

# Matematická analýza 2

## Spádové metody

Pavel Hrabák<sup>1</sup>, Tomáš Kalvoda<sup>2</sup>, Ivo Petr<sup>3</sup>

<sup>1</sup>pavel.hrabak@fit.cvut.cz, <sup>2</sup>tomas.kalvoda@fit.cvut.cz, <sup>3</sup>ivo.petr@fit.cvut.cz

Katedra aplikované matematiky  
Fakulta informačních technologií  
České vysoké učení technické v Praze

1. listopadu 2024  
ZS 2024/2025



# Hlavní body

- 1 Obecný popis spádové metody
- 2 Volby směru
- 3 Gradientová metoda / Gradientní sestup
- 4 Newtonova metoda

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \alpha \nabla f(\mathbf{x}_n)^T$$



# Hlavní výsledky této přednášky

- Popis principu spádové metody pro hledání lokálních extrémů.
  
  
  
  
  
  
  
  
  
  
- Ukázka dvou konkrétních metod.



# Hlavní body

## 1 Obecný popis spádové metody

## 2 Volby směru

## 3 Gradientová metoda / Gradientní sestup

## 4 Newtonova metoda

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \alpha \nabla f(\mathbf{x}_n)^T$$



# Úloha

V této sekci si ukážeme obecný postup při *numerickém* hledání lokálních minim<sup>1</sup> funkcí  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  bez omezujících podmínek na proměnné  $x_i$ ,  $i = 1, 2, \dots, n$ .

Řešíme tedy úlohu

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

kde

- $f : \mathbb{R}^n \rightarrow \mathbb{R}$  a  $x$  probíhá všechny možné hodnoty  $\mathbf{x} \in D_f$ ,
- definiční obor  $D_f$  je otevřená množina,
- funkce  $f$  je minimálně dvakrát spojitě diferencovatelná<sup>2</sup>.

---

<sup>1</sup>To není žádné omezení, maxima  $f$  jsou minima  $-f$ .

<sup>2</sup>Tj. všechny její parciální derivace až do druhého řádu včetně jsou spojitě na  $D_f$ .



# Spádová metoda: princip

Řešení hledáme iterativně pomocí tzv. **spádové metody** (*descent methods*), jejichž princip je jednoduchý:

V každé iteraci se snažíme snížit hodnotu minimalizované funkce  $f$ .

Nechť je dáno  $\mathbf{x}^{(1)} \in D_f$ . Sestavíme posloupnost vektorů  $\mathbf{x}^{(k)}$ ,  $k = 1, 2, \dots$ , podle rekurentního předpisu

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + t^{(k)} \Delta \mathbf{x}^{(k)},$$

kde „ $\Delta \mathbf{x}^{(k)}$ “ je vhodně zvolený vektor (**směr poklesu**) a  $t^{(k)}$  **délka** tzv. **kroku**.

Následující člen vždy musí být zvolen tak, aby  $f(\mathbf{x}^{(k+1)}) < f(\mathbf{x}^{(k)})$ , samozřejmě vyjma případu, kdy  $\mathbf{x}^{(k)}$  je již optimální (je bodem lokálního minima).




# Spádová metoda: obecný postup

Jeden krok typické spádové metody lze tedy popsat následovně (odpustíme si horní indexy, budeme mluvit o jednom kroku):

Nechť je dáno  $\mathbf{x} \in D_f$ .

1. Urči směr  $\Delta\mathbf{x}$ .
2. Zvol velikost kroku  $t > 0$ .
3. Napočti  $\mathbf{x} + t\Delta\mathbf{x}$  a ulož ho do  $\mathbf{x}$ .



Tento postup opakuj dokud není splněno *kritérium pro zastavení iterační smyčky*. Praktické kritérium pro zastavení může být například dostatečná nulovost gradientu. Je také vhodné kontrolovat maximální povolený počet iterací.



# Spádová metoda: obecná volba směru

Konkrétní volbě směru  $\Delta \mathbf{x}$  se budeme věnovat podrobněji níže. V tento okamžik pouze uvedme, že pro  $t$  blízka nule přibližně platí (viz Taylor)

$$f(\mathbf{x} + t\Delta \mathbf{x}) \approx f(\mathbf{x}) + t\nabla f(\mathbf{x}) \cdot \Delta \mathbf{x}.$$

Pokud chceme být schopní **i malým krokem funkční hodnotu zmenšit**, musíme směr kroku, tj.  $\Delta \mathbf{x}$ , vždy volit tak, aby

$$\nabla f(\mathbf{x}) \cdot \Delta \mathbf{x} < 0.$$

Také ve zbytku popisu algoritmu předpokládáme, že v každém kroku  $\nabla f(\mathbf{x}) \neq 0$ . Pokud by gradient byl nulový, pak běh algoritmu již skončil.





# Spádová metoda: volba $t$ pomocí zpětného krokování

Nechť máme bod  $\mathbf{x}$  a již jsme zvolili směr  $\Delta\mathbf{x}$ .

Ideálně bychom chtěli  $t > 0$  zvolit tak, aby v tomto bodě  $t$  bylo nabyto minimum funkce **jedné** proměnné  $s > 0$ ,

$$s \mapsto f(\mathbf{x} + s\Delta\mathbf{x})$$

Analytické řešení tohoto problému nemusí být obecně jednoduché, stejně bychom se museli uchýlit k numerickým metodám (ovšem s jednou proměnnou!).

V praxi se často používá tzv. **zpětné krokování** (*backtracking*), které popíšeme na následujícím slide.



# Spádová metoda: volba $t$ pomocí zpětného krokování

Algoritmus **zpětného krokování** probíhá následovně:


- Jsou dány  $f$ , směr  $\Delta \mathbf{x}$ , bod  $\mathbf{x} \in D_f$  a parametry  $\alpha \in (0, 1/2)$ ,  $\beta \in (0, 1)$ .
- Polož  $t := 1$ . Dokud  $f(\mathbf{x} + t\Delta \mathbf{x}) > f(\mathbf{x}) + \alpha t \nabla f(\mathbf{x}) \cdot \Delta \mathbf{x}$  změň  $t$  na  $\beta t$ .
- Vrať  $t$ .

Parametr  $\alpha$  kontroluje, jaký pokles jsme ochotni akceptovat. Parametr  $\beta$  pak udává, jak rychle zmenšujeme prvotní  $t$  (proto zpětné krokování).



# Spádová metoda: volba $t$ pomocí zpětného krokování

$$z(t) = f(\mathbf{x} + t\Delta\mathbf{x})$$



Na obrázku je znázorněn řez grafu funkce nad přímkou  $\mathbf{x} + t\Delta\mathbf{x}$  (černě), tečna  $f(\mathbf{x}) + t\nabla f(\mathbf{x}) \cdot \Delta\mathbf{x}$  a přípustná mez poklesu  $f(\mathbf{x}) + \alpha t\nabla f(\mathbf{x}) \cdot \Delta\mathbf{x}$ .

- Bod  $t_1$  by nebyl akceptován (i když k poklesu došlo).
- Bod  $t_2$  by již akceptován byl (i když nedává nejmenší možnou hodnotu).



# Hlavní body

- 1 Obecný popis spádové metody
- 2 Volby směru
- 3 Gradientová metoda / Gradientní sestup
- 4 Newtonova metoda

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \alpha \nabla f(\mathbf{x}_n)^T$$



## Volby směru

Předpokládejme, že jsme v bodě  $\mathbf{x}$  a vydáme se malým krokem směrem  $\mathbf{s}$ . Potom lineární aproximace změny funkční hodnoty je

$$f(\mathbf{x} + \mathbf{s}) \approx f(\mathbf{x}) + \nabla f(\mathbf{x}) \cdot \mathbf{s}.$$

Směry, ve kterých dojde k poklesu funkční hodnoty, splňují  $\nabla f(\mathbf{x}) \cdot \mathbf{s} < 0$ .



## Volby směru

Předpokládejme, že jsme v bodě  $\mathbf{x}$  a vydáme se malým krokem směrem  $\mathbf{s}$ . Potom lineární aproximace změny funkční hodnoty je

$$f(\mathbf{x} + \mathbf{s}) \approx f(\mathbf{x}) + \nabla f(\mathbf{x}) \cdot \mathbf{s}.$$

Směry, ve kterých dojde k poklesu funkční hodnoty, splňují  $\nabla f(\mathbf{x}) \cdot \mathbf{s} < 0$ .

Zvolme normu  $\|\cdot\|$  na  $\mathbb{R}^n$ . Směr nejprudšího poklesu je pak dán řešením úlohy

$$\Delta \mathbf{x} = \operatorname{argmin} \{ \nabla f(\mathbf{x}) \cdot \mathbf{s} \mid \|\mathbf{s}\| \leq 1 \}.$$



## Volby směru

Předpokládejme, že jsme v bodě  $\mathbf{x}$  a vydáme se malým krokem směrem  $\mathbf{s}$ . Potom lineární aproximace změny funkční hodnoty je

$$f(\mathbf{x} + \mathbf{s}) \approx f(\mathbf{x}) + \nabla f(\mathbf{x}) \cdot \mathbf{s}.$$

Směry, ve kterých dojde k poklesu funkční hodnoty, splňují  $\nabla f(\mathbf{x}) \cdot \mathbf{s} < 0$ .

Zvolme normu  $\|\cdot\|$  na  $\mathbb{R}^n$ . Směr nejprudšího poklesu je pak dán řešením úlohy

$$\Delta \mathbf{x} = \operatorname{argmin} \{ \nabla f(\mathbf{x}) \cdot \mathbf{s} \mid \|\mathbf{s}\| \leq 1 \}.$$

Pro *reálnou* symetrickou pozitivně definitní matici  $\mathbf{P} \in \mathbb{R}^{n,n}$  můžeme definovat normu (pro Euklidovskou máme  $\mathbf{P} = \mathbf{E}$ )

$$\|\mathbf{s}\|_{\mathbf{P}} := \sqrt{\mathbf{s}^T \mathbf{P} \mathbf{s}}, \quad \mathbf{s} \in \mathbb{R}^n.$$



## Volby směru

Předpokládejme, že jsme v bodě  $\mathbf{x}$  a vydáme se malým krokem směrem  $\mathbf{s}$ . Potom lineární aproximace změny funkční hodnoty je

$$f(\mathbf{x} + \mathbf{s}) \approx f(\mathbf{x}) + \nabla f(\mathbf{x}) \cdot \mathbf{s}.$$

Směry, ve kterých dojde k poklesu funkční hodnoty, splňují  $\nabla f(\mathbf{x}) \cdot \mathbf{s} < 0$ .

Zvolme normu  $\|\cdot\|$  na  $\mathbb{R}^n$ . Směr nejprudšího poklesu je pak dán řešením úlohy

$$\Delta \mathbf{x} = \operatorname{argmin} \{ \nabla f(\mathbf{x}) \cdot \mathbf{s} \mid \|\mathbf{s}\| \leq 1 \}.$$

Pro *reálnou* symetrickou pozitivně definitní matici  $\mathbf{P} \in \mathbb{R}^{n,n}$  můžeme definovat normu (pro Euklidovskou máme  $\mathbf{P} = \mathbf{E}$ )

$$\|\mathbf{s}\|_{\mathbf{P}} := \sqrt{\mathbf{s}^T \mathbf{P} \mathbf{s}}, \quad \mathbf{s} \in \mathbb{R}^n.$$

Směr největšího poklesu vzhledem k této normě je pak dán vektorem

$$\Delta \mathbf{x} = -\mathbf{P}^{-1} \nabla f(\mathbf{x})^T.$$





# Důkaz pro případ $P = E$

Uvažme tedy obecně úlohu minimalizovat lineární reálnou funkci

$$g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}, \quad D_g = \mathbb{R}^n,$$

kde  $\mathbf{c} \in \mathbb{R}^n$  je zadaný vektor, za podmínky

$$\|\mathbf{s}\|^2 = \mathbf{s}^T \mathbf{s} = 1.$$

Vzpomeňme si, že ze Schwarzovy nerovnosti plyne nerovnost  $|g(\mathbf{s})| \leq \|\mathbf{c}\| \|\mathbf{s}\|$ , což za uvedené podmínky na vektory  $\mathbf{s}$  implikuje  $|g(\mathbf{s})| \leq \|\mathbf{c}\|$ . Této **maximální** meze ale snadno **dosáhneme** právě volbami

$$\mathbf{s}_+ = \frac{\mathbf{c}}{\|\mathbf{c}\|} \quad \text{a} \quad \mathbf{s}_- = -\frac{\mathbf{c}}{\|\mathbf{c}\|}.$$

První vektor dává maximální hodnotu a druhý minimální hodnotu funkce  $g$  za uvedených podmínek. To jsme přesně očekávali: v kontextu předcházejících úvah je  $\mathbf{c}$  gradient.



## Důkaz pro obecný případ: náčrt

Uvažme funkci  $g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}$ ,  $\mathbf{s} \in D_g = \mathbb{R}^n$ , pro zadaný vektor  $\mathbf{c} \in \mathbb{R}^n$ . Hledáme řešení úlohy

$$\left\{ \begin{array}{l} \text{minimalizuj} \quad g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}, \\ \text{za podmínky} \quad \mathbf{s}^T \mathbf{P} \mathbf{s} = 1, \\ \mathbf{s} \in \mathbb{R}^n. \end{array} \right.$$

kde  $\mathbf{P}$  je (reálná) symetrická pozitivně definitní matice.



## Důkaz pro obecný případ: náčrt

Uvažme funkci  $g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}$ ,  $\mathbf{s} \in D_g = \mathbb{R}^n$ , pro zadaný vektor  $\mathbf{c} \in \mathbb{R}^n$ . Hledáme řešení úlohy

$$\begin{cases} \text{minimalizuj} & g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}, \\ \text{za podmínky} & \mathbf{s}^T \mathbf{P} \mathbf{s} = 1, \\ & \mathbf{s} \in \mathbb{R}^n. \end{cases}$$

kde  $\mathbf{P}$  je (reálná) symetrická pozitivně definitní matice.

Matice  $\mathbf{P}$  má všechna vlastní čísla kladná a je diagonalizovatelná, tj.

$$\mathbf{P} = \mathbf{U} \text{diag}(\lambda_1, \dots, \lambda_n) \mathbf{U}^T,$$

kde  $\lambda_i > 0$ ,  $i \in \hat{n}$ , jsou vlastní čísla matice  $\mathbf{P}$  a matice  $\mathbf{U}$  je (reálná) a ortogonální.



## Důkaz pro obecný případ: náčrt

Uvažme funkci  $g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}$ ,  $\mathbf{s} \in D_g = \mathbb{R}^n$ , pro zadaný vektor  $\mathbf{c} \in \mathbb{R}^n$ . Hledáme řešení úlohy

$$\begin{cases} \text{minimalizuj} & g(\mathbf{s}) = \mathbf{c}^T \mathbf{s}, \\ \text{za podmínky} & \mathbf{s}^T \mathbf{P} \mathbf{s} = 1, \\ & \mathbf{s} \in \mathbb{R}^n. \end{cases}$$

kde  $\mathbf{P}$  je (reálná) symetrická pozitivně definitní matice.

Matice  $\mathbf{P}$  má všechna vlastní čísla kladná a je diagonalizovatelná, tj.

$$\mathbf{P} = \mathbf{U} \text{diag}(\lambda_1, \dots, \lambda_n) \mathbf{U}^T,$$

kde  $\lambda_i > 0$ ,  $i \in \hat{n}$ , jsou vlastní čísla matice  $\mathbf{P}$  a matice  $\mathbf{U}$  je (reálná) a ortogonální.

Definujme matici  $\mathbf{P}^{1/2}$  předpisem

$$\mathbf{P}^{1/2} := \mathbf{U} \text{diag}(\lambda_1^{1/2}, \dots, \lambda_n^{1/2}) \mathbf{U}^T.$$

Tato matice splňuje  $\mathbf{P}^{1/2} \mathbf{P}^{1/2} = \mathbf{P}$ , je (reálná) symetrická a regulární.



## Důkaz pro obecný případ: náčrt

Naší minimalizační úlohu proto můžeme přepsat do následujícího tvaru,

$$\begin{cases} \text{minimalizuj} & g(\mathbf{s}) = ((\mathbf{P}^{1/2})^{-1}\mathbf{c})^T \mathbf{P}^{1/2}\mathbf{s}, \\ \text{za podmínky} & (\mathbf{P}^{1/2}\mathbf{s})^T (\mathbf{P}^{1/2}\mathbf{s}) = 1, \mathbf{s} \in \mathbb{R}^n. \end{cases}$$



## Důkaz pro obecný případ: náčrt

Naší minimalizační úlohu proto můžeme přepsat do následujícího tvaru,

$$\begin{cases} \text{minimalizuj} & g(\mathbf{s}) = ((\mathbf{P}^{1/2})^{-1}\mathbf{c})^T \mathbf{P}^{1/2}\mathbf{s}, \\ \text{za podmínky} & (\mathbf{P}^{1/2}\mathbf{s})^T (\mathbf{P}^{1/2}\mathbf{s}) = 1, \mathbf{s} \in \mathbb{R}^n. \end{cases}$$

Pokud provedeme změnu souřadnic  $\mathbf{z} := \mathbf{P}^{1/2}\mathbf{s}$ , tak dostaneme minimalizační úlohu tvaru

$$\begin{cases} \text{minimalizuj} & \tilde{g}(\mathbf{z}) = ((\mathbf{P}^{1/2})^{-1}\mathbf{c})^T \mathbf{z}, \\ \text{za podmínky} & \mathbf{z}^T \mathbf{z} = 1 \quad \mathbf{z} \in \mathbb{R}^n. \end{cases}$$

O té z předchozího případu víme, že nabývá maxima a minima v

$$\mathbf{z}_+ = \frac{(\mathbf{P}^{1/2})^{-1}\mathbf{c}}{\|(\mathbf{P}^{1/2})^{-1}\mathbf{c}\|} \quad \text{a} \quad \mathbf{z}_- = -\frac{(\mathbf{P}^{1/2})^{-1}\mathbf{c}}{\|(\mathbf{P}^{1/2})^{-1}\mathbf{c}\|}.$$

V původních proměnných pak v

$$\mathbf{s}_+ = \frac{\mathbf{P}^{-1}\mathbf{c}}{\|(\mathbf{P}^{1/2})^{-1}\mathbf{c}\|} \quad \text{a} \quad \mathbf{s}_- = -\frac{\mathbf{P}^{-1}\mathbf{c}}{\|(\mathbf{P}^{1/2})^{-1}\mathbf{c}\|}.$$



# Hlavní body

- 1 Obecný popis spádové metody
- 2 Volby směru
- 3 Gradientová metoda / Gradientní sestup**
- 4 Newtonova metoda

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \alpha \nabla f(\mathbf{x}_n)^T$$



# Gradientová metoda / Gradientní sestup

Očividným kandidátem pro volbu směru kroku při minimalizaci je krok ve směru záporně vzatého gradientu (je-li nenulový), tj. volíme  $\mathbf{P} = \mathbf{E}$ ,


$$\Delta \mathbf{x} := -\nabla f(\mathbf{x}).$$

Potom skutečně

$$\nabla f(\mathbf{x}) \cdot \Delta \mathbf{x} = -\|\Delta \mathbf{x}\|^2 < 0$$

## Poznámky:

- Relativně snadno spočítatelný.
- Výsledný směr nemusí být „nejvhodnější“.
- Nevyužívá informaci obsaženou ve vyšších derivacích.



Vpravo je ukázka pro  $f(x, y) = \frac{1}{9}x^2 + y^2$ .



# Hlavní body

- 1 Obecný popis spádové metody
- 2 Volby směru
- 3 Gradientová metoda / Gradientní sestup
- 4 Newtonova metoda

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \alpha \nabla f(\mathbf{x}_n)^T$$



# Newtonova metoda

Newtonova metoda volí směr v bodě  $\mathbf{x}$  **vzhledem k Hesseově matici**  $\mathbf{P} = \nabla^2 f(\mathbf{x})$ , tedy dle výpočtů výše

$$\mathbf{s}_- = - \frac{\mathbf{P}^{-1} \mathbf{c}}{\|(\mathbf{P}^{1/2})^{-1} \mathbf{c}\|},$$


kde  $\mathbf{c} = \nabla f(\mathbf{x})$ . Tj. bez pro nás nepodstatného normalizačního faktoru dostáváme

$$\Delta \mathbf{x} = -(\nabla^2 f(\mathbf{x}))^{-1} \cdot \nabla f(\mathbf{x})^T.$$


- Vpravo uvádíme opět ukázkou pro

$$f(x, y) = \frac{1}{9}x^2 + y^2.$$

- Pro kvadratickou funkci nepřekvapivě dostáváme směr přímo k  $\theta$ .



# Newtonova metoda: poznámky


- Neplést s Newtonovou metodou v  BI-MA1.
- Výpočetně je tato metoda náročnější. Není ale potřeba počítat maticovou inverzi, směr  $\Delta \mathbf{x}$  je řešením nehomogenní lineární soustavy

$$\nabla^2 f(\mathbf{x}) \cdot \Delta \mathbf{x} = \nabla f(\mathbf{x})^T.$$

- Lze očekávat podstatně lepší míru konvergence než u obyčejné gradientové metody.
- Existuje mnoho modifikací této metody, které zjednodušují výpočet ale stále se snaží získat informace o derivacích druhého řádu (Hesseově matici).



# Newtonova metoda: poznámky

- Neplést s Newtonovou metodou v  BI-MA1.
- Výpočetně je tato metoda náročnější. Není ale potřeba počítat maticovou inverzi, směr  $\Delta \mathbf{x}$  je řešením nehomogenní lineární soustavy

$$\nabla^2 f(\mathbf{x}) \cdot \Delta \mathbf{x} = \nabla f(\mathbf{x})^T.$$

- Lze očekávat podstatně lepší míru konvergence než u obyčejné gradientové metody.
- Existuje mnoho modifikací této metody, které zjednodušují výpočet ale stále se snaží získat informace o derivacích druhého řádu (Hesseově matici).



# Hlavní body

## 5 Dodatek

$$\mathbf{x}_{n+1} = \mathbf{x}_n + \alpha \nabla f(\mathbf{x}_n)^T$$





# Komentář

TBA

