

# Optimalizace

Metody hledání volných lokálních extrémů

---

Tomáš Kroupa, Mirko Navara

21. 4. 2024

FEL ČVUT

1. Vnitřek a hranice množiny
2. Typy extrémů
3. Podmínka prvního řádu pro extrémy
4. Parciální derivace druhého řádu (Hessova matice), hessián
5. Taylorův polynom (pro funkci více proměnných, do stupně 2)
6. Podmínky druhého řádu pro extrémy
7. Iterační metody
8. Gradientní metody
9. Newtonova metoda


## Vnitřek a hranice množiny

Nechť  $X \subseteq \mathbb{R}^n$ . Bod  $\mathbf{x} \in \mathbb{R}^n$  je její

- **vnitřní bod**, pokud  $\exists \varepsilon > 0 : B_\varepsilon(\mathbf{x}) \subseteq X$ ,
- **vnější bod**, pokud  $\exists \varepsilon > 0 : B_\varepsilon(\mathbf{x}) \subseteq \mathbb{R}^n \setminus X$ , tj.  $B_\varepsilon(\mathbf{x}) \cap X = \emptyset$ ,
- **hraniční bod**, pokud  $\forall \varepsilon > 0 : B_\varepsilon(\mathbf{x}) \cap X \neq \emptyset, B_\varepsilon(\mathbf{x}) \cap (\mathbb{R}^n \setminus X) \neq \emptyset$ .

**Které body jsou vnitřní a které hraniční?**

$$X = \{(x, y) \in \mathbb{R}^2 \mid x^2 + y^2 \leq 1, y > 0\} \cup \{(1, 1)\}$$



## Extrémy funkce na množině



Funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  nabývá na množině  $X \subseteq \mathbb{R}^n$  v bodě  $\mathbf{x} \in X$

- **minima**, pokud  $f(\mathbf{x}) \leq f(\mathbf{y})$  pro všechna  $\mathbf{y} \in X$ ,
- **lokálního minima**, pokud existuje  $\varepsilon > 0$  tak, že  $f(\mathbf{x}) \leq f(\mathbf{y})$  pro všechna  $\mathbf{y} \in X \cap B_\varepsilon(\mathbf{x})$ .

(Lokální) minimum v bodě  $\mathbf{x}$  je

- **volné**, pokud  $\mathbf{x}$  je vnitřním bodem množiny  $X$ ,
- **vázané**, pokud  $\mathbf{x}$  je hraničním bodem množiny  $X$ .

# Extrémy funkce na množině – příklady



## Podmínka prvního řádu

**Stacionární bod**  $\mathbf{x} \in \mathbb{R}^n$  funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  splňuje  $f'(\mathbf{x}) = \mathbf{0}$ .

### Věta

Nechť  $X \subseteq \mathbb{R}^n$ ,  $\mathbf{x} \in X$ , je vnitřní bod množiny  $X$  a  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je diferencovatelná v  $\mathbf{x}$ . Je-li  $\mathbf{x}$  lokální extrém funkce  $f$  na  $X$ , platí

$$f'(\mathbf{x}) = \mathbf{0},$$

tj.  $\mathbf{x}$  je stacionární bod funkce  $f$ .

Stacionární body se celkem dobře hledají, takže mnoho úloh se budeme snažit převést na řešení soustavy rovnic  $f'(\mathbf{x}) = \mathbf{0}$ .

K rozhodnutí, zda stacionární bod je extrém, nám mohou (ale nemusí!) pomoci druhé derivace.

## Parciální derivace druhého řádu

### Věta

Nechť  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  a  $\mathbf{x} \in \mathbb{R}^n$ . Jestliže druhé parciální derivace

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = D_j D_i f(\mathbf{x}), \quad \frac{\partial^2 f(\mathbf{x})}{\partial x_j \partial x_i} = D_i D_j f(\mathbf{x})$$

v bodě  $\mathbf{x}$  existují a jsou v bodě  $\mathbf{x}$  spojité, potom jsou si rovny.

Hessova matice je


$$f''(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_1} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_n} \end{bmatrix} = \begin{bmatrix} D_1 D_1 f(\mathbf{x}) & \cdots & D_n D_1 f(\mathbf{x}) \\ \vdots & \ddots & \vdots \\ D_1 D_n f(\mathbf{x}) & \cdots & D_n D_n f(\mathbf{x}) \end{bmatrix} \in \mathbb{R}^{n \times n}$$

Obvykle symetrická, je maticí nějaké kvadratické formy.

Determinant Hessovy matice,  $\det f''(\mathbf{x})$ , se nazývá **hessián**.

## Taylorův polynom pro funkci $f: \mathbb{R}^n \rightarrow \mathbb{R}$

Hledáme polynom  $k$ -tého stupně  $T_k: \mathbb{R}^n \rightarrow \mathbb{R}$ , který má v bodě  $\mathbf{x}$  všechny parciální derivace až do řádu  $k$  stejné jako funkce  $f$ .



### Taylorovy polomy v bodě $\mathbf{x}$ do stupně 2

$$T_0(\mathbf{y}) = f(\mathbf{x})$$

$$T_1(\mathbf{y}) = f(\mathbf{x}) + f'(\mathbf{x})(\mathbf{y} - \mathbf{x})$$

$$T_2(\mathbf{y}) = f(\mathbf{x}) + f'(\mathbf{x})(\mathbf{y} - \mathbf{x}) + \frac{1}{2}(\mathbf{y} - \mathbf{x})^\top f''(\mathbf{x})(\mathbf{y} - \mathbf{x})$$



### Věta

Nechť  $X \subseteq \mathbb{R}^n$ ,  $\mathbf{x} \in X$  je vnitřní bod množiny  $X$  a  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je dvakrát diferencovatelná v  $\mathbf{x}$ . Je-li  $\mathbf{x}$  stacionární bod, platí:

- Pokud je  $\mathbf{x}$  lokální minimum, pak je Hessova matice  $f''(\mathbf{x})$  pozitivně semidefinitní.
- Pokud je  $f''(\mathbf{x})$  pozitivně definitní, pak je  $\mathbf{x}$  ostré lokální minimum.
- Pokud je  $f''(\mathbf{x})$  indefinitní, pak  $\mathbf{x}$  není lokální extrém, ale **sedlový bod**.

## Iterační metody **minimalizace funkce**

Hledáme lokální minimum funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  pomocí konstrukce posloupnosti bodů  $\mathbf{x}_0, \mathbf{x}_1, \dots \in \mathbb{R}^n$ . Volíme počáteční bod  $\mathbf{x}_0 \in \mathbb{R}^n$ , **směr hledání**  $\mathbf{v}_k \in \mathbb{R}^n$  a parametr  $\alpha_k > 0$ , určující **délku kroku**  $\alpha_k \|\mathbf{v}\|$ .

### Iterace

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k.$$

- **Sestupná metoda** splňuje  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$ .
- **Sestupný směr**  $\mathbf{v}_k$  splňuje  $f'(\mathbf{x}_k) \mathbf{v}_k < 0$  (tj.  $\nabla f(\mathbf{x}_k)^T \mathbf{v}_k < 0$ ).

### Iterace gradientní metody

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \nabla f(\mathbf{x}_k) = \mathbf{x}_k - \alpha_k f'(\mathbf{x}_k)^T.$$

- Směr  $-\nabla f(\mathbf{x}_k)$  je sestupný.
- Optimální parametr  $\alpha_k$  lze nalézt minimalizací funkce

$$\varphi_k(\alpha) := f(\mathbf{x}_k + \alpha \mathbf{v}_k),$$

ale často to nestojí za velké úsilí.

- Můžeme zvolit  $\alpha$  velké a exponenciálně zmenšovat, dokud nedocílíme pokles kritéria (pokud každý pokus stojí stejně!).
- Robustní metoda.
- Může konvergovat velmi pomalu.

## Newtonova metoda řešení soustavy rovnic

Hledáme řešení soustavy rovnic  $\mathbf{g}(\mathbf{x}) = \mathbf{0}$ , kde  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^n$  je diferencovatelné zobrazení.

$$T_1(\mathbf{x}_{k+1}) = \mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k) (\mathbf{x}_{k+1} - \mathbf{x}_k) = \mathbf{0}.$$

### Iterace

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1} \mathbf{g}(\mathbf{x}_k).$$

- Jacobiho matice  $\mathbf{g}'(\mathbf{x}_k)$  musí být regulární (raději dobře podmíněná).
- Rychlá konvergence, ale nezaručená.
- Nutno začít s dobrou počáteční aproximací řešení,  $\mathbf{x}_0$ .

# Newtonova metoda **minimalizace funkce**

Hledáme možné lokální minimum dvakrát diferencovatelné funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  jako řešení rovnice  $\mathbf{g}(\mathbf{x}) = \mathbf{0}$ , kde  $\mathbf{g}(\mathbf{x}) := \nabla f(\mathbf{x}) = f'(\mathbf{x})^\top$ .






## Iterace Newtonovy metody

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1} \mathbf{g}(\mathbf{x}_k) = \mathbf{x}_k - f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^\top.$$

## Iterace gradientní metody

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{g}'(\mathbf{x}_k)^\top.$$

## Reference

-  T. Werner. *Optimalizace* (kapitola 8). Elektronická skripta. FEL ČVUT, 17. 10. 2022. [https://cw.fel.cvut.cz/wiki/\\_media/courses/b0b33opt/opt.pdf](https://cw.fel.cvut.cz/wiki/_media/courses/b0b33opt/opt.pdf)
-  J. Hamhalter a J. Tišer. *Diferenciální počet funkcí více proměnných*. FEL ČVUT, 2005. <https://math.fel.cvut.cz/en/people/tiser/dipocet.pdf>
-  G. Goh. *Why Momentum Really Works*. <https://distill.pub/2017/momentum/>
-  *Matlab Activities for Multivariable Calculus*. <https://mse.redwoods.edu/darnold/math50c/matlab/>
-  M. Navara. *Matematika spojitého světa*. Elektronická skripta. FEL ČVUT, 2011. [https://cmp.felk.cvut.cz/~navara/MSS/MSS\\_print.pdf](https://cmp.felk.cvut.cz/~navara/MSS/MSS_print.pdf)