

# Kapitola 5

## Symetrická úloha NLP

V této kapitole se budeme zabývat **symetrickou úlohou nelineárního programování**

$$\begin{array}{ll} \text{minimalizovat} & f(\mathbf{x}), \\ \text{za podmíněk} & g_k(\mathbf{x}) \leq 0 \quad \forall k = 1, 2, \dots, m, \\ & x_i \geq 0 \quad \forall i = 1, 2, \dots, n. \end{array} \quad (5.1)$$

Úloha je speciálním případem obecné úlohy NLP, nemá omezení ve tvaru rovnic (2.13) a podmínka nezápornosti je explicitně vyjádřena.

Úloze (5.1) přiřadíme **Lagrangeovu funkci**

$$L(\mathbf{x}; \mathbf{y}) := f(\mathbf{x}) + \sum_{k=1}^m y_k g_k(\mathbf{x}). \quad (5.2)$$

### 5.1 Globální podmínky optimality

**Definice 5.1.:** Řekneme, že pro  $\mathbf{x}^* \in \mathbb{R}^n$ ,  $\mathbf{y}^* \in \mathbb{R}^m$  jsou splněny **globální podmínky optimality (GPO)** pro úlohu (5.1), jestliže

$$\mathbf{x}^* \geq \mathbf{0}, \mathbf{y}^* \geq \mathbf{0} \quad (5.3)$$

$$\text{a pro každé } \mathbf{x} \geq \mathbf{0}, \mathbf{y} \geq \mathbf{0} \text{ platí } L(\mathbf{x}; \mathbf{y}^*) \geq L(\mathbf{x}^*; \mathbf{y}^*) \geq L(\mathbf{x}^*; \mathbf{y}). \quad (5.4)$$

Říkáme též, že  $(\mathbf{x}^*, \mathbf{y}^*)$  je **sedlový bod Lagrangeovy funkce (5.2) v oboru  $\mathbf{x} \geq \mathbf{0}, \mathbf{y} \geq \mathbf{0}$** .

**Věta 5.2.:** Necht' jsou pro  $\mathbf{x}^* \in \mathbb{R}^n$ ,  $\mathbf{y}^* \in \mathbb{R}^m$  splněny GPO pro úlohu NLP (5.1). Pak je  $\mathbf{x}^*$  **optimální řešení** zmíněné úlohy a je splněna **podmínka komplementarity**

$$\text{pro každé } k = 1, 2, \dots, m \text{ je buď } y_k^* = 0 \text{ nebo } g_k(\mathbf{x}^*) = 0. \quad (5.5)$$

**Důkaz:** Podle předpokladu je  $\mathbf{x}^* \geq \mathbf{0}$ . Dosazením tvaru Lagrangeovy funkce (5.2) do (5.4) dostáváme

$$f(\mathbf{x}) + \sum_{k=1}^m y_k^* g_k(\mathbf{x}) \geq f(\mathbf{x}^*) + \sum_{k=1}^m y_k^* g_k(\mathbf{x}^*) \geq f(\mathbf{x}^*) + \sum_{k=1}^m y_k g_k(\mathbf{x}^*). \quad (5.6)$$

Nerovnosti (5.6) podle předpokladu platí pro nějaké  $\mathbf{y}^* \geq \mathbf{0}$  a pro všechna  $\mathbf{x} \geq \mathbf{0}$ ,  $\mathbf{y} \geq \mathbf{0}$ . Použijeme nejprve pravou větev (5.6), tj. nerovnost

$$\sum_{k=1}^m y_k^* g_k(\mathbf{x}^*) \geq \sum_{k=1}^m y_k g_k(\mathbf{x}^*) \quad \forall \mathbf{y} \geq \mathbf{0}. \quad (5.7)$$

Uvědomíme si, že  $g_k(\mathbf{x}^*)$  jsou pevné koeficienty a že  $\mathbf{y}^* \geq \mathbf{0}$  je z hlediska uvažované nerovnosti také pevný vektor. Odtud přímo vyplývá, že (5.7) může platit jen když  $g_k(\mathbf{x}^*) \leq 0$ ,  $k = 1, 2, \dots, m$  a

$$\sum_{k=1}^m y_k^* g_k(\mathbf{x}^*) = 0. \quad (5.8)$$

Tato podmínka je ekvivalentní s podmínkou komplementarity (5.5).

To znamená, že  $\mathbf{x}^*$  je přípustné řešení úlohy (5.1) a že se levá větev nerovností (5.6) redukuje na

$$f(\mathbf{x}) + \sum_{k=1}^m y_k^* g_k(\mathbf{x}) \geq f(\mathbf{x}^*) \quad \forall \mathbf{x} \geq \mathbf{0}. \quad (5.9)$$

Omezme se jen na přípustná  $\mathbf{x}$ . Pro ně je  $g_k(\mathbf{x}) \leq 0$ ,  $k = 1, 2, \dots, m$  a z nerovnosti (5.9) plyne  $f(\mathbf{x}) \geq f(\mathbf{x}^*)$ .

Tedy  $\mathbf{x}^*$  je optimální řešení úlohy (5.1).

**Q.E.D.**

## 5.2 Podmínky regularity

Věta 5.2 platí bez jakýchkoli předpokladů na funkci  $f$ ,  $g_k$ . Avšak pro ověřování optimality řešení nebo pro nalezení optimálního řešení je nepraktická. Jako vedlejší výsledek jsme dostali podmínku komplementarity (5.5). (Porovnejte s podmínkami komplementarity v LP (3.32), (3.33).)

Věta 5.2 dává postačující podmínku pro bod globálního minima funkce  $f$  na množině popsané nerovnostmi (5.1). Otázkou je, kdy bude globální podmínka (5.6) nutná. Snadno najdeme příklad, kdy k optimálnímu řešení  $\mathbf{x}^*$  úlohy (5.1) neexistuje vektor Lagrangeových multiplikátorů  $\mathbf{y}^*$  tak, aby platilo (5.6).

**Příklad 5.3.:** Řešme úlohu  $\min \{-x : x^2 \leq 0, x \geq 0, x \in \mathbb{R}\}$ , tj.  $f(x) = -x$ ,  $g(x) = x^2$ .

Existuje jediné přípustné a tedy i optimální řešení úlohy. Je to  $x^* = 0$ .

Lagrangeova funkce má tvar  $L(x; y) = -x + yx^2$ .

1. V bodě  $(0, 0)$  nemá sedlový bod neboť funkce  $x \mapsto L(x; 0) = -x$  nemá na  $x \geq 0$  minimum v  $x^* = 0$ .

2. Pro  $y > 0$ , v bodě  $(0, y)$  také není sedlový bod Lagrangeovy funkce, neboť  $x \mapsto L(x; y) = -x + yx^2$  má na  $x \geq 0$  minimum v  $\bar{x} = \frac{1}{2y}$  a nikoli v  $x^* = 0$ .

K bodu  $x^* = 0$  tedy neexistuje žádné  $y^* \in \mathbb{R}$  tak, aby dvojice  $(x^*, y^*)$  splňovala GPO.

△

Je tedy zapotřebí dalších předpokladů, tzv. **podmínek regularity**, které vyloučí podobné degenerované případy. Z příkladu vidíme, že samotný předpoklad konvexnosti funkcí  $f, g_1, g_2, \dots, g_m$  nestačí.

**Definice 5.4.:** Pro úlohu (5.1) zavedeme množinu indexů aktivních omezení v bodě  $\mathbf{x} \geq \mathbf{0}$

$$\mathbf{B}_g(\mathbf{x}) = \{k = 1, 2, \dots, m : g_k(\mathbf{x}) = 0\}, \quad (5.10)$$

$$\mathbf{B}_x(\mathbf{x}) = \{i = 1, 2, \dots, n : x_i = 0\}. \quad (5.11)$$

Uvedeme si tři podmínky, které spolu s konvexností funkcí  $f, g_1, g_2, \dots, g_m$  zaručují ekvivalenci mezi splněním (5.4) a existencí optimálního řešení úlohy (5.1).

**Definice 5.5.:** Řekneme, že pro přípustné řešení  $\mathbf{x} \in \mathbb{R}^n$  úlohy (5.1) je splněna **podmínka lineární nezávislosti**, jsou-li funkce  $g_k$ ,  $k = 1, 2, \dots, m$  v bodě  $\mathbf{x}$  diferencovatelné a gradienty aktivních omezení jsou lineárně nezávislé, tj. matice

$$(\nabla_x g_k(\mathbf{x}) \quad k \in B_g(\mathbf{x}), \quad \mathbf{e}_i \quad i \in B_x(\mathbf{x}))$$

má plnou sloupcovou hodnost.

**Definice 5.6.:** Řekneme, že úloha (5.1) splňuje **Slaterovu podmínku**, jestliže existuje  $\bar{\mathbf{x}} \geq 0$ , pro které platí  $g_k(\bar{\mathbf{x}}) < 0$  pro každé  $k = 1, 2, \dots, m$ .

Platí následující věty.

**Věta 5.7.:** Nechtě  $f, g_k$ ,  $k = 1, 2, \dots, m$  jsou konvexní funkce a v bodě  $\mathbf{x}^* \in \mathbb{R}^n$  je splněna podmínka lineární nezávislosti. Pak  $\mathbf{x}^*$  je optimální řešení úlohy (5.1) tehdy a jen tehdy, když existuje  $\mathbf{y}^* \in \mathbb{R}^m$  tak, že dvojice  $(\mathbf{x}^*, \mathbf{y}^*)$  splňuje GPO.

**Důkaz:** Důkaz je uveden například v [1] a v [4].

**Q.E.D.**

**Věta 5.8.:** Nechtě  $f, g_k$ ,  $k = 1, 2, \dots, m$  jsou konvexní funkce a je splněna Slaterova podmínka. Pak  $\mathbf{x}^* \in \mathbb{R}^n$  je optimální řešení úlohy (5.1) tehdy a jen tehdy, když existuje  $\mathbf{y}^* \in \mathbb{R}^m$  tak, že dvojice  $(\mathbf{x}^*, \mathbf{y}^*)$  splňuje GPO.

**Důkaz:** Důkaz je uveden například v [1], [4] a v [5].

**Q.E.D.**

**Věta 5.9.:** Nechtě  $f$  je konvexní funkce a  $g_k$ ,  $k = 1, 2, \dots, m$  jsou lineární funkce. Pak  $\mathbf{x}^* \in \mathbb{R}^n$  je optimální řešení úlohy (5.1) tehdy a jen tehdy, když existuje  $\mathbf{y}^* \in \mathbb{R}^m$  tak, že dvojice  $(\mathbf{x}^*, \mathbf{y}^*)$  splňuje GPO.

**Důkaz:** Důkaz je uveden například v [1], [4] a v [5].

**Q.E.D.**

Povšimněte si, že podmínka lineární nezávislosti je obdobou podmínky používané ve větě o vázaném extrému z matematické analýzy.

## 5.3 Lokální podmínky optimality

V této podkapitole představíme nutné a postačující podmínky k tomu, aby dvojice  $\mathbf{x}^*, \mathbf{y}^*$  splňovala GPO. K tomu cíli budeme většinou předpokládat diferencovatelnost a konvexnost funkcí  $f, g_1, g_2, \dots, g_m$ .

**Definice 5.10.:** Řekneme, že pro  $\mathbf{x}^* \in \mathbb{R}^n$ ,  $\mathbf{y}^* \in \mathbb{R}^m$  jsou splněny **lokální podmínky optimality (LPO)** pro úlohu (5.1), jestliže platí

$$\nabla_x L(\mathbf{x}^*; \mathbf{y}^*) \geq 0, \quad (\mathbf{x}^*)^\top \nabla_x L(\mathbf{x}^*; \mathbf{y}^*) = 0, \quad \mathbf{x}^* \geq 0, \quad (5.12)$$

$$\nabla_y L(\mathbf{x}^*; \mathbf{y}^*) \leq 0, \quad (\mathbf{y}^*)^\top \nabla_y L(\mathbf{x}^*; \mathbf{y}^*) = 0, \quad \mathbf{y}^* \geq 0. \quad (5.13)$$

Poznamenejme, že pro každé  $k = 1, 2, \dots, m$  platí  $\frac{\partial L}{\partial y_k}(\mathbf{x}^*; \mathbf{y}^*) = g_k(\mathbf{x}^*)$ . Tudíž podmínka (5.13) je shodná s podmínkou

$$g_k(\mathbf{x}^*) \leq 0 \quad \text{pro každé } k = 1, 2, \dots, m \quad \text{a} \quad (\mathbf{y}^*)^\top g(\mathbf{x}^*) = \sum_{k=1}^m y_k^* g_k(\mathbf{x}^*) = 0. \quad (5.14)$$

**Věta 5.11.:** *Nechť  $f, g_1, g_2, \dots, g_m$  jsou diferencovatelné. Pak podmínky LPO, tj. (5.12), (5.13), jsou nutné k tomu, aby dvojice  $\mathbf{x}^*, \mathbf{y}^*$  splňovala GPO pro úlohu (5.1).*

**Důkaz:** Nechť  $\mathbf{x}^*, \mathbf{y}^*$  splňují GPO.

1. Pak pro každé  $i = 1, 2, \dots, n$  platí

$$\frac{\partial L}{\partial x_i}(\mathbf{x}^*; \mathbf{y}^*) = \lim_{t \rightarrow 0^+} \frac{L(\mathbf{x}^* + t \mathbf{e}_i; \mathbf{y}^*) - L(\mathbf{x}^*; \mathbf{y}^*)}{t} \geq 0,$$

neboť pro každé kladné  $t$  je

$$L(\mathbf{x}^* + t \mathbf{e}_i; \mathbf{y}^*) \geq L(\mathbf{x}^*; \mathbf{y}^*).$$

( $\mathbf{e}_i$  označuje vektor, jehož  $i$ -tá složka je 1 a ostatní složky jsou nulové.)

Pokud  $x_i^* > 0$ , pak platí ještě

$$\frac{\partial L}{\partial x_i}(\mathbf{x}^*; \mathbf{y}^*) = \lim_{t \rightarrow 0^-} \frac{L(\mathbf{x}^* + t \mathbf{e}_i; \mathbf{y}^*) - L(\mathbf{x}^*; \mathbf{y}^*)}{t} \leq 0.$$

Tím je splnění podmínky (5.12) dokázáno.

2. Pak pro každé  $k = 1, 2, \dots, m$  platí

$$\frac{\partial L}{\partial y_k}(\mathbf{x}^*; \mathbf{y}^*) = \lim_{t \rightarrow 0^+} \frac{L(\mathbf{x}^*; \mathbf{y}^* + t \mathbf{e}_k) - L(\mathbf{x}^*; \mathbf{y}^*)}{t} \leq 0,$$

neboť pro každé kladné  $t$  je

$$L(\mathbf{x}^*; \mathbf{y}^* + t \mathbf{e}_k) \leq L(\mathbf{x}^*; \mathbf{y}^*).$$

Pokud  $y_k^* > 0$ , pak platí ještě

$$\frac{\partial L}{\partial y_k}(\mathbf{x}^*; \mathbf{y}^*) = \lim_{t \rightarrow 0^-} \frac{L(\mathbf{x}^*; \mathbf{y}^* + t \mathbf{e}_k) - L(\mathbf{x}^*; \mathbf{y}^*)}{t} \geq 0.$$

Tím je splnění podmínky (5.13) dokázáno.

**Q.E.D.**

**Věta 5.12.:** *Nechť  $f, g_1, g_2, \dots, g_m$  jsou konvexní a diferencovatelné. Pak jsou podmínky LPO nutné a postačující k tomu, aby dvojice  $\mathbf{x}^*, \mathbf{y}^*$  splňovala GPO pro úlohu (5.1).*

**Důkaz:** Nutnost podmínek již byla ukázána ve větě 5.11. Stačí proto ukázat pouze postačitelost.

Pro  $\mathbf{y}^* \geq \mathbf{0}$  je funkce  $L(\bullet; \mathbf{y}^*)$  konvexní na  $\mathbb{R}^n$ . Podle (2.9) a (5.12) upravujeme postupně

$$\begin{aligned} L(\mathbf{x}; \mathbf{y}^*) &\geq L(\mathbf{x}^*; \mathbf{y}^*) + (\mathbf{x} - \mathbf{x}^*)^\top \nabla_x L(\mathbf{x}^*; \mathbf{y}^*) \\ &\geq L(\mathbf{x}^*; \mathbf{y}^*) + \mathbf{x}^\top \nabla_x L(\mathbf{x}^*; \mathbf{y}^*) \geq L(\mathbf{x}^*; \mathbf{y}^*) \quad \forall \mathbf{x} \geq \mathbf{0} \end{aligned}$$

Jako funkce  $\mathbf{y}$  je  $L(\mathbf{x}^*; \bullet)$  lineární, tedy

$$\begin{aligned} L(\mathbf{x}^*; \mathbf{y}) &= L(\mathbf{x}^*; \mathbf{y}^*) + (\mathbf{y} - \mathbf{y}^*)^\top \nabla_{\mathbf{y}} L(\mathbf{x}^*; \mathbf{y}^*) \\ &= L(\mathbf{x}^*; \mathbf{y}^*) + \mathbf{y}^\top \nabla_{\mathbf{y}} L(\mathbf{x}^*; \mathbf{y}^*) \leq L(\mathbf{x}^*; \mathbf{y}^*) \quad \forall \mathbf{y} \geq \mathbf{0} \end{aligned}$$

podle (5.13).

Tím je splnění GPO ukázáno.

**Q.E.D.**

Pro symetrickou úlohu NLP používáme Lagrangeovu funkci ve tvaru (5.2), GPO vyjádřené jako (5.4) a LPO zapsané v podmínkách (5.12), (5.13). Lagrangeovu funkci, GPO a LPO lze využít i pro pozměněný tvar úlohy NLP. Avšak Lagrangeova funkce a následně i podmínky budou mít pozměněný tvar. Budou podstatně záviset na tvaru úlohy NLP. Uvedme si v následující tabulce některé z používaných možností:

omezení	Lagrangeova funkce	lokální podmínky optimality
$g_k(\mathbf{x}) \leq 0 \quad \forall k$	$f(\mathbf{x}) + \sum_k y_k g_k(\mathbf{x})$	$\nabla_x L(\mathbf{x}^*; \mathbf{y}^*) = \mathbf{0}$ a (5.13)
$\mathbf{x} \geq \mathbf{0}$	$f(\mathbf{x})$	$\nabla_x f(\mathbf{x}^*) \geq \mathbf{0}, \mathbf{x}^* \geq \mathbf{0}, (\mathbf{x}^*)^\top \nabla_x f(\mathbf{x}^*) = 0$
$g_k(\mathbf{x}) = 0 \quad \forall k, \mathbf{x} \geq \mathbf{0}$	$f(\mathbf{x}) + \sum_k y_k g_k(\mathbf{x})$	(5.12) a $g_k(\mathbf{x}^*) = 0 \quad \forall k$

(5.15)

## 5.4 Citlivost úlohy NLP

Obdoba aproximace (3.42) pro úlohu LP v kapitole 3.8.2 platí také pro symetrickou úlohu NLP. Avšak roli duálních proměnných zde přebírají Lagrangeovy multiplikátory.

**Věta 5.13.:** *Uvažujme symetrickou úlohu NLP*

$$\max \{f(\mathbf{x}) : g_k(\mathbf{x}) \leq b_k, k = 1, 2, \dots, m, \mathbf{x} \geq \mathbf{0}\} \quad (5.16)$$

a úlohu, která z ní vznikne po změně pravých stran nerovností o vektor  $\Delta$

$$\max \{f(\mathbf{x}) : g_k(\mathbf{x}) \leq b_k + \Delta_k, k = 1, 2, \dots, m, \mathbf{x} \geq \mathbf{0}\}. \quad (5.17)$$

*Abychom mohli použít vyloženou teorii, převedeme úlohu na minimalizaci*

$$\min \{-f(\mathbf{x}) : g_k(\mathbf{x}) \leq b_k, k = 1, 2, \dots, m, \mathbf{x} \geq \mathbf{0}\}, \quad (5.18)$$

$$\min \{-f(\mathbf{x}) : g_k(\mathbf{x}) \leq b_k + \Delta_k, k = 1, 2, \dots, m, \mathbf{x} \geq \mathbf{0}\}. \quad (5.19)$$

*Nechť  $\hat{\mathbf{x}}$  je optimální řešení úlohy (5.18) splňující GPO s Lagrangeovými multiplikátory  $\hat{\mathbf{y}}$  a  $\hat{\xi}$  je optimální řešení úlohy (5.19) splňující GPO s Lagrangeovými multiplikátory  $\hat{\eta}$ . Pak platí*

$$\sum_{k=1}^m \Delta_k \hat{y}_k \geq f(\hat{\xi}) - f(\hat{\mathbf{x}}) \geq \sum_{k=1}^m \Delta_k \hat{\eta}_k. \quad (5.20)$$

**Důkaz:** Stačí si pouze napsat GPO pro obě úlohy, tj. pro všechna  $\mathbf{x} \geq \mathbf{0}, \mathbf{y} \geq \mathbf{0}$  platí

$$\begin{aligned} -f(\mathbf{x}) + \sum_{k=1}^m \hat{y}_k (g_k(\mathbf{x}) - b_k) &\geq -f(\hat{\mathbf{x}}) \geq -f(\hat{\mathbf{x}}) + \sum_{k=1}^m y_k (g_k(\hat{\mathbf{x}}) - b_k), \\ -f(\mathbf{x}) + \sum_{k=1}^m \hat{\eta}_k (g_k(\mathbf{x}) - b_k - \Delta_k) &\geq -f(\hat{\xi}) \geq -f(\hat{\xi}) + \sum_{k=1}^m y_k (g_k(\hat{\xi}) - b_k - \Delta_k). \end{aligned}$$