - a)^T (x^* - a) = c^T (x^* - a) \geq 0 \Rightarrow c^T x^* \geq c^T a \Rightarrow c^T x \geq c^T a.$$

2) Necht  $C_2 = \{a\}$ ,  $a \in \partial C_1$ . Potom existuje posloupnost bodů  $a_n \in \text{Ext}(C)$ ,  $a_n \rightarrow a$ . Ke každému existuje  $c_n$ , že

$$(\forall x \in C_1) \quad c_n^T x \geq c_n^T a_n$$

znormováním lze předpokládat  $\|c_n\|=1$ . Existuje vybraná posloupnost  $\{c_{n_k}\} \rightarrow c$ , pak  $\|c\|=1$  a  $\forall x \in C_1$  limitním přechodem

$$c^T x \geq c^T a.$$

3) Nechť  $C_1 \cap C_2 = \emptyset$ . Potom  $C := C_1 - C_2 = \{x_1 - x_2; x_1 \in C_1, x_2 \in C_2\}$  je konvexní  $[\lambda_1(x_1 - x_2) + \lambda_2(y_1 - y_2) = (\lambda_1 x_1 + \lambda_2 y_1) - (\lambda_1 x_2 + \lambda_2 y_2) \in C_1 - C_2]$  a  $0 \notin C_1 - C_2$ . Tedy existuje  $c \neq 0$ , že  $x \in C \Rightarrow c^T x \geq c^T 0 = 0$ , tj.  $x_1 \in C_1, x_2 \in C_2 \Rightarrow x_1 - x_2 \in C \Rightarrow c^T(x_1 - x_2) \geq 0 \Rightarrow c^T x_1 \geq c^T x_2$ . ■

**Věta 40 (Farkas).** Nechť  $A \in R^{m \times n}$ ,  $b \in R^m$ . Potom soustava

$$\begin{aligned} Ax &= b \\ x &\geq 0 \end{aligned}$$

má řešení právě když platí

$$(\forall y)(A^T y \geq 0 \Rightarrow b^T y \geq 0)$$

neboli nemá řešení právě když

$$(\exists y)(A^T y \geq 0 \ \& \ b^T y < 0).$$

**Důkaz** 1) Má-li řešení  $x$ , potom  $\forall y, A^T y \geq 0, b^T y = b^T Ax = x^T A^T y \geq 0$ .

2) Naopak nechť soustava nemá řešení. To znamená, že

$$b \notin C := \{Ax; x \geq 0\}.$$

Tedy existuje vektor  $c$  - označme ho zde  $y$  - takový, že

$$(\forall z \in C)(y^T z > y^T b)$$

tj.

$$(\forall x \geq 0)(y^T Ax > y^T b)$$

spec. pro  $x = 0$  dostáváme  $y^T b < 0$ , tudíž z  $(A^T y)^T x \geq 0 \ \forall x \geq 0$  musí být  $A^T y \geq 0$  (je-li  $(A^T y)_j < 0$ , volíme  $x = \lambda e_j \geq 0$ , potom  $\lim_{\lambda \rightarrow \infty} (A^T y)^T x = -\infty$ ). Tedy  $A^T y \geq 0$  a  $b^T y < 0$ , spor. ■

**Důsledek**  $Ax \leq b$  má řešení právě když

$$(\forall y \geq 0)(A^T y = 0 \Rightarrow b^T y \geq 0)$$

**Důkaz**  $Ax \leq b$  má řešení  $\Leftrightarrow A(x_1 - x_2) + x_3 = b, x_{1,2,3} \geq 0$  má řešení,  $\Leftrightarrow (\forall y)(A^T y \geq 0, A^T y \leq 0, y \geq 0 \Rightarrow b^T y \geq 0)$ . ■

**Věta 41** (Jordan) Nechť  $A \in R^{m \times n}$ ,  $b \in R^m$ . Potom soustava

$$Ax < b$$

má řešení právě když

$$(\forall y)(A^T y = 0, y \geq 0, y \neq 0 \Rightarrow b^T y \geq 0).$$

**Důkaz** 1) Má-li řešení a je-li  $A^T y = 0, y \geq 0, y \neq 0$ , potom  $0 < y^T(b - Ax) = y^T b - (A^T y)^T x = y^T b$ .

2) Nechť  $Ax < b$  nemá řešení. Nechť  $C_1 = \{Ax; x \in R^n\}$ ,  $C_2 = \{z; z < b\}$ , neprázdné disjunktní konvexní, tedy existuje  $y \neq 0$ , že  $y^T Ax \geq y^T z \forall x \in R^n \forall z < b$ .  $(A^T y)_j \neq 0 \Rightarrow$  volbou  $x = \pm \lambda e_j$  není splněno, tedy  $A^T y = 0$ . Kdyby  $y_j < 0$ , volme  $z = \lambda e_j, \lambda \rightarrow -\infty$ . Tedy  $y \geq 0$ . Pro  $x = 0 : 0 \geq y^T z \forall z < b$ , tedy  $\lim_{z \rightarrow b_-}$  dává  $0 \geq y^T b$ . ■

## 6.2 Pozitivně (semi)definitní matice

Matice  $A$  se nazývá pozitivně (semi)definitní jestliže  $x^T Ax \geq 0 \forall x$  ( $x^T Ax > 0 \forall x \neq 0$ ).  $A$  je symetrická, jestliže  $A^T = A$ . Protože  $x^T Ax = x^T \left(\frac{1}{2}(A + A^T)\right) x \forall x$ , lze se zabývat pouze vyšetřováním symetrických matic.

**Věta 42** (Sylvester). Symetrická matice  $A$  je pozitivně definitní právě když

$$\det \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & a_{2k} \\ \vdots & & & \\ a_{k1} & a_{k2} & \dots & a_{kk} \end{pmatrix} > 0$$

pro  $k = 1, \dots, n$ .

**Věta 43** Nechť  $A$  je pozitivně semidefinitní a nechť

$$x^T Ax = 0$$

pro jisté  $x$ . Potom

$$(A + A^T)x = 0.$$

**Důkaz** a) Nechť  $A$  je symetrická. Potom  $\forall \lambda \in R^1$

$$(\lambda x + Ax)^T A(\lambda x + Ax) \geq 0$$

tj.

$$\begin{aligned} (\lambda x + Ax)^T (\lambda Ax + A^2 x) &= \lambda^2 x^T Ax + \lambda x^T A^2 x + \lambda (Ax)^T Ax + (Ax)^T A^2 x \geq 0 \\ &= \lambda^2 x^T Ax + 2\lambda \|Ax\|^2 + (Ax)^T A^2 x \\ &= 2\lambda \|Ax\|^2 + x^T A^3 x \geq 0 \quad \forall \lambda \in R^1 \end{aligned}$$

$$\Rightarrow \|Ax\| = 0 \Rightarrow Ax = 0$$

$$\text{b) } A \text{ obecná: } x^T Ax = 0 \Rightarrow x^T \left( \frac{1}{2}(A + A^T) \right) x = 0 \Rightarrow \frac{1}{2}(A + A^T)x = 0. \quad \blacksquare$$

**Věta 44** Symetrická matice  $A$  má pouze reálná vlastní čísla a pro její nejmenší a největší vlastní číslo platí

$$\begin{aligned} \lambda_{\min}(A) &= \min_{\|x\|_2=1} x^T Ax \\ \lambda_{\max}(A) &= \max_{\|x\|_2=1} x^T Ax. \end{aligned}$$

**Důkaz**  $A(x_1 + x_2 i) = (\lambda_1 + \lambda_2 i)(x_1 + x_2 i) \Rightarrow (x_1 - x_2 i)^T A(x_1 + x_2 i) = (\lambda_1 + \lambda_2 i)(x_1^T x_1 + x_2^T x_2)$

$$\begin{aligned} \lambda_1 + \lambda_2 i &= \frac{x_1^T Ax_1 + x_2^T Ax_2 + (x_1^T Ax_2 - x_2^T Ax_1)i}{x_1^T x_1 + x_2^T x_2} \\ \Rightarrow \lambda_2 &= \frac{x_1^T Ax_2 - x_2^T Ax_1}{x_1^T x_1 + x_2^T x_2} = 0. \end{aligned}$$

Je-li  $Ax = \lambda x$ ,  $\|x\|_2 = 1$ , potom  $\lambda = x^T Ax \leq \max_{\|x\|_2=1} x^T Ax$ . Nechť  $\mu = \max_{\|x\|_2=1} x^T Ax$ .

Potom  $x^T Ax \leq \mu \forall x$ ,  $\|x\|_2 = 1$ ; tj.  $\left( \frac{x}{\|x\|} \right)^T A \left( \frac{x}{\|x\|} \right) \leq \mu \Rightarrow x^T Ax \leq \mu x^T x$   
 $\Rightarrow x^T (\mu I - A)x \geq 0 \Rightarrow \mu I - A$  je pozitivně semidefinitní a existuje  $x_0$ , že  $x_0^T (\mu I - A)x_0 = 0 \Rightarrow (\mu I - A)x_0 = 0$ ,  $Ax_0 = \mu x_0 \Rightarrow \mu$  je vlastní číslo  $A$ , tedy největší. Navíc,  $x$  je vlastní vektor příslušný k  $\lambda_{\max}(A)$  právě když  $\lambda_{\max}(A) = \frac{x^T Ax}{x^T x}$ .  $\blacksquare$

**Důsledek** Symetrická matice je pozitivně (semi)definitní právě když všechna její vlastní čísla jsou kladná (nezáporná), tj.  $\lambda_{\min}(A) > 0$ , resp.  $\geq 0$ .

## 6.3 Konvexní funkce

Funkce  $f$  je *konvexní* v konvexní množině  $X \subseteq R^n$ , jestliže  $\forall x_1, x_2 \in X \forall \lambda_1 \geq 0, \lambda_2 \geq 0, \lambda_1 + \lambda_2 = 1, f(\lambda x_1 + \lambda x_2) \leq \lambda_1 f(x_1) + \lambda_2 f(x_2)$ .

**Příklad**  $f(x) = x^2$ .

**Věta 45** (*Jenssenova nerovnost*). *Nechť  $f$  je konvexní v  $X$ , nechť  $x_1, \dots, x_m \in X, \lambda_i \geq 0 \forall i, \sum_{i=1}^m \lambda_i = 1$ . Potom*

$$f\left(\sum_{i=1}^m \lambda_i x_i\right) \leq \sum_{i=1}^m \lambda_i f(x_i).$$

**Důkaz** indukcí podle  $m$ : pro  $m = 1$  a  $m = 2$  zřejmě platí. Nechť  $m > 2$  a  $\lambda_1 < 1$ , pak

$$\begin{aligned} f\left(\sum_1^m \lambda_i x_i\right) &= f\left(\lambda_1 x_1 + (1 - \lambda_1) \sum_{i=2}^m \frac{\lambda_i}{1 - \lambda_1} x_i\right) \\ &\leq \lambda_1 f(x_1) + (1 - \lambda_1) f\left(\sum_{i=2}^m \frac{\lambda_i}{1 - \lambda_1} x_i\right) \\ &\leq \lambda_1 f(x_1) + (1 - \lambda_1) \sum_{i=2}^m \frac{\lambda_i}{1 - \lambda_1} f(x_i) = \sum_1^m \lambda_i f(x_i). \end{aligned}$$

■

- Vlastnosti**
- 1)  $f, g$  konvexní,  $\alpha \geq 0, \beta \geq 0 \Rightarrow \alpha f + \beta g$  konvexní
  - 2)  $f, g$  konvexní  $\Rightarrow \max\{f, g\}$  konvexní
  - 3)  $f$  konvexní,  $\alpha \in R^1 \Rightarrow \{x; f(x) \leq \alpha\}$  konvexní množina

**Věta 46** *Je-li  $f$  konvexní v  $X$ , potom je spojitá v  $X^0$ .*

(bez důkazu); příklad:  $f(x) = x$  pro  $x \in [0, 1)$ ,  $f(1) = 2$  je konvexní, ale není spojitá v  $[0, 1]$ .

**Značení:**  $C(X), C^1(X), C^2(X)$  třída funkcí spojitých v  $X$  majících 1. resp. 2. parciální derivace v  $X, \nabla f = \left(\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n}\right)^T$  gradient,  $H = \nabla^2 f = \left(\frac{\partial^2 f}{\partial x_i \partial x_j}\right)_{i,j=1}^n$  hessián.

**Věta 47** *Nechť  $X$  je otevřená konvexní množina,  $f \in C^1(X)$ . Potom  $f$  je konvexní v  $X$  právě když*

$$f(x) + (y - x)^T \nabla f(x) \leq f(y) \tag{6.1}$$

pro každé  $x, y \in X$ .



**Důkaz**  $\Rightarrow$ :  $\forall \lambda \in [0, 1]$  platí  $f(x + \lambda(y - x)) \leq f(x) + \lambda(f(y) - f(x))$ , tj.

$$\frac{f(x + \lambda(y - x)) - f(x)}{\lambda} \leq f(y) - f(x)$$

$\lim_{\lambda \rightarrow 0^+}$  dává  $(y - x)^T \nabla f(x) \leq f(y) - f(x)$ , což je (6.1).

$\Leftarrow$  Nechť to platí a nechť  $x, y \in X$ ,  $z = \lambda_1 x + \lambda_2 y$ ,  $\lambda_{1,2} \geq 0$ ,  $\lambda_1 + \lambda_2 = 1$ .  
Potom

$$\begin{aligned} f(z) + (y - z)^T \nabla f(z) &\leq f(y) & / \cdot \lambda_2 \\ f(z) + (x - z)^T \nabla f(z) &\leq f(x) & / \cdot \lambda_1 \end{aligned}$$

$$f(z) + (\lambda_1 x + \lambda_2 y - z)^T \nabla f(z) \leq \lambda_1 f(x) + \lambda_2 f(y)$$

tj.

$$f(z) = f(\lambda_1 x + \lambda_2 y) \leq \lambda_1 f(x) + \lambda_2 f(y).$$

■

**Věta 48** *Nechť  $X$  je otevřená konvexní množina a nechť  $f \in C^2(X)$ . Potom  $f$  je konvexní v  $X$  právě když  $\nabla^2 f$  je pozitivně semidefinitní v každém bodě  $X$ .*

**Důkaz**  $\Rightarrow$ : Nechť  $\nabla^2 f$  není pozitivně semidefinitní v jistém bodě  $x \in X$ , tj. existuje  $d \neq 0$ , že  $d^T \nabla^2 f(x) d < 0$ . Protože  $\lim_{\alpha \rightarrow 0} d^T \nabla^2 f(x + \alpha d) d = d^T \nabla^2 f(x) d < 0$ , existuje vzhledem ke spojitosti  $\nabla^2 f$  číslo  $\alpha_0 > 0$  tak, že pro každé  $\alpha \in [0, \alpha_0]$  je  $d^T \nabla^2 f(x + \alpha d) d < 0$ . Potom podle Taylorovy věty existuje  $\alpha \in [0, \alpha_0]$ , že

$$f(x + \alpha_0 d) - f(x) = \alpha_0 d^T \nabla f(x) + \frac{1}{2} \alpha_0^2 d^T \nabla^2 f(x_0 + \alpha d) d < \alpha_0 d^T \nabla f(x)$$

tj. pro  $y = x + \alpha_0 d$  máme

$$f(y) < f(x) + (y - x)^T \nabla f(x),$$

spor s větou 47.

$\Leftarrow$  Je-li  $\nabla^2 f$  pozitivně semidefinitní, pak  $\forall x, y$  je podle Taylorovy věty

$$f(y) = f(x) + (y - x)^T \nabla f(x) + \frac{1}{2} (y - x)^T \nabla^2 f(z) (y - x) \geq f(x) + (y - x)^T \nabla f(x)$$

pro jisté  $z \in \overline{x, y}$  tedy je konvexní. ■

**Tvrzení** Nechť  $D$  je symetrická matice. Potom  $\nabla(x^T D x + c^T x) = 2Dx + c$ ,  $\nabla^2(x^T D x + c^T x) = 2D$ . Tudíž kvadratická funkce  $x^T D x + c^T x$  je konvexní právě když  $D$  je pozitivně semidefinitní.

**Důkaz**

$$\begin{aligned}
 \frac{\partial}{\partial x_k} \left( \sum_i x_i (Dx)_i + \sum_i c_i x_i \right) &= \sum_{i \neq k} x_i \frac{\partial}{\partial x_k} \sum_j D_{ij} x_j + (Dx)_k + x_k \frac{\partial}{\partial x_k} \sum_j D_{kj} x_j + c_k \\
 &= \sum_{i \neq k} x_i D_{ik} + (Dx)_k + x_k D_{kk} + c_k = \\
 &= \sum_i x_i D_{ik} + (Dx)_k + c_k = \sum_i D_{ki} x_i + (Dx)_k + c_k \\
 &= 2(Dx)_k + c_k
 \end{aligned}$$

$\Rightarrow \nabla(x^T Dx + c^T x) = 2Dx + c$ . Pak

$$\frac{\partial^2}{\partial x_k \partial x_l} = 2D_{kl} \Rightarrow \nabla^2(x^T Dx + c^T x) = 2D.$$

■

## 6.4 Optimalizace konvexních funkcí

**Definice** Necht  $f : X \rightarrow R^1$ . Bod  $x^*$  je globální minimum  $f$  v  $X$ , jestliže  $f(x^*) \leq f(x) \forall x \in X$ . (Nazývá se optimální řešení.) Nazývá se lokální minimum, jestliže existuje  $\varepsilon > 0$ , že  $f(x^*) \leq f(x) \forall x \in B(x^*, \varepsilon) \cap X$ .

**Tvrzení** Necht  $f$  je spojitá v  $X$  a necht pro jisté  $x_0 \in X$  je množina

$$L(x_0) = \{x \in X; f(x) \leq f(x_0)\}$$

kompaktní. Potom  $f$  má globální minimum v  $X$ .

**Důkaz**  $L(x_0) \neq \emptyset$ , protože  $x_0 \in L(x_0)$ . Protože  $f$  je spojitá v  $L(x_0)$ , nabývá v ní minima: existuje  $x^* \in L(x_0)$ , že  $f(x^*) = \min\{f(x); x \in L(x_0)\}$ . Nyní, necht  $x \in X$ ; a) je-li  $f(x) > f(x_0)$ , potom  $f(x) > f(x_0) \geq f(x^*)$ , b) je-li  $f(x) \leq f(x_0)$ , je  $x \in L(x_0)$ , tedy  $f(x) \geq f(x^*)$ . V obou případech  $f(x) \geq f(x^*)$ , tedy  $x^*$  je globální minimum  $f$  v  $X$ . ■

**Věta 49** Necht  $f$  je konvexní v konvexní množině  $X$ . Potom každé její lokální minimum je rovněž globálním minimem.

**Důkaz** Necht jisté lokální minimum  $x^*$  není globální, tj. existuje  $y \in X$ , že  $f(y) < f(x^*)$ . Potom  $\forall \lambda \in (0, 1]$  je

$$f(x^* + \lambda(y - x^*)) \leq f(x^*) + \lambda(f(y) - f(x^*)) < f(x^*),$$

tedy v každém okolí  $x^*$  existuje bod z  $X$  s menší hodnotou, tj.  $x^*$  není lokální minimum. ■

**Věta 50** *Nechť  $f$  je konvexní v konvexní množině  $X$ . Potom množina všech globálních minim je konvexní.*

**Důkaz** Necht'  $f(x^*) = f(x^{**}) = \min_X f(x)$ . Potom  $\forall \lambda \in [0, 1]$  platí

$$\begin{aligned} f(x^* + \lambda(x^{**} - x^*)) &\leq f(x^*) + \lambda(f(x^{**}) - f(x^*)) = f(x^*) \\ \Rightarrow f(x^* + \lambda(x^{**} - x^*)) &= f(x^*) \end{aligned}$$

$\Rightarrow x^* + \lambda(x^{**} - x^*)$  je globální minimum  $\forall \lambda \in [0, 1]$ . ■

**Věta 51** *Je-li  $X$  konvexní polyedr a  $f$  je konvexní v  $X$ , potom*

$$\max_X f(x) = f(\hat{x})$$

*pro jistý vrchol  $\hat{x}$  polyedru  $X$ .*

**Důkaz** Necht'  $\hat{x}_1, \dots, \hat{x}_m$  jsou vrcholy  $X$ . Protože  $X$  je konvexním obalem svých vrcholů, existují ke každému  $x \in X$  čísla  $\lambda_i \geq 0$  ( $i = 1, \dots, m$ ),  $\sum_{i=1}^m \lambda_i = 1$  taková, že  $x = \sum_{i=1}^m \lambda_i \hat{x}_i$ , a podle Jenssenovy nerovnosti (věta 45)

$$f(x) = f\left(\sum_{i=1}^m \lambda_i \hat{x}_i\right) \leq \sum_{i=1}^m \lambda_i f(\hat{x}_i) \leq \left(\sum_{i=1}^m \lambda_i\right) \max_i f(\hat{x}_i) = \max_i f(\hat{x}_i) = f(\hat{x}_j)$$

kde  $f(\hat{x}_j) = \max_i f(\hat{x}_i)$ , tedy  $\max_X f(x) = f(\hat{x}_j)$ . ■

# Kapitola 7

## Teorie nelineárního programování

### 7.1 Úlohy bez vazeb

**Věta 52** *Nechť  $X \subseteq R^n$  je otevřená,  $f \in C^1(X)$ , a necht'  $x^*$  je lokální minimum  $f$  v  $X$ . Potom*

$$\nabla f(x^*) = 0.$$

**Důkaz** Platí

$$\lim_{\alpha \rightarrow 0} \frac{f(x^* - \alpha \nabla f(x^*)) - f(x^*)}{\alpha} = \lim_{\alpha \rightarrow 0} (-\nabla f(x^*)^T \nabla f(\xi)) = -\|\nabla f(x^*)\|_2^2.$$

Kdyby  $\nabla f(x^*) \neq 0$ , je  $\lim \dots < 0$ , tedy pro dostatečně malé  $\alpha > 0$  je  $x^* - \alpha \nabla f(x^*) \in X$  a  $f(x^* - \alpha \nabla f(x^*)) < f(x^*) \Rightarrow x^*$  není lokální minimum. ■

**Definice** Bod  $x^*$ , pro který  $\nabla f(x^*) = 0$ , se nazývá stacionární bod.

**Věta 53** *Nechť  $X \subseteq R^n$  je otevřená konvexní množina a necht'  $f \in C^1(X)$  je konvexní. Potom  $x^* \in X$  je globální (= lokální) minimum  $f$  v  $X$ , právě když*

$$\nabla f(x^*) = 0.$$

**Důkaz** Podle předchozí věty je podmínka nutná. Je-li  $\nabla f(x^*) = 0$ , potom podle charakteristiky konvexní funkce (věta 47) platí  $\forall x \in X$

$$f(x^*) + (x - x^*)^T \nabla f(x^*) \leq f(x)$$

tj.  $f(x^*) \leq f(x)$ , čili  $x^*$  je globální minimum. ■

**Věta 54** *Nechť  $X$  je otevřená,  $f \in C^2(X)$  a necht'  $x^*$  je lokální minimum  $f$  v  $X$ . Potom  $\nabla^2 f(x^*)$  je pozitivně semidefinitní.*

**Důkaz** Necht' není, tj. existuje  $d$ , že  $d^T \nabla^2 f(x^*) d < 0$ . Potom

$$\begin{aligned} f(x^* + \alpha d) &= f(x^*) + \alpha d^T \nabla f(x^*) + \frac{1}{2} \alpha^2 d^T \nabla^2 f(x^*) d + o(\alpha^2) \\ &= f(x^*) + \frac{1}{2} \alpha^2 d^T \nabla^2 f(x^*) d + o(\alpha^2) \end{aligned}$$

tj.

$$f(x^* + \alpha d) - f(x^*) = \alpha^2 \left( \frac{1}{2} d^T \nabla^2 f(x^*) d + \frac{o(\alpha^2)}{\alpha^2} \right)$$

a jelikož  $\lim_{\alpha \rightarrow 0} \frac{o(\alpha^2)}{\alpha^2} = 0$ , je  $f(x^* + \alpha d) - f(x^*) < 0$  pro dodatečně malé  $\alpha$ , tedy  $x^*$  není lokální minimum. ■

**Věta 55** *Nechť  $X$  je otevřená,  $f \in C^2(X)$  a necht' pro jisté  $x^* \in X$  platí  $\nabla f(x^*) = 0$  a  $\nabla^2 f(x^*)$  je pozitivně definitní. Potom  $x^*$  je [ostré] lokální minimum  $f$  v  $X$ .*

**Důkaz** Pro každé  $x^* + d$  je

$$\begin{aligned} f(x^* + d) &= f(x^*) + d^T \nabla f(x^*) + \frac{1}{2} d^T \nabla^2 f(x^*) d + o(\|d\|_2^2) \\ &= f(x^*) + \frac{1}{2} d^T \nabla^2 f(x^*) d + o(\|d\|_2^2) \\ &= f(x^*) + \|d\|_2^2 \left( \frac{1}{2} \left( \frac{d}{\|d\|_2} \right)^T \nabla^2 f(x^*) \frac{d}{\|d\|_2} + \frac{o(\|d\|_2^2)}{\|d\|_2^2} \right). \end{aligned}$$

Platí

$$\left( \frac{d}{\|d\|_2} \right)^T \nabla^2 f(x^*) \left( \frac{d}{\|d\|_2} \right) \geq \lambda_{\min}(\nabla^2 f(x^*)) > 0$$

a protože  $\lim_{\|d\| \rightarrow 0} \frac{o(\|d\|_2^2)}{\|d\|_2^2} = 0$ , je  $\frac{o(\|d\|_2^2)}{\|d\|_2^2} \leq \frac{1}{2} \lambda_{\min}(\nabla^2 f(x^*))$  pro dost malá  $\|d\|_2$ . Pro tato  $d$  je potom  $f(x^* + d) > f(x^*)$ , tedy  $x^*$  je ostré lokální minimum. ■

## 7.2 Úlohy s vazbami

### 7.2.1 Věta Fritze Johna

Nyní se budeme zabývat obecnou úlohou

$$\min\{f(x); g(x) \leq 0, h(x) = 0, x \in X\} \quad (\text{NLP})$$

kde  $g(x) = (g_1(x), \dots, g_n(x))^T$  je vektorová funkce, stejně tak  $h(x) = (h_1(x), \dots, h_p(x))^T$ ,  $X \subseteq R^n$  (obvykle se bere  $X = R^n$ ). Pro  $\alpha \in R^1$  definujme  $\alpha^+ = \max\{\alpha, 0\}$ , takže  $\alpha \leq 0 \Leftrightarrow \alpha^+ = 0$ . To umožňuje převádět nerovnosti na rovnice:  $g^+(x) = 0 \Leftrightarrow g(x) \leq 0$  a  $g^+(x) = 0 \Leftrightarrow \|g^+(x)\|_2^2 = 0$ .

$$\frac{\partial}{\partial x_k} \|h(x)\|^2 = \frac{\partial}{\partial x_k} \sum_i h_i^2(x) = \sum_i 2h_i(x) \frac{\partial h_i}{\partial x_k}$$

Je-li  $g_i^+(x) < 0$ : v okolí  $g_i(x) < 0$ , tedy  $g_i^+(x) = 0$ ,  $\frac{\partial}{\partial x_k} g_i^{+2}(x) = \frac{\partial}{\partial x_k} 0 = 0$  a přitom  $2g_i^+(x) \nabla g_i(x) = 0 = \frac{\partial}{\partial x_k} g_i^{+2}(x)$ . Je-li  $g_i(x) = 0$ , tj.  $g_i^+(x) = 0$ , tj.

$$g_i^{+2}(x) = \begin{cases} g_i^2(x) & \text{pro } g_i(x) < 0 \\ 0 & \text{pro } g_i(x) = 0 \end{cases}$$

**Věta 56** (*Fritz John, někdy Karush-John*). *Nechť  $f, g, h \in C^1(X)$  a nechť  $x^* \in X$  je lokální optimum úlohy*

$$\min\{f(x); g(x) \leq 0, h(x) = 0, x \in X\}.$$

*Potom existují  $\nu \in R^1$ ,  $\lambda \in R^m$ ,  $\mu \in R^p$ ,  $(\nu, \lambda, \mu) \neq 0$  tak, že*

$$\begin{aligned} \nabla(\nu f + \lambda^T g + \mu^T h)(x^*) &= 0 \\ \lambda^T g(x^*) &= 0 \\ \nu \geq 0, \lambda &\geq 0. \end{aligned}$$

**Důkaz** Označme  $F = \{x; g(x) \leq 0, h(x) = 0, x \in X\}$ . Protože  $x^*$  je lokální optimum, existuje  $\varepsilon > 0$  tak, že  $\overline{B(x^*, \varepsilon)} \subset X$  a  $f(x^*) \leq f(x)$  pro každé  $x \in \overline{B(x^*, \varepsilon)} \cap F$ . Pro každé přirozené  $k$  definujme

$$f_k(x) = f(x) + k(\|g^+(x)\|^2 + \|h(x)\|^2) + \|x - x^*\|^2, \quad x \in X.$$

Potom  $f_k$  je spojitá v  $\overline{B(x^*, \varepsilon)}$ , tedy tam nabývá minima v jistém bodě  $x_k$ . Potom  $f_k(x_k) \leq f_k(x^*) = f(x^*)$ , tedy

$$f(x_k) + k(\|g^+(x_k)\|^2 + \|h(x_k)\|^2) + \|x_k - x^*\|^2 \leq f(x^*) \quad (7.1)$$

a odtud

$$\|g^+(x_k)\|^2 + \|h(x_k)\|^2 \leq \frac{1}{k} (f(x^*) - f(x_k) - \|x_k - x^*\|^2).$$

Protože  $x_k \in \overline{B(x^*, \varepsilon)}$ , existuje vybraná posloupnost  $x_{k_j} \rightarrow \tilde{x} \in \overline{B(x^*, \varepsilon)}$ . Jelikož čítecil napravo je omezený, jde k 0 pro  $k \rightarrow \infty$ , tedy

$$0 \leq \|g^+(\tilde{x})\|^2 + \|h(\tilde{x})\|^2 \leq 0$$

$\Rightarrow \|g^+(\tilde{x})\| = \|h(\tilde{x})\| = 0 \Rightarrow \tilde{x} \in F$  a  $\|\tilde{x} - x^*\| \leq \varepsilon$ , tedy  $\tilde{x} \in F \cap \overline{B(x, \varepsilon)}$ . Z (7.1) plyne

$$f(x_k) + \|x_k - x^*\|^2 \leq f(x^*)$$

a limitním přechodem  $f(\tilde{x}) + \|\tilde{x} - x^*\|^2 \leq 0$ . Jelikož  $\tilde{x} \in F \cap \overline{B(x, \varepsilon)}$ , je  $f(x^*) \leq f(\tilde{x})$  a tedy  $f(\tilde{x}) + \|\tilde{x} - x^*\|^2 \leq f(x^*) \leq f(\tilde{x}) \Rightarrow \|\tilde{x} - x^*\|^2 \leq 0 \Rightarrow \tilde{x} = x^*$ . Závěrem, existuje vybraná posloupnost, že  $x_{k_j} \rightarrow x^*$ . Nyní, protože  $x_{k_j} \rightarrow x^*$ , existuje  $j_0$ , že  $j \geq j_0 \Rightarrow x_{k_j} \in B(x^*, \varepsilon)$  a jelikož  $f_{k_j}$  nabývá minima v bodě  $x_{k_j}$ , je

$$\nabla f_k(x_k) = 0 \quad (\text{píšeme } k \text{ místo } k_j).$$

Tj. z definice  $f_k$  dostáváme

$$\nabla f_k(x_k) = \nabla f(x_k) + \sum_j 2kg_j^+(x_k) \nabla g_j(x_k) + \sum_i 2kh_i(x_k) \nabla h_i(x_k) + 2(x_k - x^*) = 0.$$

Položme

$$\omega_k = \max \left\{ \max_j 2kg_j^+(x_k), \max_i 2k|h_i(x_k)|, 2 \right\},$$

tedy  $\omega_k \geq 2$  a vydělením

$$\underbrace{\frac{1}{\omega_k}}_{\in [0, \frac{1}{2}]} \nabla f(x_k) + \sum_j \underbrace{\frac{2kg_j^+(x_k)}{\omega_k}}_{\in [0, 1]} \nabla g_j(x_k) + \sum_i \underbrace{\frac{2kh_i(x_k)}{\omega_k}}_{\in [-1, 1]} \nabla h_i(x_k) + \underbrace{\frac{2}{\omega_k}}_{\in [0, 1]} (x_k - x^*) = 0$$

tedy existuje vybraná posloupnost, že  $\frac{1}{\omega_{k_l}} \rightarrow \nu$ ,  $\frac{2k_l g_j^+(x_{k_l})}{\omega_{k_l}} \rightarrow \lambda_j$ ,  $\frac{2k_l h_i(x_{k_l})}{\omega_{k_l}} \rightarrow \mu_i$ . Limitním přechodem tedy dostaneme

$$\nu \nabla f(x^*) + \sum_j \lambda_j \nabla g_j(x^*) + \sum_i \mu_i \nabla h_i(x^*) = 0$$

tedy

$$\nabla(\nu f + \sum_j \lambda_j g_j + \sum_i \mu_i h_i)(x^*) = 0,$$

což je první podmínka. Dále, je-li  $g_j(x^*) < 0$  pro jisté  $j$ , potom  $g_j(x_{k_l}) < 0$  pro dost velká  $l$ , tedy  $g_j^+(x_{k_l}) = 0$  a tedy  $\lambda_j = 0$ . Tedy pro každé  $j$  je  $\lambda_j g_j(x^*) = 0$ ,  $\Rightarrow \lambda^T g(x^*) = 0$ . Dále, posloupnosti konvergující k  $\nu$  a  $\lambda_j$  jsou nezáporné, tedy i  $\nu \geq 0$ ,  $\lambda \geq 0$ . Je-li  $\omega_k = 2$  pro nekonečně mnoho  $k$ , je  $\nu = \frac{1}{2}$ , jinak je buď  $\lambda_j = 1$  nebo  $\mu_i = 1$ , tedy vždy  $(\nu, \lambda, \mu) \neq 0$ . ■

## 7.2.2 Kuhn-Tuckerovy podmínky

Podmínky

$$\left. \begin{aligned} \nabla(\nu f + \lambda^T g + \mu^T h)(x^*) &= 0 \\ \lambda^T g(x^*) &= 0 \\ \nu \geq 0, \lambda &\geq 0 \end{aligned} \right\} \text{(PFJ)}$$

se nazývají podmínky Fritze Johna. Důležitý je zvláštní případ  $\nu > 0$  (tj.  $\nu \neq 0$ ). Potom vydělením dostáváme

$$\left. \begin{aligned} \nabla(f + \tilde{\lambda}^T g + \tilde{\mu}^T h)(x^*) &= 0 \\ \tilde{\lambda}^T g(x^*) &= 0 \\ \tilde{\lambda} &\geq 0 \end{aligned} \right\} \text{(KTP)}$$

(Kuhn-Tuckerovy podmínky). Smysl předpokladu  $\nu > 0$  lze nahlédnout dvojitým způsobem: 1) pro  $\nu = 0$  podmínky nic nevyovídají o minimalizované funkci  $f$ , 2) ověřování (KTP): položme  $J = \{j; \lambda_j > 0\}$ , potom máme

$$\begin{aligned} \nabla(f + \sum_{j \in J} \lambda_j g_j + \sum_i \mu_i h_i)(x^*) &= 0 \\ g_j(x^*) &= 0, \quad j \in J \\ h_i(x^*) &= 0 \quad \forall i \end{aligned}$$

to je  $n + |J| + p$  rovnic pro  $n + |J| + p$  neznámých; v případě  $\nu > 0$  by bylo neznámých o 1 více než rovnic. Metoda (teoretická): vyřešit soustavu  $\forall J \subseteq \{1, \dots, m\}$  a ověřit že  $\lambda_j \geq 0$  pro  $j \in J$ ,  $g_j(x^*) \leq 0$  pro  $j \notin J$ ,  $x^* \in X$ .

$\nu = 0$  lze dosáhnout za dodatečných podmínek (podmínky regularity).

**Věta 57** (KTP jako nutné). *Nechť  $f, g, h \in C^1(X)$ , nechť  $x^* \in X$  je lokální optimální řešení (NLP) a nechť gradienty  $\nabla g_j(x^*)$ ,  $\forall j \in J = \{j; g_j(x^*) = 0\}$ ,  $\nabla h_i(x^*) \forall i$  jsou lineárně nezávislé. Potom  $x^*$  splňuje (KTP).*

**Důkaz** Předpokládejme  $\nu = 0$ . Potom  $(\lambda, \mu) \neq 0$ , a platí  $\nabla(\lambda^T g + \mu^T h)(x^*) = 0$ . Protože  $\lambda_j = 0$  pro  $g_j(x^*) < 0$ , platí

$$\sum_{g_j(x^*)=0} \lambda_j \nabla g_j(x^*) + \sum_i \mu_i \nabla h_i(x^*) = 0,$$

tedy jsou lineárně závislé, spor. Proto  $\nu > 0$  a vydělením dostaneme (KTP). ■

**Věta 58** (KTP jako postačující). *Nechť  $f, g \in C^1(X)$  jsou konvervní,  $h = Ax - b$  a nechť  $x^* \in F$  splňuje (KTP). Potom  $x^*$  je globálním optimálním řešením (NLP).*



**Důkaz** Především,  $\frac{\partial h_i}{\partial x_j} = a_{ij}$ , tedy  $\nabla h_i = (A)_{i\text{-tý řádek}} = (A^T)_i$  a tedy  $\sum_i \mu_i \nabla h_i = \sum_i \mu_i (A^T)_i = A^T \mu$ . Nyní, necht'  $x \in F$ . Protože  $f$  je konvexní, platí  $f(x^*) + (x - x^*)^T \nabla f(x^*) \leq f(x)$ , tedy

$$\begin{aligned} f(x^*) &\leq (x^* - x)^T \nabla f(x^*) + f(x) \\ &= (x - x^*)^T \left( \sum_j \lambda_j \nabla g_j(x^*) + \sum_i \mu_i \nabla h_i(x^*) \right) + \sum_j \lambda_j g_j(x^*) + f(x) = \\ &= \sum_j \lambda_j \left[ g_j(x^*) + (x - x^*)^T \nabla g_j(x^*) \right] + (x - x^*)^T A^T \mu + f(x) \\ &\leq \sum_j \lambda_j g_j(x) + [A(x - x^*)]^T \mu + f(x) \leq f(x) \end{aligned}$$

(protože  $\lambda_j \geq 0$ ,  $g_j(x) \leq 0 \forall j$  a  $Ax = Ax^* = b$ ) a tedy  $x^*$  je globálním optimum. ■

**Věta 59** Necht'  $f, g \in C^1$  jsou konvexní a necht' existuje  $x_0 \in X$  tak, že  $g(x_0) < 0$  [Slaterova podmínka]. Potom  $x^* \in X$  je globálním optimálním řešením úlohy

$$\min\{f(x); g(x) \leq 0\} \quad (\text{NLP}_0)$$

právě když splňuje (KTP).

**Důkaz**  $\Rightarrow$  Necht'  $\nu = 0$  v (PFJ). Potom  $\sum_j \lambda_j \nabla g_j(x^*) = 0$ , a tedy

$$\begin{aligned} 0 &= (x_0 - x^*)^T \sum_j \lambda_j \nabla g_j(x^*) + \sum_j \lambda_j g_j(x^*) = \sum_j \lambda_j \left[ g_j(x^*) + (x_0 - x^*)^T \nabla g_j(x^*) \right] \\ &\leq \sum_j \lambda_j g_j(x_0) < 0 \end{aligned}$$

neboť  $\lambda_j > 0$  pro jisté  $j$ , spor.

$\Leftarrow$  plyne z předchozí věty. ■

### 7.2.3 Reformulace PFJ pomocí LP pro úlohy s nerovnostmi

**Věta 60** Necht'  $f, g \in C^1$ , a necht'  $x$  je přípustné řešení úlohy

$$\min\{f(x); g(x) \leq 0\}. \quad (\text{NLP}_0)$$

Potom  $x$  je bodem Fr. Johna právě když úloha lineárního programování

$$\min\{\delta; d^T \nabla f(x) \leq \delta, g_j(x) + d^T \nabla g_j(x) \leq \delta \forall j, -1 \leq d_j \leq 1 \forall j\} \quad (\text{LP}_x)$$

má nulovou optimální hodnotu.

**Důkaz** Především  $(LP_x)$  je omezená a  $d = 0$ ,  $\delta = 0$  je přípustné řešení, tedy  $\min\{\delta; \dots\} \leq 0$ .

$\Rightarrow$  Necht  $x$  je bodem Fr. Johna tj.

$$\begin{aligned} \nu \nabla f(x) + \sum_j \lambda_j \nabla g_j(x) &= 0 \\ \sum_j \lambda_j g_j(x) &= 0 \\ \nu \geq 0 \quad \lambda_j &\geq 0 \quad \forall j \end{aligned}$$

Potom

$$\begin{aligned} 0 &= \nu d^T \nabla f(x) + \sum_j \lambda_j d^T \nabla g_j(x) + \sum_j \lambda_j g_j(x) = \\ &= \nu d^T \nabla f(x) + \sum_j \lambda_j (g_j(x) + d^T \nabla g_j(x)) \leq (\nu + \sum_j \lambda_j) \delta. \end{aligned}$$

Jestliže v optimálním řešení je  $\delta < 0$ , potom vzhledem k  $(\nu, \lambda) \neq 0$  je  $0 = \dots < 0$ , spor.

$\Leftarrow$  Necht  $\min \delta = 0$ . Ukážeme nejprve, že úloha

$$\begin{aligned} d^T \nabla f(x) &< 0 \\ d^T \nabla g_j(x) &< 0, \quad j \in J = \{j; g_j(x) = 0\} \end{aligned}$$

nemá řešení. Kdyby měla, potom  $g_j(x) + \alpha d^T \nabla g_j(x) < 0 \quad \forall j \in J, \forall \alpha > 0$ , a lze volit  $\alpha \in (0, 1)$  tak, že  $g_j(x) + \alpha d^T \nabla g_j(x) < 0 \quad \forall j \notin J, \alpha d^T \nabla f(x) < 0$ , a platí  $|\alpha d_j| \leq |\alpha| \cdot |d_j| \leq |d_j| \leq 1$ , potom  $\min \delta < 0$ , spor. Tedy nemá řešení. Podle Jordanovy věty,  $Ax < b$  nemá řešení  $\Leftrightarrow (\exists y) (A^T y = 0, y \geq 0, y \neq 0 \ \& \ b^T y \leq 0)$  tedy  $Ax < 0$  nemá řešení  $\Leftrightarrow (\exists y) (A^T y = 0, y \geq 0, y \neq 0)$ . Jestliže tedy

$$\begin{pmatrix} \nabla^T f(x) \\ \nabla^T g_j(x) \end{pmatrix} d < 0, \quad j \in J$$

nemá řešení, potom existují  $\nu, \lambda_j, j \in J$ , že  $\nu \nabla f(x) + \sum_{j \in J} \lambda_j \nabla g_j(x) = 0, (\nu, \lambda) \geq 0, (\nu, \lambda) \neq 0$ . Doplňme  $\lambda_j = 0$  pro  $j \notin J$ , potom

$$\nu \nabla f(x) + \sum_j \lambda_j \nabla g_j(x) = 0$$

a  $\lambda_j > 0 \Rightarrow j \in J \Rightarrow g_j(x) = 0$ , tedy  $\lambda_j g_j(x) = 0 \quad \forall j$ , tj.  $\lambda^T g(x) = 0$ . Dále  $(\nu, \lambda) \geq 0, (\nu, \lambda) \neq 0$ . Tedy  $x$  je bodem Fr. Johna. ■

## 7.2.4 KTP pro LP

Uvažujme úlohu (LP)

$$\min\{c^T x; Ax = b, x \geq 0\}.$$

Potom (KTP) jsou:

$$\begin{aligned} \nabla(c^T x + \lambda^T(-x) + \mu^T(b - Ax)) &= 0 \\ \lambda^T x &= 0 \\ \lambda &\geq 0 \end{aligned}$$

tj.

$$\begin{aligned} c - \lambda - A^T \mu &= 0 \\ \lambda^T x &= 0 \\ \lambda &\geq 0 \end{aligned}$$

a eliminací  $\lambda$ :

$$\begin{aligned} A^T \mu &\leq c \\ x^T(c - A^T \mu) &= 0 \end{aligned}$$

čili  $\mu$  je duální proměnná a dostáváme obvyklé podmínky optimality (LP).