

# Nelineární optimalizace s omezeními - obecně

Většinu spojitých optimalizačních problémů lze vyjádřit následujícím způsobem:

minimalizuj:

$$f(\mathbf{x}), \mathbf{x} \in \mathbb{R}^n$$

za předpokladu:

$$c_i(\mathbf{x}) = 0, i \in E$$

$$c_i(\mathbf{x}) \geq 0, i \in I$$

# Nelineární optimalizace s omezeními

## - obecně II

Účelová funkce  $f$ , stejně jako funkce  $c_i$ ,  
určující omezení, jsou zobrazení z  $\mathbb{R}^n$  do  $\mathbb{R}$ .

E množina omezení ve formě rovnic

I množina omezení ve formě nerovnic

Dále budeme kvůli stručnosti označovat  
gradienty  $\nabla c_i$  jako  $a_i$ .

# Nelineární optimalizace s omezeními

## - příklad

Potravinářský velkoobchod má k dispozici sklad na 100 tun obilovin a jeho manažer se rozhoduje, jaké plodiny nakoupit:

- hrách se prodává za 10 Kč/kg a jeho nákupní cena je 8 Kč/kg
- mouka se prodává za 8Kč/kg, nákupní cena malého množství je 7Kč/kg, při každé odebrané tuně se cena snižuje o 0,02 Kč
- čočka se prodává za 12 Kč/kg a její nákupní cena je 9 Kč/kg, speciálním potřebám pro skladování této plodiny však vyhovuje pouze jedna část skladu, která je schopná pojmout 50 t.

Kolik nakoupit hrachu, kolik mouky a kolik čočky?

# Nelineární optimalizace s omezeními

## - příklad II

Proměnné:

x množství hrachu

y množství mouky

z množství čočky

Omezení skladovací kapacity:

$$x + y + z \leq 100$$

$$z \leq 50$$

# Nelineární optimalizace s omezeními

## - příklad III

Zisk z jedné tuny:

hrách                    2000 Kč

čočka                    3000 Kč

mouka                     $(1000 + 20y)$  Kč

Poznámka: Cena za kg:  $7 - 0,02y \Rightarrow$  zisk z tuny tedy bude  
 $1000 \cdot (8 - (7 - 0,02y)) = 1000 + 20y$

Účelová funkce má tedy tvar:

$$\begin{aligned} 2000x + (1000 + 20y)y + 3000z &= \\ = 2000x + 1000y + 20y^2 + 3000z \end{aligned}$$

# Nelineární optimalizace s omezeními

## - definice

**Množina přípustných bodů:**

$$S = \{ \mathbf{x} \in \mathbb{R}^n \mid c_i(\mathbf{x}) = 0, i \in E; c_i(\mathbf{x}) \geq 0, i \in I \}$$

Přípustný bod  $\mathbf{x}^* \in E$ , splňující omezující podmínky, nazveme **omezeným lokálním minimem** problému, pokud existuje okolí  $\Omega(\mathbf{x}^*)$  bodu  $\mathbf{x}^*$  tak, že pro všechna  $\mathbf{x} \in \Omega(\mathbf{x}^*)$ , která splňují omezení, platí  $f(\mathbf{x}^*) \leq f(\mathbf{x})$ .

# Nelineární optimalizace s omezeními

## - definice II

**Aktivní omezení** v bodě  $\mathbf{x}$  je indexová množina  $A$ , pro kterou platí:

$$A(\mathbf{x}) = \{i; c_i(\mathbf{x}) = 0\}$$

Je-li tedy  $i \in A(\mathbf{x})$ , pak  $\mathbf{x}$  je na hranici oblasti definované  $i$ -tým omezením.

Velmi důležitá je množina  $A^* = A(\mathbf{x}^*)$ , jestliže je tato množina známa, pak můžeme ostatní omezení ignorovat a řešit úlohu jako problém s omezeními ve formě rovnic  $E = A^*$ .

# Nelineární optimalizace s omezeními

## - definice III

### **Volné extrémý:**

Jsou to lokální extrémý účelové funkce, nezávisí na žádných dalších omezeních.

### **Vázané extrémý**

Body účelové funkce, které jsou minimální (maximální) v oblasti, omezené jistými podmínkami.



# Omezení v podobě rovnic - obecně

Minimalizuj:

$$f(\mathbf{x}), \quad \mathbf{x} \in \mathbb{R}^n$$

za předpokladu:

$$c_i(\mathbf{x}) = 0, \quad i \in E$$

$$c_i(\mathbf{x}) \geq 0, \quad i \in I$$

kde

$$I = \emptyset$$

# Omezení v podobě rovnic

- eliminace proměnných

Jestliže jsou omezení tvořena pouze soustavou  $m$  rovnic, můžeme z nich vyjádřit  $m$  proměnných pomocí zbývajících  $n - m$  proměnných. Za těchto  $m$  proměnných pak můžeme dosadit v účelové funkci a řešit namísto původního problému o  $n$  proměnných s omezeními nepodmíněný minimalizační problém o  $n-m$  proměnných.

# Omezení v podobě rovnic

- eliminace proměnných II

Pokud řešení nepodmíněného problému splňuje omezení původní úlohy, dospěli jsme k řešení.

Takto vytvořený nepodmíněný problém ale obecně nemusí být ekvivalentní původnímu problému, a proto je třeba při eliminaci proměnných zachovávat jistou opatrnost a konfrontovat nalezené řešení s původním zadáním.

# Omezení v podobě rovnic

- eliminace proměnných III

Příklad:

Minimalizuj:  $f(\mathbf{x}) = -x_1 - x_2$

Za předpokladu:  $x_1^2 + x_2^2 = 1$

Řešení:

$$x_2 = \pm \sqrt{1 - x_1^2}$$

$x_2$  dosadíme do rovnice pro  $f(\mathbf{x})$ , odderivujeme a řešíme  $f'(\mathbf{x}) = 0$

globální minimum je řešením rovnice:

$$\min -x_1 - \sqrt{1 - x_1^2}$$

# Omezení v podobě rovnic

- metoda Lagrangeových činitelů

Cílem metody je najít vektory  $\mathbf{x}^*$  a  $\lambda^*$  splňující rovnice:

$$\mathbf{g}(\mathbf{x}) = \sum_{i \in E} \mathbf{a}_i(\mathbf{x}) \cdot \lambda_i$$

$$c_i(\mathbf{x}) = 0, \quad i \in E$$

Kde:             $\mathbf{g}(\mathbf{x})$             gradient  $f(\mathbf{x})$   
                   $\mathbf{a}_i(\mathbf{x})$              $\nabla c_i(\mathbf{x})$

# Omezení v podobě rovnic

- metoda Lagrangeových činitelů II

Pokud máme  $m$  omezení ( $|E| = m$ ), pak dostáváme  $n+m$  rovnic o  $n+m$  neznámých.

Nicméně jde o systém nelineárních rovnic, takže nalezení řešení obecně nemusí být jednoduché. Navíc řešením mohou být kromě lokálních minim také lokální maxima a sedlové body.

# Omezení v podobě rovnic

- metoda Lagrangeových činitelů III

Příklad:

Minimalizuj  $x_1 + x_2$

Za předpokladu:  $x_1^2 - x_2 = 0$

Sestavíme rovnice:

$$\begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 2x_1 \\ -1 \end{pmatrix} \lambda$$

$$x_1^2 - x_2 = 0$$

Odtud dostáváme:

$$\lambda^* = -1, x_1^* = -1/2 \text{ a } x_2^* = 1/4$$

# Omezení v podobě nerovnic

- obecně

Nyní opět rozšíříme své úvahy na obecnou nelineární optimalizační úlohu:

Minimalizuj:

$$f(x), \quad x \in \mathbb{R}^n$$

za předpokladu:

$$c_i(x) = 0, \quad i \in E$$

$$c_i(x) \geq 0, \quad i \in I$$



# Omezení v podobě nerovnic

- obecně II

Necht' opět  $x^*$  je řešením úlohy. V okolí bodu  $x^*$  jsou pak důležité jen ty nerovnice, které představují aktivní omezení v  $x^*$ . Označíme je jako  $I^*$ , kde  $I^* = A^* \cap I$ .

Pokud  $x^*$  je lokálním minimem, pak musí splňovat následující podmínky:

$$g(x^*) = \sum_{i \in A^*} a_i(x^*) \cdot \lambda_i^*$$

a zároveň  $\lambda_i^* \geq 0, i \in I^*$

# Omezení v podobě nerovnic

## - příklad

Ukázka použití podmínek z minulého slidu pro řešení příkladu:

Minimalizuj:  $f(\mathbf{x}) = -x_1 - x_2$

Za předpokladů:  $c_1(\mathbf{x}) = x_2 - x_1^2 \geq 0$

$$c_2(\mathbf{x}) = 1 - x_1^2 - x_2^2 \geq 0$$


Nemáme žádný obecný návod, jak zjistit, které z omezení je aktivní v  $\mathbf{x}^*$ .

V tomto dvourozměrném případě lze nalézt aktivní omezení pomocí obrázku.

# Omezení v podobě nerovnic

– příklad II

Nalezení aktivního omezení pomocí obrázku:



$\Rightarrow$  Aktivní omezení je pouze omezení 2.

# Omezení v podobě nerovnic

– příklad III

Rovnice:

$$g(\mathbf{x}^*) = \sum_{i \in A^*} a_i(\mathbf{x}^*) \cdot \lambda_i^*$$

$$\text{kde: } \lambda_i^* \geq 0, i \in I^*$$

Tedy budou pro náš příklad vypadat následovně:

$$-1 = -2\lambda_2 x_1$$

$$-1 = -2\lambda_2 x_2$$

$$1 - x_1^2 - x_2^2 = 0$$

Uvedená soustava má dvě řešení, ale jen u

$$\text{jednoho z nich je } \lambda_2 \geq 0: \lambda_2 = x_1 = x_2 = \frac{1}{\sqrt{2}}$$

# Omezení v podobě nerovnic

– příklad IV

Při hledání aktivního omezení můžeme také postupovat tak, že systematicky otestujeme všechny kombinace daných omezení.

V našem případě by to tedy byly tyto kombinace:

a)  $A^* = \emptyset$  Je zřejmé, že toto neplatí.

b)  $A^* = \{1\}$  Neexistuje řešení, pro které by bylo  $\lambda_1 \geq 0$ .

c)  $A^* = \{1,2\}$  Neexistuje řešení, pro které by bylo zároveň  $\lambda_1 \geq 0$  a  $\lambda_2 \geq 0$ .

d)  $A^* = \{2\}$  Tady řešení existuje :-).

# Omezení v podobě nerovnic

- podmínky pro vázané extrémny

Na předchozích slidech jsme si ukázali, jakým způsobem lze odvodit nutné podmínky pro lokální minima problému. Dosažené výsledky nyní shrneme do jednoho tvrzení.

# Omezení v podobě nerovnic

- podmínky pro vázané extrémny II

Předtím zavedeme následující termíny:

Podmínky regularity:

- vektory  $a_i^*$  jsou lineárně nezávislé, nebo
- všechna omezení jsou lineární

Lagrangeova funkce (lagrangeián):

$$L(\mathbf{x}, \boldsymbol{\lambda}) = f(\mathbf{x}) - \sum_i \lambda_i \cdot c_i(\mathbf{x})$$

# Omezení v podobě nerovnic

- podmínky pro vázané extrémny III

A nyní nutné podmínky pro lokální minimum problému (Kuhn-Tuckerovy podmínky).

Je-li  $x^*$  lokálním minimem problému a pokud v  $x^*$  platí podmínky regularity, pak existují Lagrangeovy činitele  $\lambda^*$  tak, že  $x^*$  a  $\lambda^*$  splňují následující soustavu omezení:

$$\nabla_x L(x, \lambda) = 0$$

$$c_i(x) = 0, \quad i \in E$$

$$c_i(x) \geq 0, \quad i \in I$$

$$\lambda_i \geq 0, \quad i \in I$$

$$\lambda_i c_i(x) = 0, \quad \forall i$$



# Omezení v podobě nerovnic

- podmínky pro vázané extrémum IV

Dále zavedeme dostatečné podmínky pro lokální minimum problému: Necht' pro  $x^*$  existuje  $\lambda^*$  tak, že platí Kuhn-Tuckerovy podmínky a platí:

$$s^T \cdot \nabla_x^2 L(x^*, \lambda^*) \cdot s > 0$$

pro všechna  $s \neq 0$  taková, že

$$s^T \cdot a_i^* = 0 \quad \text{pro } i \in E \cup I_+^*$$

$$s^T \cdot a_i^* \geq 0 \quad \text{pro } i \in I_0^*$$

kde

$$I_+^* = \{i; i \in I^*, \lambda_i^* > 0\}$$

$$I_0^* = \{i; i \in I^*, \lambda_i^* = 0\}$$

Pak  $x^*$  je ostré lokální minimum úlohy.

# Omezení v podobě nerovnic

- řešení problému

Využití klasických optimalizačních metod:

Simplexová metoda

Metody první derivace (spádové metody, konjugované gradienty)

Metody druhé derivace (Newtonovské metody atd.)

+ respektování omezení při výpočtu kroku  $\delta^{(k)}$

+ testování podmínek, uvedených na předchozích slidech

# Speciální případy NP

- obecně

## **Kvadratické programování:**

kvadratická účelová funkce, lineární omezení

## **Konvexní programování:**

účelová funkce i omezení jsou konvexní funkce

## **Separabilní programování:**

bez smíšených členů ( $2 \cdot x_1 \cdot x_2$ )

## **Lomené programování:**

účelová funkce a omezení jsou podíly lineárních funkcí

## **Celočíselné programování:**

všechny nebo některé proměnné musí být celá čísla

# Kvadratické programování

- obecně

Přirozeným zobecněním lineárního programování je úloha kvadratického programování:

Minimalizuj:

$$q(\mathbf{x}) = \frac{1}{2} \cdot \mathbf{x}^T \mathbf{G} \mathbf{x} + \mathbf{g}^T \mathbf{x}$$

Za předpokladů:

$$\mathbf{a}_i^T \mathbf{x} = b_i, i \in E$$

$$\mathbf{a}_i^T \mathbf{x} \geq b_i, i \in I$$

# Kvadratické programování

- obecně II

Tato úloha má význam nejen sama o sobě, ale také proto, že některé metody pro nelineární programování s omezeními převádějí obecný problém na posloupnost kvadratických problémů.

Pokud je Hessova matice  $G$  kladně semidefinitní, pak je funkce  $q$  konvexní a problém je speciálním případem úlohy konvexního programování a tedy má je jediné minimum.

# Kvadratické programování

- obecně III

Naopak úloha

$$\min \{-x^T x; -1 \leq x_i \leq 1, i = 1, \dots, n\}$$

má lokální minimum ve všech vrcholech intervalu  $[-1, 1]^n$ , tj. celkem  $2^n$  lokálních minim.

Lze dokázat, že úloha kvadratického programování je NP-těžká (vzhledem k  $n$ ).

# Kvadratické programování

- metody řešení

Omezení v podobě rovnic:

- Přímá eliminace proměnných
- Metoda nulového prostoru

Omezení v podobě nerovnic (obecné):

- Metoda aktivní množiny

# Celočíselné programování

- obecně

Řeší úlohy typu:

minimalizuj:

$$f(\mathbf{x})$$

za předpokladu:

$$c_i(\mathbf{x}) = 0, i \in E$$

$$c_i(\mathbf{x}) \geq 0, i \in I$$

přičemž pro všechny složky vektoru řešení  $\mathbf{x}$

$$\text{platí: } x_i \in Z$$



# Celočíselné programování

- příklad problému

Problém batohu:

Mějme  $n$  předmětů, pro něž jsou zadány veličiny:

$a_j$  hmotnost  $j$ -tého předmětu

$c_j$  cena  $j$ -tého předmětu

Batoh je třeba naplnit tak, abychom maximalizovali celkovou cenu nákladu a nepřekročili přitom limit  $b$  jeho hmotnosti.

# Celočíselné programování

- příklad problému II

Zavedeme proměnné  $x_j$  ( $j = 1, 2, \dots, n$ ):

$x_j = 1$     jestli naložíme  $j$ -tý předmět

$x_j = 0$     jinak

Matematická formulace úlohy:

$$\max f(\mathbf{x}) = \sum_{j=1}^n c_j x_j$$

Za předpokladu:

$$\sum_{j=1}^n a_j x_j \leq b \quad x_j \in \{0, 1\}; j = 1, 2, \dots, n$$

# Celočíselné programování

- metody řešení

Metody řezných (sečných) nadrovin

Gomoryho algoritmus

Metoda větví a mezí

Speciální metody (maďarská metoda atd.)

# Celočíselné programování

- metoda větví a mezí

V současné době nejpoužívanější metoda celočíselného programování.

Metoda je dostatečně obecná, takže ji lze použít na mnoho úloh.

Využívá se pro řešení celočíselných úloh LP i v rámci profesionálních programových systémů.

# Celočíselné programování

- metoda větví a mezí II

Předpokládejme, že jsme našli optimální řešení, jehož některé (nebo všechny) složky  $x_i$  nesplňují podmínku celočíselnosti. Postupujeme následovně:

1) Vybereme takové  $x_i$  z optimálního řešení, které není celočíselné. (Při více takových  $x_i$  nezáleží na tom, které vybereme.)

Zvolíme interval: 
$$p \leq x_i \leq q,$$

kde  $p$  je nejbližší menší celé číslo a  $q$  nejbližší větší celé číslo vzhledem k  $x_i$ .

Vzhledem k tomu, že celočíselné řešení není uvnitř intervalu  $(p,q)$ , hledáme ho vně.

# Celočíselné programování

- metoda větví a mezí III

2) Přidáme k původní úloze podmínku ve tvaru  $x_i \leq p$ , tím vytvoříme **úlohu 2a**, a najdeme optimální řešení (nemusí být celočíselné).

Poté přidáme k původní úloze (tzn. úloze bez  $x_i \leq p$ ) podmínku ve tvaru  $x_i \geq q$ , tím vytvoříme **úlohu 2b**, a najdeme optimální řešení (nemusí být celočíselné).

# Celočíselné programování

- metoda větví a mezí IV

3) Z optimálních řešení úloh 2a a 2b vybereme tu nadějnější větev (s vyšší hodnotou účelové funkce). V případě, že optimální řešení nadějnější větve ještě není celočíselné, pokračujeme stejně jako v bodě 2.

Opakujeme body 2 a 3, dokud nedospějeme k *celočíselnému optimálnímu řešení*.

# Celočíselné programování

- metoda větví a mezí - příklad

Minimalizuj:

$$f(x) = 2x_1 + 3x_2$$

Za předpokladu:

$$4x_1 + 3x_2 \leq 13$$

$$x_1 + 2x_2 \leq 6$$

$$x_1, x_2 \geq 0$$

$x_1, x_2$  - celé




# Celočíselné programování

- metoda větví a mezí – příklad II

1) Nalezení optimálního řešení ( $x$ ) v  $\mathbb{R}^2$ .

Graficky, výsledek:

$$x = (8/5, 11/5), f(x) = 49/5$$



# Celočíselné programování

- metoda větví a mezí – příklad III

2) Vybereme  $x_1$  a interval  $p \leq x_1 \leq q$ ,

tedy je:  $1 \leq (x_1 = 8/5) \leq 2$

Úloha 2a – 1. větev:

Přidáme k zadání podmínku:  $2 \leq x_1$

Řešení:  $x' = (2, 5/3)$ ,  $f(x') = 9$

Úloha 2b – 2. větev:

Přidáme k zadání podmínku:  $x_1 \leq 1$

Řešení:  $x' = (1, 5/2)$ ,  $f(x') = 19/2$

# Celočíselné programování

- metoda větví a mezí – příklad IV

3) Nadějnější větev je větev 2  $\Rightarrow \mathbf{x} = (1, 5/2)$

2) Vybereme  $x_2$  a interval  $\mathbf{p} \leq \mathbf{x}_2 \leq \mathbf{q}$ ,

tedy je:  $2 \leq (\mathbf{x}_2 = 5/2) \leq 3$

Úloha 2a – 1. větev:

Přidáme k zadání podmínku:  $\mathbf{x}_2 \leq 2$

Řešení:  $\mathbf{x}' = (1, 2), f(\mathbf{x}') = 8$  **STOP**

Úloha 2b – 2. větev:

Přidáme k zadání podmínku:  $3 \leq \mathbf{x}_2$


Řešení:  $\mathbf{x}' = (0, 3), f(\mathbf{x}') = 9$  **STOP**

$\Rightarrow$  Celočíselným optimem je bod  $\mathbf{x} = (0, 3)$

# Celočíselné programování

- metoda větví a mezí – příklad V

Znázornění výpočtu pomocí stromu:



# Cvičení

- metoda Lagrangeových činitelů

Příklad:

Minimalizuj  $-x_1^2 - 4x_2^2$

Za předpokladu:  $x_1 + 2x_2 = 6$

Sestavíme rovnice:

$$\begin{pmatrix} -2x_1 \\ 8x_2 \end{pmatrix} = \begin{pmatrix} 1 \\ 2 \end{pmatrix} \lambda$$

$$x_1 + 2x_2 = 6$$

Odtud dostáváme:

$$\lambda^* = -6, x_1^* = 3 \text{ a } x_2^* = 3/2$$

# Cvičení

- celočíselné programování

Maximalizuj:

$$f(x) = 2x_1 + x_2$$

Za předpokladu:

$$x_1 + x_2 \leq 5$$

$$-x_1 + 2x_2 \leq 0$$

$$6x_1 + 2x_2 \leq 21$$

$$x_1, x_2 \geq 0$$

$$x_1, x_2 - \text{celé}$$