

Neexaktní lineární programování, lineární semi-infinitní programování – stručný přehled výsledků

Milan Hladík

Charles University, Faculty of Mathematics and Physics,
Malostranské nám. 25, 118 00, Prague, Czech Republic,
e-mail: milan.hladik@matfyz.cz.

28. června 2010

Abstrakt

Uvádíme zde stručný přehled výsledků (bez důkazů) z neexaktního lineárního programování a lineárního semi-infinitního programování. Jedná se o úlohy lineárního programování ve kterých vstupní data nejsou známa přesně, ale nabývají hodnot z daných množin. Některé typy úloh lze převést na obyčejnou úlohu lineárního programování. Uvádíme několik poznatků a referencí týkající se duality a podmínek optimality. Předkládáme základní myšlenky různých typů numerických metod řešení.

1 Úvod

V běžné úloze lineárního programování se předpokládá, že koeficienty v omezeních jsou pevně dány. V praxi se tento předpoklad nemusí vždy naplnit. “Nejistotě” ve vstupních datech se věnuje např. “fuzzy” programování, stochastické programování nebo analýza citlivosti (která poskytuje informaci o lokálním chování blízko předpokládaných hodnot koeficientů). V této práci se ale zabýváme situací, kdy koeficienty v omezeních úlohy sice neznáme přesně, ale víme, že náleží do nějakých předem známých množin. Takto zadanou úlohu nazveme úlohou *neexaktního lineárního programování*. Speciálně, představují-li dané množiny zobecněné intervaly (srovnej s (2.6)), potom se jedná o úlohu intervalové analýzy. Dalším speciálním typem úloh s nepřesnými daty jsou úlohy *lineárního semi-infinitního programování*, ve kterých se vyskytuje konečný počet proměnných, ale nekonečný počet lineárních omezení (viz úloha (XV)). Lineární semi-infinitní programování zaznamenalo za posledních několik desetiletí prudký vývoj a na toto téma bylo napsáno přes tisíc článků.

Historie neexaktního lineárního programování počíná v sedmdesátých letech dvacátého století. Mezi první práce na toto téma můžeme zařadit např. [12], [13], [14], [17].

Sekce 2 se věnuje nejjednodušším případům, kdy lze danou úlohu neexaktního programování výrazně zjednodušit, popřípadě převést na obyčejnou úlohu lineárního programování (podobnými tématy se zabývá “robustní optimalizace” – viz [1]). Uvádíme dualitní vztah mezi některými typy úloh. Čerpáme zejména z článků [11], [16].

Sekce 3 dává základní teoretické poznatky o lineárním semi-infinitním programování – zejména podmínky optimality, geometrické vlastnosti, dualitu. Více o podmínkách optimality

prvního a druhého řádu, geometrických vlastnostech, ale také o stabilitě, kvalifikacích omezení (které kvalifikují např. to, že daná podmínka je nutnou či postačující podmínkou optimality) viz [4], [5], [6], [7], [15].

Sekce 4 se zabývá numerickým řešením úloh lineárního semi-infinitního programování – viz např. [2], [3], [7], [8], [9], [15], [16], [18].

Dvě aplikace lineárního semi-infinitního programování z [7], [15] uvádíme v sekci 5.

Používáme následující značení:

Symbol	Význam
$\mathbf{0}$	vektor $(0, \dots, 0)^T$
$\mathbf{1}$	vektor $(1, \dots, 1)^T$
$\mathbf{A}_{i,\cdot}$	i -tý řádek matice \mathbf{A}
$\mathbf{A}_{\cdot,j}$	j -tý sloupec matice \mathbf{A}
$\mathbf{A} \geq \mathbf{B}$	nerovnost matic (a vektorů) složkách, tj. $\mathbf{A}_{ij} \geq \mathbf{B}_{ij} \forall i, j$
$\mathbf{A} \succeq 0$	matice \mathbf{A} je pozitivně semidefinitní
$\text{conv cone}(\mathcal{M})$	nejmenší konvexní kužel (s vrcholem v počátku) obsahující množinu \mathcal{M}
$\text{span}(\mathcal{M})$	lineární obal množiny \mathcal{M}
$\text{int } \mathcal{M}$	vnitřek množiny \mathcal{M}
$\text{rbd } \mathcal{M}$	relativní hranice množiny \mathcal{M}
$\text{cl } \mathcal{M}$	uzávěr množiny \mathcal{M}
\mathcal{M}^+	pozitivní polára množiny $\mathcal{M} \subset \mathbb{R}^n$, tj. $\mathcal{M}^+ = \{\mathbf{y} \in \mathbb{R}^n \mid \langle \mathbf{x}, \mathbf{y} \rangle \geq 0 \forall \mathbf{x} \in \mathcal{M}\}$
$v(P)$	optimální hodnota úlohy P

Připomeňme též, že úloha P se nazývá *nepřípustná*, pokud nemá přípustné řešení (tj. žádný bod nevyhovuje omezením úlohy).

2 Úlohy a dualita v neexaktním lineárním programování

2.1 Čtyři základní úlohy

Mějme dány neprázdné množiny $\mathcal{Q}_j \subset \mathbb{R}^m$, $j \in \{1, \dots, n\}$, a $\mathcal{P}_i \subset \mathbb{R}^n$, $i \in \{1, \dots, m\}$. Uvažujme následující čtyři třídy úloh neexaktního lineárního programování. V prvních dvou úlohách nějaký bod patří do množiny přípustných řešení, pokud splňuje omezení pro všechny realizace koeficientů (tzv. *konzervativní* či *pesimistický* přístup):

$$\max \{ \mathbf{c}^T \mathbf{x}; \mathbf{x} \in \mathcal{X}^I \}, \quad \mathcal{X}^I = \{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{i,\cdot} \in \mathcal{P}_i, i = 1, \dots, m \}, \quad (\text{I})$$

$$\max \{ \mathbf{c}^T \mathbf{x}; \mathbf{x} \in \mathcal{X}^{II} \}, \quad \mathcal{X}^{II} = \{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{\cdot,j} \in \mathcal{Q}_j, j = 1, \dots, n \}. \quad (\text{II})$$

V dalších dvou úlohách naopak nějaký bod patří do množiny přípustných řešení, pokud splňuje omezení pro alespoň jednu realizaci koeficientů (tzv. *optimistický* přístup):

$$\min \{ \mathbf{b}^T \mathbf{y}; \mathbf{y} \in \mathcal{Y}^I \}, \quad (\text{III})$$

kde

$$\mathcal{Y}^I = \{ \mathbf{y} \in \mathbb{R}^m \mid \mathbf{y} \geq \mathbf{0}, \mathbf{A}^T \mathbf{y} = \mathbf{c} \text{ pro nějaké } \mathbf{A}_{i,\cdot} \in \mathcal{P}_i, i = 1, \dots, m \}. \quad (2.1)$$

a

$$\min \{ \mathbf{b}^T \mathbf{y}; \mathbf{y} \in \mathcal{Y}^{II} \}, \quad (\text{IV})$$

kde

$$\mathcal{Y}^{II} = \{ \mathbf{y} \in \mathbb{R}^m \mid \mathbf{y} \geq \mathbf{0}, \mathbf{A}^T \mathbf{y} = \mathbf{c} \text{ pro nějaké } \mathbf{A}_{\cdot,j} \in \mathcal{Q}_j, j = 1, \dots, n \}. \quad (2.2)$$

Množiny přípustných řešení \mathcal{X}^I , \mathcal{X}^{II} jsou vždy konvexní. Podle [16] je množina \mathcal{Y}^I konvexní, jsou-li konvexní \mathcal{P}_i pro všechna $i \in \{1, \dots, m\}$. Množina \mathcal{Y}^{II} není obecně konvexní i když jsou všechny množiny \mathcal{Q}_j , $j \in \{1, \dots, n\}$, konvexní (protipříklad viz [16]).

2.1.1 Úloha (I)

Úloha (I) je speciálním typem úlohy lineárního semi-infinitního programování, kterým se zabýváme v sekci 3. Proto poznatky uvedené v sekci 3 platí také i pro úlohu (I).

Definice 2.1

Úlohu

$$\max \{ \mathbf{c}^T \mathbf{x}; \mathbf{a}_i^T \mathbf{x} \leq b_i \forall i = 1, \dots, m \},$$

kde $\mathbf{a}_i \in \mathcal{P}_i$, $i \in \{1, \dots, m\}$ jsou pevné vektory, nazveme *instancí* problému (I).

Platí následující tvrzení z [1], které dává do souvislosti přípustnost úlohy (I) (tj. neprázdnot množiny \mathcal{X}^I) s přípustností jejích instancí. Poznamenejme, že bez uvedených předpokladů tvrzení 2.2 výroky (1), (2) obecně neplatí.

Tvrzení 2.2

Nechť existuje konvexní kompaktní množina $\mathcal{P} \subset \mathbb{R}^n$ obsahující všechna přípustná řešení všech instancí problému (I). Potom

- (1) *Úloha (I) je nepřípustná právě tehdy, když je nepřípustná nějaká instance úlohy (I).*
- (2) *Je-li úloha (I) přípustná a v^* její optimální hodnota, potom v^* je rovno supremu optimálních hodnot všech instancí.* □

2.1.2 Zjednodušení úlohy (II)

Ukážeme si, jak zjednodušit popis množiny \mathcal{X}^{II} z (II) (pro ostatní úlohy tento postup obecně nelze použít). Předpokládejme, že množiny \mathcal{Q}_j , $j \in \{1, \dots, n\}$, jsou omezné. Definujme

$$\bar{a}_{ij} = \sup \{ a_{ij}; (a_{1j}, \dots, a_{mj})^T \in \mathcal{Q}_j \}, \quad \underline{a}_{ij} = \inf \{ a_{ij}; (a_{1j}, \dots, a_{mj})^T \in \mathcal{Q}_j \} \quad (2.3)$$

a matice

$$\bar{\mathbf{A}} = (\bar{a}_{ij}) \in \mathbb{R}^{m \times n}, \quad \underline{\mathbf{A}} = (\underline{a}_{ij}) \in \mathbb{R}^{m \times n}. \quad (2.4)$$

Pokud \mathcal{Q}_j , $j \in \{1, \dots, n\}$, představují konvexní polyedry, potom výpočet extrémálních hodnot \underline{a}_{ij} , \bar{a}_{ij} podle (2.3) představuje řešení úloh lineárního programování o počtu $2mn$. Pokud množiny \mathcal{Q}_j , $j \in \{1, \dots, n\}$, představují nadkoule v prostoru \mathbb{R}^m , potom extrémální hodnoty \underline{a}_{ij} , \bar{a}_{ij} můžeme určit snadno a dokonce vyjádřit explicitně. Nechť \mathcal{Q}_j , $j \in \{1, \dots, n\}$, představují nadkoule s popisem $\mathcal{Q}_j = \{ \mathbf{a} \in \mathbb{R}^m \mid \|\mathbf{a} - \mathbf{s}_j\| \leq r_j \}$, $j \in \{1, \dots, n\}$, kde $\mathbf{s}_j \in \mathbb{R}^m$ jsou jejich středy a $r_j \geq 0$ jejich poloměry. Potom $\bar{\mathbf{A}}_{\cdot,j} = \mathbf{s}_j + r_j \mathbf{1}$, $\underline{\mathbf{A}}_{\cdot,j} = \mathbf{s}_j - r_j \mathbf{1}$. Následující jednoduché tvrzení z [16] říká, že množiny \mathcal{Q}_j z (II) lze nahradit množinami

$$\hat{\mathcal{Q}}_j = \{ \mathbf{a} \in \mathbb{R}^m \mid \underline{\mathbf{A}}_{\cdot,j} \leq \mathbf{a} \leq \bar{\mathbf{A}}_{\cdot,j} \}. \quad (2.5)$$

Tvrzení 2.3

Nechť množiny \mathcal{Q}_j , $j \in \{1, \dots, n\}$, z (II) jsou omezené. Potom platí

$$\mathcal{X}^{II} = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{\cdot,j} \in \hat{\mathcal{Q}}_j, j = 1, \dots, n\}.$$

□

Dle tvrzení 2.3 lze tedy množinu \mathcal{X}^{II} přepsat do tvaru

$$\mathcal{X}^{II} = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \leq \mathbf{b} \forall \mathbf{A} \in \mathbb{R}^{m \times n} : \underline{\mathbf{A}} \leq \mathbf{A} \leq \overline{\mathbf{A}}\}. \quad (2.6)$$

Množiny $\hat{\mathcal{Q}}_j$, $j \in \{1, \dots, n\}$, z (2.5) představují zobecněné intervaly v prostoru \mathbb{R}^m a tudíž (viz též [16], [17]) je úloha (II) ekvivalentní s obyčejnou úlohou lineárního programování

$$\max \{\mathbf{c}^T \mathbf{x}^+ - \mathbf{c}^T \mathbf{x}^-; (\mathbf{x}^+, \mathbf{x}^-) \in \mathcal{X}_{\pm}\},$$

kde

$$\mathcal{X}_{\pm} = \{(\mathbf{x}^+, \mathbf{x}^-) \in \mathbb{R}^{2n} \mid \overline{\mathbf{A}}\mathbf{x}^+ - \underline{\mathbf{A}}\mathbf{x}^- \leq \mathbf{b}, \mathbf{x}^+ \geq \mathbf{0}, \mathbf{x}^- \geq \mathbf{0}\}.$$

2.1.3 Převody mezi úlohami (I)–(IV)

Nyní se podívejme, jaký je vztah mezi úlohami (I), (II) a mezi úlohami (III), (IV). Nejprve ukážeme, jak můžeme převést úlohu (II) na úlohu (I). Víme, že za předpokladu omezenosti množin \mathcal{Q}_j , $j \in \{1, \dots, n\}$, můžeme množinu přípustných řešení úlohy (II) zapsat ve tvaru (2.6). Definujme

$$\mathcal{P}_i \equiv \{\mathbf{a} \in \mathbb{R}^n \mid \underline{\mathbf{A}}_{i,\cdot} \leq \mathbf{a} \leq \overline{\mathbf{A}}_{i,\cdot}\}, \quad i \in \{1, \dots, m\}. \quad (2.7)$$

Potom $\mathcal{X}^I = \mathcal{X}^{II}$, čímž jsme převedli úlohu (II) na úlohu (I). Pokud \mathcal{Q}_j , $j \in \{1, \dots, n\}$, představují zobecněné intervaly i v (2.2), lze analogicky převést i úlohu (IV) na úlohu (III) (neboť $\mathcal{Y}^I = \mathcal{Y}^{II}$). Za předpokladu, že množiny \mathcal{P}_i , $i \in \{1, \dots, m\}$, představují zobecněné intervaly, tj. jsou tvaru (2.7) pro nějaké matice $\underline{\mathbf{A}}, \overline{\mathbf{A}} \in \mathbb{R}^{m \times n}$, potom lze obdobně převést úlohu (I) na úlohu (II) a úlohu (III) na úlohu (IV). Obecně ale takovéto převody (“nejistotu” danou v řádcích na “nejistotu” ve sloupcích a naopak) provádět nemůžeme (viz [16]).

2.1.4 Zjednodušení úlohy (III)

Nyní se zabývejme zjednodušením úlohy (III). Nechť \mathcal{P}_i , $i \in \{1, \dots, m\}$, jsou omezené konvexní polyedry s vrcholy $\mathbf{a}_i^1, \dots, \mathbf{a}_i^{v_i}$. Potom úloha (III) je ekvivalentní s úlohou (viz [17]):

$$\min \left\{ \sum_{i=1}^m b_i \sum_{j=1}^{v_i} y_i^j; \sum_{i=1}^m \sum_{j=1}^{v_i} y_i^j \mathbf{a}_i^j = \mathbf{c}, y_i^j \geq 0 \forall i, j \right\}. \quad (V)$$

Je-li \tilde{y}_i^j , $i \in \{1, \dots, m\}$, $j \in \{1, \dots, v_i\}$, optimální řešení úlohy (V), potom $\tilde{y}_i = \sum_{j=1}^{v_i} \tilde{y}_i^j$ je optimální řešení (III) s volbou $\tilde{\mathbf{a}}_i \in \mathcal{P}_i$, pro kterou platí:

$$\tilde{\mathbf{a}}_i = \begin{cases} \sum_{j=1}^{v_i} \frac{\tilde{y}_i^j}{\tilde{y}_i} \mathbf{a}_i^j, & \tilde{y}_i \neq 0, \\ \text{libovolné } \mathbf{a}_i \in \mathcal{P}_i, & \tilde{y}_i = 0. \end{cases}$$

Úloha (V) je obyčejnou úlohou lineárního programování, ale s velkým počtem proměnných (je jich $\sum_{i=1}^m v_i$). Pokud množiny \mathcal{P}_i , $i \in \{1, \dots, m\}$, jsou tvaru (2.7), potom lze úlohu (III) ještě více zjednodušit, neboť množinu \mathcal{Y}^I lze přepsat do tvaru (viz např. [10])

$$\mathcal{Y}^I = \{\mathbf{y} \in \mathbb{R}^m \mid \underline{\mathbf{A}}^T \mathbf{y} \leq \mathbf{c} \leq \overline{\mathbf{A}}^T \mathbf{y}, \mathbf{y} \geq \mathbf{0}\}.$$

Poznámka 2.4

Analogickou úvahu jako pro úlohu (III) lze provést i pro následující varianty úlohy (III)

$$\min \{ \mathbf{b}^T \mathbf{y}; \mathbf{y} \geq \mathbf{0}, \mathbf{A}^T \mathbf{y} \leq \mathbf{c} \text{ pro nějaké } \mathbf{A}_{i\cdot} \in \mathcal{P}_i, i = 1, \dots, m \}, \quad (\text{VI})$$

$$\min \{ \mathbf{b}^T \mathbf{y}; \mathbf{A}^T \mathbf{y} \leq \mathbf{c} \text{ pro nějaké } \mathbf{A}_{i\cdot} \in \mathcal{P}_i, i = 1, \dots, m \}. \quad (\text{VII})$$

Nechť $\mathcal{P}_i, i \in \{1, \dots, m\}$, jsou omezené konvexní polyedry s vrcholy $\mathbf{a}_i^1, \dots, \mathbf{a}_i^{v_i}$. Potom úloha (VI) je ekvivalentní s úlohou

$$\min \left\{ \sum_{i=1}^m b_i \sum_{j=1}^{v_i} y_i^j; \sum_{i=1}^m \sum_{j=1}^{v_i} y_i^j \mathbf{a}_i^j \leq \mathbf{c}, y_i^j \geq 0 \forall i, j \right\},$$

a úloha (VII) je ekvivalentní s úlohou

$$\min \left\{ \sum_{i=1}^m b_i \sum_{j=1}^{v_i} y_i^j; \sum_{i=1}^m \sum_{j=1}^{v_i} y_i^j \mathbf{a}_i^j \leq \mathbf{c} \forall i, j \right\}.$$

Pokud množiny $\mathcal{P}_i, i \in \{1, \dots, m\}$, jsou tvaru (2.7), potom lze úlohu (VI) snadno zjednodušit na tvar

$$\min \{ \mathbf{b}^T \mathbf{y}; \mathbf{y} \geq \mathbf{0}, \underline{\mathbf{A}}^T \mathbf{y} \leq \mathbf{c} \}.$$

Úlohu (VII) nelze za stejného předpokladu výrazně zjednodušit, neboť je to NP-těžký problém.

2.2 Další úlohy

A. Uvažujme úlohu z [16]:

$$\max_{\mathbf{x} \in \mathcal{X}} \min_{\mathbf{c} \in \mathcal{C}} \mathbf{c}^T \mathbf{x}, \quad \mathcal{X} = \{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{A} \mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{i\cdot} \in \mathcal{P}_i, i = 1, \dots, m \}, \quad (\text{VIII})$$

kde $\mathcal{C} \subset \mathbb{R}^n$ je kompaktní konvexní množina. Jedná se o zobecnění úlohy (I), neboť zde navíc uvažujeme “nejistotu” i ve vektoru cílové funkce. Zajímá nás nejlepší (maximální) hodnota cílové funkce pro nejhorší možnou realizaci vektoru $\mathbf{c} \in \mathcal{C}$. Zavedením nové proměnné x_{n+1} můžeme úlohu (VIII) přepsat na

$$\max \{ x_{n+1}; \mathbf{A} \mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{i\cdot} \in \mathcal{P}_i, i = 1, \dots, m, \mathbf{c}^T \mathbf{x} - x_{n+1} \geq 0 \forall \mathbf{c} \in \mathcal{C} \},$$

což je speciální typ úlohy (I).

B. Uvažujme úlohu z [16]:

$$\max \{ \mathbf{c}^T \mathbf{x}; \mathbf{x} \in \mathcal{X} \}, \quad \mathcal{X} = \{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{A} \mathbf{x} \leq \mathbf{b} \forall \mathbf{A} \in \mathcal{M} \}, \quad (\text{IX})$$

kde $\mathcal{M} \subset \mathbb{R}^{m \times n}$ je kompaktní množina matic, $\mathbf{c} \in \mathbb{R}^n, \mathbf{b} \in \mathbb{R}^m$. Také tento problém lze převést na úlohu (I). Stačí definovat $\mathcal{P}_i \equiv \{ \mathbf{A}_{i\cdot} \in \mathbb{R}^n \mid \mathbf{A} \in \mathcal{M} \}, i \in \{1, \dots, m\}$.

C. Uvažujme speciální typ úlohy (II) s přidáním podmínkami nezápornosti proměnných (viz [11], [17]):

$$\max \{ \mathbf{c}^T \mathbf{x}; \mathbf{x} \in \mathcal{X}_0 \}, \quad \mathcal{X}_0 = \{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{x} \geq \mathbf{0}, \mathbf{A} \mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{\cdot j} \in \mathcal{Q}_j, j = 1, \dots, n \}. \quad (\text{X})$$

Díky nezápornosti proměnných lze množinu přípustných řešení \mathcal{X}_0 přepsat do tvaru (srovnej s (2.6)):

$$\mathcal{X}_0 = \{\mathbf{x} \in \mathbb{R}^n \mid \overline{\mathbf{A}}\mathbf{x} \leq \mathbf{b}, \mathbf{x} \geq \mathbf{0}\},$$

kde matice $\overline{\mathbf{A}}$ je definována stejně jako v (2.4). V tomto případě můžeme úlohu zobecnit i na případ, kdy množiny \mathcal{Q}_j , $j \in \{1, \dots, n\}$, nejsou nutně omezené. Dostaneme-li $\overline{a}_{ij} = \infty$ pro nějaké i, j , potom musí nutně proměnná $x_j = 0$.

D. Uvažujme úlohu (viz [11]):

$$\min \{\mathbf{b}^T \mathbf{y}; \mathbf{y} \in \mathcal{Y}_0\}, \quad (\text{XI})$$

kde

$$\mathcal{Y}_0 = \{\mathbf{y} \in \mathbb{R}^m \mid \mathbf{y} \geq \mathbf{0}, \mathbf{A}^T \mathbf{y} \geq \mathbf{c} \text{ pro nějaké } \mathbf{A}_{\cdot,j} \in \mathcal{Q}_j, j = 1, \dots, n\}.$$

Jedná se o speciální typ úlohy (IV), neboť stačí zavést doplňkové proměnné do nerovnic $\mathbf{A}^T \mathbf{y} \geq \mathbf{c}$. Předpokládejme, že množiny \mathcal{Q}_j , $j \in \{1, \dots, n\}$, jsou konvexní a tzv. “directed to the right”, to znamená $\forall \mathbf{a}^1, \mathbf{a}^2 \in \mathcal{Q}_j$ existuje $\mathbf{a}^0 \in \mathcal{Q}_j$ takové, že $\mathbf{a}^1 \leq \mathbf{a}^0$, $\mathbf{a}^2 \leq \mathbf{a}^0$. Potom množinu přípustných řešení \mathcal{Y}_0 lze přepsat do tvaru

$$\mathcal{Y}_0 = \{\mathbf{y} \in \mathbb{R}^m \mid \overline{\mathbf{A}}^T \mathbf{y} \geq \mathbf{c}, \mathbf{y} \geq \mathbf{0}\},$$

kde matice $\overline{\mathbf{A}}$ je definována stejně jako v (2.4). Potom je také zřejmé, že úlohy (X), (XI) jsou navzájem duální.

E. Uvažujme dle [11] následující zobecnění úlohy (II), kde množina přípustných řešení je tvaru

$$\mathcal{X}_D^{II} = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \in \mathcal{Q}(\mathbf{D}, \mathbf{b}) \forall \mathbf{A}_{\cdot,j} \in \mathcal{Q}_j, j = 1, \dots, n\}, \quad (\text{XII})$$

přičemž $\mathcal{Q}(\mathbf{D}, \mathbf{b})$ je konvexní polyedr s popisem ($\mathbf{D} \in \mathbb{R}^{l \times m}$, $\mathbf{b} \in \mathbb{R}^l$):

$$\mathcal{Q}(\mathbf{D}, \mathbf{b}) = \{\mathbf{z} \in \mathbb{R}^m \mid \mathbf{D}\mathbf{z} \leq \mathbf{b}\}.$$

Bod \mathbf{x} náleží do \mathcal{X}_D^{II} právě tehdy, když splňuje nerovnost

$$\mathbf{D}\mathbf{A}\mathbf{x} \leq \mathbf{b} \quad \forall \mathbf{A}_{\cdot,j} \in \mathcal{Q}_j, j = 1, \dots, n.$$

Označme $\mathcal{Q}_j^D = \{\mathbf{D}\mathbf{a} \in \mathbb{R}^l \mid \mathbf{a} \in \mathcal{Q}_j\}$, $j \in \{1, \dots, n\}$. Takto jsme úlohu (XII) převedli na úlohu (II) s popisem množiny přípustných řešení

$$\mathcal{X}_D^{II} = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \leq \mathbf{b} \forall \mathbf{A}_{\cdot,j} \in \mathcal{Q}_j^D, j = 1, \dots, n\}.$$

F. Uvažujme dle [1] speciální typ úlohy (I), kde \mathcal{P}_i jsou tzv. *elipsoidy* s popisem

$$\mathcal{P}_i = \{\mathbf{r}_i + \mathbf{R}_i \mathbf{u}; \|\mathbf{u}\| \leq 1\}, \quad i = 1, \dots, m$$

pro určité vektory $\mathbf{r}_i \in \mathbb{R}^n$ a matice $\mathbf{R}_i \in \mathbb{R}^{n \times k}$, $i \in \{1, \dots, m\}$. Bod $\mathbf{x} \in \mathbb{R}^n$ je pak přípustný právě tehdy, když pro všechna $i \in \{1, \dots, m\}$ platí

$$b_i \geq \max \{\mathbf{r}_i^T \mathbf{x} + \mathbf{u}^T \mathbf{R}_i^T \mathbf{x}; \|\mathbf{u}\| \leq 1\} = \mathbf{r}_i^T \mathbf{x} + \|\mathbf{R}_i^T \mathbf{x}\|.$$

Úloha (I) potom přejde v úlohu

$$\max \{\mathbf{c}^T \mathbf{x}; \mathbf{r}_i^T \mathbf{x} + \|\mathbf{R}_i^T \mathbf{x}\| \leq b_i \quad i = 1, \dots, m\},$$

což je tzv. *kuželová kvadratická* úloha s konečně mnoha omezeními. Tuto úlohu lze řešit v polynomiálním čase tzv. metodou vnitřních bodů. Poznamenejme, že do této podoby lze přepsat i úlohu (I), kde \mathcal{P}_i jsou omezené konvexní polyedry resp. úlohu (IX), kde \mathcal{M} je omezený konvexní polyedr.

2.3 Dualita mezi úlohami (I) a (III)

Budeme se zabývat dualitou mezi úlohami (I) a (III). Opět poznamenejme, že úlohy (I), (III) jsou speciálním typem úloh lineárního semi-infinitního programování (XV), (XVI). Tudiž poznatky uvedené v sekci 3.2 platí i pro úlohy (I), (III). Předpokládejme, že množiny \mathcal{P}_i , $i \in \{1, \dots, m\}$, jsou kompaktní. Definujme následující konvexní kužely s vrcholy v počátku (tzv. první a druhý momentový kužel množiny \mathcal{X}^I)

$$\mathcal{M}_n = \text{conv cone} \left(\bigcup_{i=1}^m \mathcal{P}_i \right), \quad (2.8)$$

$$\mathcal{M}_{n+1} = \text{conv cone} \left(\bigcup_{i=1}^m \left\{ \begin{pmatrix} \mathbf{a}_i \\ b_i \end{pmatrix} \mid \mathbf{a}_i \in \mathcal{P}_i \right\} \right). \quad (2.9)$$

Následující věta o dualitě je převzata z [16].

Věta 2.5

- (1) *Buď \mathcal{M}_{n+1} uzavřená množina. Pokud má úloha (I) optimální řešení nebo úloha (III) je přípustná a $v(\text{III}) > -\infty$, potom úloha (III) má optimální řešení a $v(\text{I}) = v(\text{III})$.*
- (2) *Nechť $\mathbf{c} \in \text{int } \mathcal{M}_n$ a nechť úloha (I) je přípustná. Potom úloha (I) má optimální řešení a $v(\text{I}) = v(\text{III})$. \square*

Postačující podmínky pro uzavřenost \mathcal{M}_{n+1} jsou např. následující dvě:

- Slaterova podmínka, tj. existuje $\mathbf{x}^0 \in \mathbb{R}^n$ takové, že $\mathbf{A}\mathbf{x}^0 < \mathbf{b} \forall \mathbf{A}_{i \cdot} \in \mathcal{P}_i$, $i = 1, \dots, m$.
- existuje konečná podmnožina \mathcal{S} množiny $\bigcup_{i=1}^m \left\{ \begin{pmatrix} \mathbf{a}_i \\ b_i \end{pmatrix} \mid \mathbf{a}_i \in \mathcal{P}_i \right\}$, pro níž platí $\mathcal{M}_{n+1} = \text{conv cone}(\mathcal{S})$.

Následující důsledek udává postačující podmínky pro silnou dualitu úloh (I), (III).

Důsledek 2.6

- (1) *Nechť $\mathbf{c} > \mathbf{0}$ a přípustná množina úlohy (I) je omezená. Potom úlohy (I), (III) mají optimální řešení a $v(\text{I}) = v(\text{III})$.*
- (2) *Nechť \mathcal{P}_i , $i \in \{1, \dots, m\}$, jsou konvexní polyedry. Má-li jedna z úloh (I), (III) optimální řešení, potom i druhá má optimální řešení a $v(\text{I}) = v(\text{III})$. \square*

Dle [17] platí navíc: Jsou-li \mathcal{P}_i , $i \in \{1, \dots, m\}$, konvexní polyedry a jedna z úloh (I), (III) je neomezená, potom druhá je nepřípustná.

2.4 Dualita mezi úlohami (XIII) a (XIV)

Buď $\mathcal{C} \subset \mathbb{R}^n$ neprázdná uzavřená konvexní množina. Uvažujme následující úlohy (viz [13], [14]):

$$\max_{\mathbf{x} \in \mathcal{X}} \min_{\mathbf{c} \in \mathcal{C}} \mathbf{c}^T \mathbf{x}, \quad \mathcal{X} = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} \leq \mathbf{b}, \mathbf{x} \geq \mathbf{0}\}, \quad (\text{XIII})$$

$$\min \{\mathbf{b}^T \mathbf{y}; \mathbf{A}^T \mathbf{y} = \mathbf{w}, \mathbf{y} \geq \mathbf{0} \text{ pro nějaké } \mathbf{w} \in \mathcal{C}\}, \quad (\text{XIV})$$

kde $\mathbf{A} \in \mathbb{R}^{m \times n}$, $\mathbf{b} \in \mathbb{R}^m$. Pro úlohy (XIII), (XIV) platí následující věta o dualitě převzatá z [13], [14].

Věta 2.7

- (1) Jsou-li úlohy (XIII), (XIV) přípustné, pak $v(\text{XIV}) \geq v(\text{XIII})$.
- (2) Je-li $v(\text{XIII}) > -\infty$, potom úloha (XIV) má optimální řešení a $v(\text{XIV}) = v(\text{XIII})$.
- (3) Je-li \mathbf{x}^* optimální řešení úlohy (XIII) a $(\mathbf{y}^*, \mathbf{w}^*)$ optimální řešení úlohy (XIV), potom platí podmínka komplementarity $(\mathbf{A}\mathbf{x}^* - \mathbf{b})^T \mathbf{y}^* = 0$.
- (4) Je-li $(\mathbf{y}^*, \mathbf{w}^*)$ optimální řešení úlohy (XIV), potom existuje nějaké optimální řešení úlohy $\max \{ \mathbf{w}^{*T} \mathbf{x}; \mathbf{x} \in \mathcal{X} \}$, které je optimálním řešením úlohy (XIII). \square

3 Lineární semi-infinitní programování

Úlohou lineárního semi-infinitního programování rozumíme úlohu:

$$\inf \{ \mathbf{c}^T \mathbf{x}; \mathbf{x} \in \mathcal{X} \}, \quad \mathcal{X} = \{ \mathbf{x} \in \mathbb{R}^n \mid \mathbf{a}_t^T \mathbf{x} \geq b_t \ \forall t \in \mathcal{T} \}. \quad (\text{XV})$$

K úloze (XV) uvažujeme duální (tzv. *Haarovu*) úlohu ve tvaru

$$\sup \{ \mathbf{b}^T \boldsymbol{\lambda}; \boldsymbol{\lambda} \in \mathcal{Y} \}, \quad \mathcal{Y} = \left\{ \boldsymbol{\lambda} \in \mathbb{R}_+^{|\mathcal{T}|} \mid \sum_{t \in \mathcal{T}} \lambda_t \mathbf{a}_t = \mathbf{c} \right\}, \quad (\text{XVI})$$

kde $\mathbf{c} \in \mathbb{R}^n$, $\mathbf{a} : \mathcal{T} \mapsto \mathbb{R}^n$, $\mathbf{b} : \mathcal{T} \mapsto \mathbb{R}$ a $\mathcal{T} \subset \mathbb{R}^m$ kompaktní (obecně nekonečná) množina. Symbol $\mathbb{R}_+^{|\mathcal{T}|}$ z (XVI) značí množinu funkcí $\boldsymbol{\lambda} : \mathcal{T} \mapsto \mathbb{R}_+$, které jsou nenulové (tj. kladné) jen pro konečný počet prvků z \mathcal{T} (potom je výraz $\mathbf{b}^T \boldsymbol{\lambda} = \sum_{t \in \mathcal{T}} b_t \lambda_t$ dobře definovaný, neboť sčítáme přes konečný počet prvků).

Definice 3.1

Nerovnice $\mathbf{a}^T \mathbf{x} \geq b$ se nazývá *lineární důsledek* množiny \mathcal{X} , jestliže je splněna pro všechna $\mathbf{x} \in \mathcal{X}$. Množina \mathcal{X} se nazývá *lokálně Farkas–Minkowská (LFM)*, jestliže každý lineární důsledek \mathcal{X} , určující opěrnou nadrovinu \mathcal{X} , je zároveň lineárním důsledkem nějakého konečného pod systému \mathcal{X} . Dále označme jako $A(\mathbf{x}) = \text{conv cone} \{ \mathbf{a}_t \in \mathbb{R}^n \mid \mathbf{a}_t^T \mathbf{x} = b_t \}$ tzv. *aktivní kužel*.

Platí následující věta z [6]. Podmínka (2) věty je Karush–Kuhn–Tuckerova podmínka (KKT), podmínka (4) je podmínkou na sedlový bod lagrangeovy funkce $L(\mathbf{x}, \boldsymbol{\lambda}) = \mathbf{c}^T \mathbf{x} + \sum_{t \in \mathcal{T}} \lambda_t (b_t - \mathbf{a}_t^T \mathbf{x})$. Poznamenejme, že existuje mnoho variant KKT-podmínek za platnosti různých kvalifikačních podmínek omezení (např. viz [15]), pro ilustraci uvádíme jen jednu.

Věta 3.2

Nechť \mathcal{X} je (LFM) a nechť $\mathbf{x}^* \in \mathcal{X}$. Potom následující podmínky jsou ekvivalentní

- (1) \mathbf{x}^* je optimálním řešením úlohy (XV);
- (2) $\mathbf{c} \in A(\mathbf{x}^*)$;
- (3) existuje $\boldsymbol{\lambda}^* \in \mathcal{Y}$ takové, že $\lambda_t^* (\mathbf{a}_t^T \mathbf{x}^* - b_t) = 0 \ \forall t \in \mathcal{T}$;
- (4) existuje $\boldsymbol{\lambda}^* \in \mathbb{R}_+^{|\mathcal{T}|}$ takové, že $L(\mathbf{x}^*, \boldsymbol{\lambda}) \leq L(\mathbf{x}^*, \boldsymbol{\lambda}^*) \leq L(\mathbf{x}, \boldsymbol{\lambda}^*)$ pro všechna $\mathbf{x} \in \mathbb{R}^n$ a $\boldsymbol{\lambda} \in \mathbb{R}_+^{|\mathcal{T}|}$. \square

3.1 Geometrické vlastnosti množiny \mathcal{X}

V této sekci uvádíme mj. podmínky, za kterých je množina \mathcal{X} omezená, neprázdná, podmínky určující krajní bod \mathcal{X} .

Je-li množina $\mathcal{T} \subset \mathbb{R}^m$, potom je \mathcal{X} vždy uzavřená a konvexní množina (viz [5], [15]). Tvrzení platí i naopak. Každá uzavřená konvexní množina může být reprezentována ve formě \mathcal{X} pro určité $\mathbf{a} : \mathcal{T} \mapsto \mathbb{R}^n$, $b : \mathcal{T} \mapsto \mathbb{R}$ a $\mathcal{T} \subset \mathbb{R}^m$.

Označme tzv. *referenční kužel* k množině \mathcal{X} jako

$$\mathcal{K} = \text{conv cone}\left(\left\{\begin{pmatrix} \mathbf{a}_t \\ b_t \end{pmatrix} \mid t \in \mathcal{T}\right\} \cup \left\{\begin{pmatrix} \mathbf{0} \\ -1 \end{pmatrix}\right\}\right). \quad (3.1)$$

Potom dle [6] platí (je-li $\mathcal{X} \neq \emptyset$), že $\mathbf{a}^T \mathbf{x} \geq b$ je lineární důsledek \mathcal{X} právě tehdy, když $\begin{pmatrix} \mathbf{a} \\ b \end{pmatrix} \in \text{cl } \mathcal{K}$. Množina \mathcal{X} představuje konvexní polyedr právě tehdy, když $\text{cl } \mathcal{K}$ představuje konvexní polyedrický kužel. Následující věta z [4] uvádí ekvivalentní podmínku omezenosti množiny \mathcal{X} .

Věta 3.3

Následující tvrzení jsou ekvivalentní:

- (1) Množina \mathcal{X} je omezená;
- (2) $\{\mathbf{a}_t^T \mathbf{x} \geq 0 \mid t \in \mathcal{T}\} = \{\mathbf{0}\}$;
- (3) $\mathcal{M}_n = \mathbb{R}^n$;
- (4) $\begin{pmatrix} \mathbf{0} \\ -1 \end{pmatrix} \in \text{int } \mathcal{K}$;
- (5) existuje konečná $\mathcal{T}' \subset \mathcal{T}$ taková, že $\mathcal{X}(\mathcal{T}')$ je omezená množina. □

Definujme analogicky jako v (2.8) tzv. *první a druhý momentový kužel* pro úlohu (XV):

$$\mathcal{M}_n = \text{conv cone}\{\mathbf{a}_t \mid t \in \mathcal{T}\}, \quad (3.2)$$

$$\mathcal{M}_{n+1} = \text{conv cone}\left\{\begin{pmatrix} \mathbf{a}_t \\ b_t \end{pmatrix} \mid t \in \mathcal{T}\right\} \quad (3.3)$$

Z definice množiny \mathcal{Y} přímo plyne, že $\mathcal{Y} \neq \emptyset \Leftrightarrow \mathbf{c} \in \mathcal{M}_n$. Následující věta 3.4 z [5] udává zase ekvivalentní podmínky přípustnosti úlohy (XV). Pro $\mathcal{T}' \subset \mathcal{T}$ značíme symbolem $\text{XV}(\mathcal{T}')$ úlohu (XV) s indexovou množinou \mathcal{T}' a symbolem $\mathcal{X}(\mathcal{T}')$ množinu přípustných řešení této úlohy.

Věta 3.4

Následující tvrzení jsou ekvivalentní:

- (1) $\mathcal{X} \neq \emptyset$;
- (2) $\begin{pmatrix} \mathbf{0} \\ 1 \end{pmatrix} \notin \text{cl } \mathcal{M}_{n+1}$;
- (3) $\begin{pmatrix} \mathbf{0} \\ 1 \end{pmatrix} \notin \text{cl } \mathcal{K}$;
- (4) Pro každou spočetnou množinu $\mathcal{T}' \subset \mathcal{T}$ je $\mathcal{X}(\mathcal{T}') \neq \emptyset$;
- (5) existuje kompaktní množina, která má neprázdný průnik s každým systémem $\mathcal{X}(\mathcal{T}')$ pro všechny konečné $\mathcal{T}' \subset \mathcal{T}$. □

Definice 3.5

Označme $D(\mathcal{X}, \mathbf{x}) = \{\mathbf{d} \in \mathbb{R}^n \mid \exists \varepsilon > 0, \mathbf{x} + \varepsilon \mathbf{d} \in \mathcal{X}\}$ množinu *přípustných směrů* z bodu \mathbf{x} . Množina \mathcal{X} se nazývá *lokálně polyedrická*, pokud $A(\mathbf{x})^+ = D(\mathcal{X}, \mathbf{x})$ pro všechna $\mathbf{x} \in \mathcal{X}$. Označme $L(\mathbf{x}) = \text{span}\{\mathbf{a}_t \in \mathbb{R}^n \mid \mathbf{a}_t^T \mathbf{x} = b_t, t \in \mathcal{T}\}$.

Platí následující věta z [6], která charakterizuje krajní bod množiny \mathcal{X} z úlohy (XV) a krajní bod množiny \mathcal{Y} z úlohy (XVI).

Věta 3.6

- (1) *Je-li \mathcal{X} lokálně polyedrická množina, potom bod $\mathbf{x} \in \mathcal{X}$ je krajní bod \mathcal{X} právě tehdy, když $L(\mathbf{x}) = \mathbb{R}^n$.*
- (2) *Bod $\boldsymbol{\lambda} \in \mathcal{Y}$ je krajní bod \mathcal{Y} právě tehdy, když vektory $\{\mathbf{a}_t \mid \lambda_t > 0\}$ jsou lineárně nezávislé.* □

3.2 Dualita

Tato sekce se zabývá dualitou úloh (XV), (XVI) lineárního semi-infinitního programování. Nejprve si ukážeme, jak spočítat optimální hodnotu úlohy (XV) resp. (XVI) pomocí kužele \mathcal{K} resp. \mathcal{M}_{n+1} z (3.1) resp. (3.3). Platí následující rovnost (viz [6])

$$v(\text{XV}) = \max \left\{ \alpha \in \mathbb{R}; \begin{pmatrix} \mathbf{c} \\ \alpha \end{pmatrix} \in cl \mathcal{K} \right\}.$$

Pro hodnotu duální úlohy (XVI) podle [7] platí:

$$\begin{aligned} v(\text{XVI}) &= \max \left\{ \alpha \in \mathbb{R}; \begin{pmatrix} \mathbf{c} \\ \alpha \end{pmatrix} \in \mathcal{M}_{n+1} \right\} \\ &= \max \left\{ \alpha \in \mathbb{R}; \begin{pmatrix} \mathbf{c} \\ \alpha \end{pmatrix} \in \mathcal{K} \right\}. \end{aligned}$$

Věty 3.7 a 3.8 čerpáme z [15].

Věta 3.7 (slabá dualita)

Nechť $\mathbf{x} \in \mathcal{X}$, $\boldsymbol{\lambda} \in \mathcal{Y}$. Potom platí $\mathbf{c}^T \mathbf{x} \geq \mathbf{b}^T \boldsymbol{\lambda}$. Je-li $\mathbf{c}^T \mathbf{x} = \mathbf{b}^T \boldsymbol{\lambda}$, potom \mathbf{x} resp. $\boldsymbol{\lambda}$ je optimální řešení úlohy (XV) resp. (XVI). □

Zavedeme následující kvalifikační podmínky omezení:

- Slaterova podmínka: existuje $\mathbf{x}^0 \in \mathbb{R}^n$ takové, že $\mathbf{a}_t^T \mathbf{x}^0 < b_t \forall t \in \mathcal{T}$; (3.4)

- duální Slaterova podmínka: $\mathbf{c} \in \text{int } \mathcal{M}_n$. (3.5)

Věta 3.8 (silná dualita)

Nechť platí podmínky (3.4), (3.5). Potom existuje \mathbf{x}^ optimální řešení (XV) a $\boldsymbol{\lambda}^*$ optimální řešení (XVI) a $\mathbf{c}^T \mathbf{x}^* = \mathbf{b}^T \boldsymbol{\lambda}^*$.* □

Bez uvedených předpokladů obecně věta 3.8 neplatí. Na rozdíl od lineárního programování, pouhá přípustnost obou duálních úloh (XV), (XVI) neimplikuje existenci jejich optimálních řešení a existence optimálních řešení \mathbf{x}^* , $\boldsymbol{\lambda}^*$ neimplikuje rovnost $\mathbf{c}^T \mathbf{x}^* = \mathbf{b}^T \boldsymbol{\lambda}^*$ (protipříklad viz [15]). Následující věta z [7] uvádí postačující podmínku pro rovnost $v(\text{XV}) = v(\text{XVI})$ (srovnej s větami 4.4 a 4.6).

Věta 3.9

- (1) *Nechť $v(\text{XVI}) \in \mathbb{R}$ (nemusí se ale nutně nabýt) a $\mathbf{c} \in \text{int } \mathcal{M}_n$. Potom $v(\text{XV}) = v(\text{XVI})$ a úloha (XV) má optimální řešení.*
- (2) *Nechť $v(\text{XV}) \in \mathbb{R}$ (nemusí se ale nutně nabýt) a \mathcal{M}_{n+1} je uzavřený kužel. Potom $v(\text{XV}) = v(\text{XVI})$ a úloha (XVI) má optimální řešení.* □

Perfektní dualitou mezi úlohami (XV), (XVI) rozumíme situaci, kdy $v(\text{XV}) = v(\text{XVI})$, anebo $v(\text{XV}) = \infty$ a $v(\text{XVI}) = -\infty$. V lineárním programování je perfektní dualita vždy zaručena. V lineárním semi-infinitním programování platí perfektní dualita pouze za určitých předpokladů. Následující věta z [7] uvádí postačující podmínku pro perfektní dualitu. Využívá se v ní fakt, že je-li množina \mathcal{M}_{n+1} uzavřená, potom je uzavřená i \mathcal{K} .

Věta 3.10

Nechť $\mathcal{X} \neq \emptyset$. Potom \mathcal{K} je uzavřená množina právě tehdy, když úlohy (XV), (XVI) jsou v perfektní dualitě a úloha (XVI) má optimální řešení. \square

3.3 Souvislost se semidefinitním programováním

Mějme úlohu semidefinitního programování následujícího typu (viz [15])

$$\min \{ \mathbf{c}^T \mathbf{x}; \sum_{j=1}^n \mathbf{A}_j x_j - \mathbf{B} \succeq 0 \}, \tag{XVII}$$

kde $\mathbf{A}_1, \dots, \mathbf{A}_n, \mathbf{B} \in \mathbb{R}^{k \times k}$ jsou symetrické matice. Obecná symetrická matice \mathbf{M} je pozitivně semidefinitní právě tehdy, když $\mathbf{t}^T \mathbf{M} \mathbf{t} \geq 0 \forall \mathbf{t} : \|\mathbf{t}\| = 1$. Tudíž lze úlohu (XVII) přeformulovat jako úlohu lineárního semi-infinitního programování (XV), kde

$$\mathbf{a}_t = (\mathbf{t}^T \mathbf{A}_1 \mathbf{t}, \dots, \mathbf{t}^T \mathbf{A}_n \mathbf{t}), \quad \mathbf{b}_t = \mathbf{t}^T \mathbf{B}_1 \mathbf{t}, \quad \mathcal{T} = \{ \mathbf{t} \in \mathbb{R}^k \mid \|\mathbf{t}\| = 1 \}.$$

Poznamenejme, že z výpočetního hlediska není výhodné úlohu (XVII) převádět na úlohu lineárního semi-infinitního programování, neboť úlohy typu (XVII) lze řešit v polynomiálním čase např. metodou vnitřních bodů či elipsoidovou metodou.

4 Numerické metody řešení

Jak jsme ukázali v sekci 2, v určitých situacích lze převést úlohu neexaktního programování na obyčejnou úlohu lineárního programování. Ovšem i tato úloha může mít velké rozměry a někdy takováto redukce není vůbec proveditelná. Nezbývá proto než si pomoci numerickými metodami k obecně přibližnému řešení. Numerickými metodami řešení lineárního semi-infinitního programování se věnuje např. [3], [7], [8], [9], [15], [16], [18]. Na prvním místě zmiňme metodu řezů (viz [2], [16], [18]). V [8] autoři studují metody přípustných směrů (včetně rozšíření simplexové metody na řešení lineárního semi-infinitního programování). Numerické metody a geometrické vlastnosti tzv. analytických systémů najdeme v [3]. Perturbační metoda je popsána v [18], logaritmická barierová dekompoziční metoda v [9]. V [15] najdeme metodu přípustných směrů, metodu založenou na KKT-podmínkách a diskretizační metody (nekonečnou množinu indexů nahrazujeme posloupností dostatečně hustých konečných podmnožin). Metoda založená na lokální redukci je popsána v [7].

4.1 Metoda řezů

Uvažujme úlohu (I) ze strany 2. Budeme používat následující značení: $I(\mathcal{P}_i)$ označuje úlohu (I) se zadanými množinami $\mathcal{P}_i, i \in \{1, \dots, m\}$. Metoda řezů dle [16] je založena na následujícím postupu.

Algoritmus 4.1

krok 0. Dány množiny $\mathcal{P}_i, i \in \{1, \dots, m\}$. Přiřaď $k = 0$. Vyber konečné podmnožiny $\mathcal{P}_i^k \subset \mathcal{P}_i, i \in \{1, \dots, m\}$. Zvol $\alpha > 0$.

krok k. Vyřeš úlohu lineárního programování $I(\mathcal{P}_i^k)$, necht' má optimální řešení \mathbf{x}^k . Dále pro $i = 1, \dots, m$ řešme následující úlohy obecně nelineárního programování (necht' mají optimální řešení \mathbf{a}_i^k)

$$\max \{ \mathbf{a}^T \mathbf{x}^k; \mathbf{a} \in \mathcal{P}_i \}$$

a určíme maximum

$$\rho_k = \max \{ (\mathbf{a}_i^k)^T \mathbf{x}^k - b_i; i = 1, \dots, m \}.$$

Je-li $\rho_k < \alpha$, konec. Jinak přiřaď $\mathcal{P}_i^{k+1} = \mathcal{P}_i^k \cup \{ \mathbf{a}_i^k \}$, $i \in \{1, \dots, m\}$, $k = k + 1$ a opakuj krok k .

Pro \mathcal{P}_i , $i \in \{1, \dots, m\}$, konvexní polyedry je tato metoda vždy konečná, obecně ale bývá konvergence velmi pomalá. Zrychlením metody řezů se zabývá [2].

4.2 Diskretizační metody

Definujme si některé pojmy týkající se diskretizace úlohy (XV) lineárního semi-infinitního programování. Označme symbolem \mathcal{S} množinu optimálních řešení úlohy (XV). Definujme *vzdálenost* mezi množinami \mathcal{T}' a \mathcal{T} jako $\rho(\mathcal{T}') = \max_{t \in \mathcal{T}'} \text{dist}(t, \mathcal{T})$, kde $\text{dist}(t, \mathcal{T}) = \min_{t' \in \mathcal{T}} \|t - t'\|$.

Definice 4.2

Úloha (XV) se nazývá *konečně redukovatelná*, pokud existuje konečná množina $\mathcal{T}' \subset \mathcal{T}$ taková, že $v(\text{XV}) = v(\text{XV}(\mathcal{T}'))$. Úloha (XV) se nazývá *slabě diskretizovatelná*, pokud existuje posloupnost konečných množin $\mathcal{T}_k \subset \mathcal{T}$, $k = 1, \dots$, pro kterou platí $v(\text{XV}(\mathcal{T}_k)) \rightarrow v(\text{XV})$ pro $k \rightarrow \infty$. Úloha (XV) se nazývá *diskretizovatelná*, pokud pro každou posloupnost konečných množin $\mathcal{T}_k \subset \mathcal{T}$ splňující $\rho(\mathcal{T}_k) \rightarrow 0$ existují optimální řešení \mathbf{x}^k úloh $\text{XV}(\mathcal{T}_k)$ a platí $\text{dist}(\mathbf{x}^k, \mathcal{S}) \rightarrow 0$ a $v(\text{XV}(\mathcal{T}_k)) \rightarrow v(\text{XV})$.

Platí následující jednoduché vztahy. Je-li $\mathcal{T}_1 \subset \mathcal{T}_2$, potom $v(\text{XV}(\mathcal{T}_1)) \leq v(\text{XV}(\mathcal{T}_2))$. Je-li úloha (XV) konečně redukovatelná, potom je i slabě diskretizovatelná. Hlubší výsledky obsahují následující věty 4.3 a 4.4 z [15], věta 4.5 z [7] a věta 4.6 z [5].

Věta 4.3

Bud' \mathcal{X} neprázdná a omezená množina. Potom úloha (XV) je konečně redukovatelná právě tehdy, když je slabě diskretizovatelná a duální úloha (XVI) je přípustná. \square

Věta 4.4

Bud' $\mathcal{X} \neq \emptyset$. Potom úloha (XV) je slabě diskretizovatelná právě tehdy, když $v(\text{XV}) = v(\text{XVI})$. \square

Věta 4.5

Předpokládejme, že platí následující typ Slaterovy podmínky: pro každých $n+1$ bodů $t_0, \dots, t_n \in \mathcal{T}$ existuje \mathbf{x}^0 takové, že $\mathbf{a}_t^T \mathbf{x}^0 > b_t \forall t = t_0, \dots, t_n$. Potom existuje n -prvková množina $\mathcal{T}_n \subset \mathcal{T}$, pro kterou platí $v(\text{XV}) = v(\text{XV}(\mathcal{T}_n))$. \square

Věta 4.6

Necht' $\mathcal{X} \neq \emptyset$, $\mathbf{c} \notin \text{rbd } \mathcal{M}_n$. Potom úloha (XV) je slabě diskretizovatelná. \square

Následující věty z [15] uvádí postačující podmínky pro diskretizovatelnost.

Věta 4.7

Mějme posloupnost konečných množin $\mathcal{T}_k \subset \mathcal{T}$, $k = 1, \dots$. Necht' $\mathcal{T}_0 \subset \mathcal{T}_k \forall k \geq 1$ a necht' $\rho(\mathcal{T}_k) \rightarrow 0$ pro $k \rightarrow \infty$. Necht' $\mathcal{X}(\mathcal{T}_0)$ je kompaktní množina. Potom úloha (XV) je diskretizovatelná posloupností \mathcal{T}_k , $k = 1, \dots$ \square

Věta 4.8

Nechť $\mathcal{X} \neq \emptyset$, $\mathbf{c} \in \text{int } \mathcal{M}_n$. Potom úloha (XV) je diskretizovatelná a množina jejích optimálních řešení \mathcal{S} je neprázdná a omezená. \square

Diskretizační metody spočívají na následujícím algoritmickém schématu.

Algoritmus 4.9

krok 0. Vyber konečnou podmnožinu $\mathcal{T}_0 \subset \mathcal{T}$, $k = 0$. Zvol $\alpha > 0$.

krok k. Vyřeš úlohu $\text{XV}(\mathcal{T}_k)$, necht' má řešení \mathbf{x}^k . Je-li $\mathbf{a}_t^T \mathbf{x}^k \geq b_t - \alpha$ pro všechna $t \in \mathcal{T}$, konec (jsme dostatečně blízko množině přípustných řešení). Jinak vyber "jemnější" diskretizaci \mathcal{T}_{k+1} . Přiřaď $k = k + 1$ a opakuj krok k .

Možný způsob jak volit diskretizace je navržený v [7]. Mějme $\mathbf{t}^0 \in \mathbb{R}^m$ pevné a $\mathbf{h} \in \mathbb{R}^m$, $\mathbf{h} > \mathbf{0}$. Definujme rastr

$$\mathcal{T}_{\mathbf{h}} = \{t \in \mathcal{T} \mid t_j = t_j^0 + z_j h_j, z_j \in \mathbb{Z}, j = 1, \dots, m\},$$

který je základem pro následující variantu diskretizační metody.

Algoritmus 4.10

krok 0. Zvol \mathbf{t}^0 , $\mathbf{h}^0 \in \mathbb{R}^m$, $\mathbf{h} > \mathbf{0}$ a $\alpha > 0$. Přiřaď $k = 1$.

krok k. Přiřaď $\mathbf{h}^k = \frac{1}{n_k} \mathbf{h}^{k-1}$, kde $n_k \in \mathbb{N}$, $n \geq 2$. Vyber $\tilde{\mathcal{T}}_{\mathbf{h}^k} \subseteq \mathcal{T}_{\mathbf{h}^k}$ (na základě znalosti hodnot $\tilde{\mathbf{x}}^{k-1}$, $\tilde{\mathcal{T}}_{\mathbf{h}^{k-1}}$). Vyřeš úlohu $\text{XV}(\tilde{\mathcal{T}}_{\mathbf{h}^k})$, necht' má optimální řešení $\tilde{\mathbf{x}}^k$. Je-li $\mathbf{a}_t^T \tilde{\mathbf{x}}^k > b_t - \alpha \forall t \in \mathcal{T}_{\mathbf{h}^k}$, konec. Jinak přiřaď $k = k + 1$ a opakuj krok k .

Často se přidává podmínka, aby počet iterací algoritmu byl alespoň k_0 , $k_0 \in \mathbb{N}$. Při výběru $\tilde{\mathcal{T}}_{\mathbf{h}^k} \subseteq \mathcal{T}_{\mathbf{h}^k}$ je vhodné využít maximálně informace z minulých iterací algoritmu. Tento výběr se také doporučuje provést tak, aby platila inkluze

$$\tilde{\mathcal{T}}_{\mathbf{h}^k} \supset \{t \in \mathcal{T}_{\mathbf{h}^k} \mid \mathbf{a}_t^T \tilde{\mathbf{x}}^{k-1} \geq b_t - \gamma\},$$

kde $\gamma > 0$ je pevný práh. Je-li γ "příliš" veliké, vede to k mnoha omezením v úloze $\text{XV}(\tilde{\mathcal{T}}_{\mathbf{h}^k})$, je-li "příliš" malé, může to mít podobný účinek při dalších iteracích algoritmu.

4.3 Výměnná metoda

Uvažujme úlohu (XV). Výměnná metoda je založena na následujícím algoritmickém schématu (viz [7], [15]).

Algoritmus 4.11

krok 0. Vyber konečnou podmnožinu $\mathcal{T}_0 \subset \mathcal{T}$, $k = 0$. Zvol $\alpha > 0$.

krok k. Spočítej řešení \mathbf{x}^k úlohy $\text{XV}(\mathcal{T}_k)$. Spočítej lokální řešení $t_k^1, \dots, t_k^{v_k}$ úlohy

$$\min \{ \mathbf{a}_t^T \mathbf{x}^k - b_t; t \in \mathcal{T} \} \quad (4.1)$$

Je-li $\mathbf{a}_t^T \mathbf{x}^k > b_t - \alpha$ pro všechna $t = t_k^1, \dots, t_k^{v_k}$, konec. Jinak vyber

$$\mathcal{T}_{k+1} \subseteq \mathcal{T}_k \cup \{t_k^1, \dots, t_k^{v_k}\} \quad (4.2)$$

Přiřaď $k = k + 1$ a opakuj krok k .

Tento algoritmus se nazývá *výměnná metoda*, neboť v každé iteraci (4.2) se některé omezení přidají do $\mathcal{X}(\mathcal{T}_k)$ a některé odeberou. Lze uvažovat různé varianty algoritmu. Je-li krok (4.2) nahrazen přiřazením $\mathcal{T}_{k+1} = \mathcal{T}_k \cup \{t_k^1, \dots, t_k^{v_k}\}$, pak se jedná o variantu algoritmu blízkou diskretizačním metodám. Je-li navíc v k . kroku vždy $v_k = 1$ (tj. vybíráme jen jedno lokální řešení úlohy (4.1)), potom se jedná přímo o metodu řezů popsanou v sekci 4.1.

Věta 4.12

Předpokládejme, že v každém kroku algoritmu 4.11 je jedno z $t_k^1, \dots, t_k^{v_k}$ zároveň globálním řešením úlohy (4.1). Necht' dále \mathcal{X} je omezená množina. Potom algoritmus 4.11 s $\alpha = 0$ buď skončí po konečně mnoha krocích v řešení úlohy (XV), nebo každá posloupnost $\{\mathbf{x}^k\}_{k=1}^\infty$ má aspoň jeden hromadný bod a každý hromadný bod této posloupnosti řeší úlohu (XV). \square

4.4 Metoda přípustných směrů

Uvažujme úlohu (XV). Metoda přípustných směrů je založena na následujícím algoritmickém schématu (podrobnější popis jednotlivých kroků viz [15]).

Algoritmus 4.13

krok 0. Vyber počáteční přípustné řešení \mathbf{x}^0 , $k = 0$.

krok k . Je-li \mathbf{x}^k lokální minimum úlohy (XV), konec. Jinak vyber směr, ve kterém cílová funkce klesá od bodu \mathbf{x}^k a v tomto směru přejdi do přípustného bodu \mathbf{x}^{k+1} s minimální hodnotou cílové funkce. Přiřaď $k = k + 1$ a opakuj krok k .

Pododná předchozímu algoritmu je metoda přípustných směrů simplexového typu z [8]. Je založena na následujícím algoritmickém schématu:

Algoritmus 4.14

krok 0. Najdi počáteční přípustné řešení \mathbf{x}^0 úlohy (XV), $k = 0$. Není-li \mathbf{x}^0 krajní bod množiny \mathcal{X} (např. podle věty 3.6), potom urči směr a v tomto směru přejdi v krajní bod \mathbf{x}^1 množiny \mathcal{X} a přiřaď $k = 1$.

krok k . Je-li \mathbf{x}^k lokální minimum úlohy (XV), konec. Jinak vyber směr, ve kterém cílová funkce klesá od bodu \mathbf{x}^k a v tomto směru přejdi v krajní bod \mathbf{x}^{k+1} množiny \mathcal{X} . Přiřaď $k = k + 1$ a opakuj krok k .

4.5 Metoda založená na KKT-podmínkách

Definice 4.15

Mějme $\mathbf{x}^0 \in \mathcal{X}$ z (XV). Množina aktivních podmínek pro bod \mathbf{x}^0 je definována takto: $\mathcal{I}(\mathbf{x}^0) = \{t \in \mathcal{T} \mid \mathbf{a}_t^T \mathbf{x}^0 = b_t\}$.

Dle [15] je za určitých předpokladů množina aktivních podmínek konečná. Proto i soustava KKT-podmínek je konečněrozměrná a lze ji řešit určitými numerickými metodami (Newtonova, ...).

5 Aplikace

Aplikce lze najít např. v [1], [7], [15].

Příklad 5.1 (minimalizace ceny omezení znečištění vzduchu z [7])

Předpokládejme, že existuje n zdrojů chemicky inertních znečištění vzduchu v kraji, jejichž

emise musí být řízeny tak, aby roční průměr znečištění vzduchu v každém bodě t kraje \mathcal{T} byl pod určitým limitem. Přitom požadujeme, aby hledané řízení bylo co nejlevnější. Nechť a_t^j značí roční průměr koncentrace znečištění v bodě $t \in \mathcal{T}$ zdroje j před řízením a nechť Ψ_t je maximální povolený limit koncentrace znečištění v $t \in \mathcal{T}$. Nechť z_j je zlomek, o který omezíme zdroj j , nesmíme však přesáhnout horní hranici $u_j \in (0, 1)$, tedy $z_j \in \langle 0, u_j \rangle$. Po zahájení řízení bude tedy roční koncentrace znečištění $\sum_{j=1}^n (1 - z_j) a_t^j$. Cena za omezení zdroje j o zlomek z_j nechť je lineární $c_j z_j$. Potom program řízení omezení znečištění vzduchu lze formulovat jako úlohu lineárního semi-infinitního programování

$$\min \{ \mathbf{c}^T \mathbf{z}; (\mathbf{1} - \mathbf{z})^T \mathbf{a}_t \leq \Psi_t \quad \forall t \in \mathcal{T}, \mathbf{0} \leq \mathbf{x} \leq \mathbf{u} \}.$$

Příklad 5.2 (problém portfolia z [15])

Chceme investovat k jednotek peněz mezi n druhů akcií na jedn rok. Do akcie i , $i = 1, \dots, n$, investujeme x_i jednotek peněz a předpokládáme výdělek z_i jednotek peněz na jednu jednotku vloženou do akcie i . Chceme tedy maximalizovat výdělek $\mathbf{z}^T \mathbf{x}$, jenomže hodnotu vektoru \mathbf{z} dopředu neznáme. Nicméně předpokládáme, že vektor \mathbf{z} nabývá hodnot z nějaké kompaktní množiny \mathcal{Z} . Problém portfolia můžeme formulovat jako následující úlohu lineárního semi-infinitního programování

$$\max \{ v; \mathbf{z}^T \mathbf{x} \geq v \quad \forall \mathbf{z} \in \mathcal{Z}, \mathbf{1}^T \mathbf{x} = k, \mathbf{x} \geq \mathbf{0} \}.$$

6 Závěr

Lineární semi-infinitní programování je velké odvětví optimalizace a na toto téma bylo napsáno mnoho článků. Není možné zde uvést všechny známé výsledky, ukázali jsme jen ty nejzákladnější z nich. Pěkné přehledy dosavadních výsledků najde čtenář např. v [6], [7], [15].

Reference

- [1] A. Ben-Tal, A. Nemirovski (1999): Robust solutions of uncertain linear programs, *Oper. Res. Lett.* **25**, No. 1, 1–13.
- [2] B. Betrò (2004): An accelerated central cutting plane algorithm for linear semi-infinite programming, *Math. Program.* **101**, No. 3, 479–495.
- [3] M. A. Goberna, V. Jornet, R. Puente, M. I. Todorov (1999): Analytical linear inequality systems and optimization, *J. Optimization Theory Appl.* **103**, No. 1, 95–119.
- [4] M. A. Goberna, M. A. López (1988): A theory of linear inequality systems, *Linear Algebra Appl.* **106**, 77–115.
- [5] M. A. Goberna, M. A. López (1999): On duality in semi-infinite programming and existence theorems for linear inequalities, *J. Math. Anal. Appl.* **230**, No. 1, 173–192.
- [6] M. A. Goberna, M. A. López (2002): Linear semi-infinite programming theory: An updated survey, *Eur. J. Oper. Res.* **143**, No. 2, 390–405.
- [7] R. Hettich, K. O. Kortanek (1993): Semi-infinite programming: Theory, methods, and applications, *SIAM Rev.* **35**, No. 3, 380–429.

- [8] T. Leon, S. Sanmatias, E. Vercher (2000): On the numerical treatment of linearly constrained semi-infinite optimization problems, *Eur. J. Oper. Res.* **121**, No. 1, 78–91.
- [9] Z.-Q. Luo, C. Roos, T. Terlaky (1999): Complexity analysis of logarithmic barrier decomposition methods for semi-infinite linear programming, *Appl. Numer. Math.* **29**, No. 3, 379–394.
- [10] J. Rohn (1976): Systems of linear equations with inexact data (česky), *Ekon.-Mat. Obz.* **12**, 311–315.
- [11] I. M. Stancu-Minasian, Ş. Ţigan (1987): Inexact mathematical programming, *Prepr.*, “Babes-Bolyai” Univ., Fac. Math. Phys., Res. Semin. 8, 99–116.
- [12] A. L. Soyster (1973): Convex programming with set-inclusive constraints and applications to inexact linear programming, *Oper. Res.* **21**, 1154–1157.
- [13] A. L. Soyster (1974): A duality theory for convex programming with set-inclusive constraints, *Oper. Res.* **22**, 892–898.
- [14] A. L. Soyster (1974): Erratum. A duality theory for convex programming with set-inclusive constraints, *Oper. Res.* **22**, 1279–1280.
- [15] G. Still (2004): Semi-infinite programming: An introduction “preliminary version”, University of Twente, Department of Applied Mathematics, Netherlands, 1–39. (<http://wwwhome.math.utwente.nl/~stillgj/sip.html>)
- [16] R. Tichatschke, R. Hettich, G. Still (1989): Connections between generalized, inexact and semi-infinite linear programming, *ZOR Math. Methods Oper. Res.* **33**, No. 6, 367–382.
- [17] D. J. Thuente (1980): Duality theory for generalized linear programs with computational methods, *Oper. Res.* **28**, 1005–1011.
- [18] M.-H. Wang, Y.-E. Kuo (1999): A perturbation method for solving linear semi-infinite programming problems, *Comput. Math. Appl.* **37**, No. 4–5, 181–198.