

# Matematická analýza 2

## Extrémy funkcí více proměnných

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

22. prosince 2024  
ZS 2024/2025



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

1 Motivace: Optimalizační úlohy

2 Extrémy funkcí více proměnných

3 Nutné podmínky

$$\nabla f(\mathbf{a}) = \theta$$

4 Postačující podmínka

5 Příklady

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$



# Hlavní výsledky této přednášky

- Motivační zmínka obecných optimalizačních úloh.
- Zavedení lokálních extrémů funkcí více proměnných.
- Nutné podmínky pro existenci lokálního extrému funkcí více proměnných.
- Analytický postup pro hledání extrému funkcí více proměnných.



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

## 1 Motivace: Optimalizační úlohy

## 2 Extrémy funkcí více proměnných

## 3 Nutné podmínky

$$\nabla f(\mathbf{a}) = \theta$$

## 4 Postačující podmínka

## 5 Příklady

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$



# Co je to optimalizační úloha?

Co mají následující úlohy společného?

- Jak rovnoměrně rozmístit objekty na tiskovou podložku 3D tiskárny?
- Jak „naučit“ neuronovou síť vykonávat jistý úkol?
- Jak z několika potravin s různým složením vytvořit optimální jídelníček splňující zadaná dietologická kritéria?
- Jak na desku optimálně rozmístit elektronické součástky při splnění zejména prostorových omezení a nákladnosti výroby?
- Jak nalézt co nejkratší (nebo nejlevnější) trasu mezi zadanými místy?

Pod každou z těchto úloh dříme **optimalizační úloha**, tedy úloha nalézt minimum/maximum jisté funkce (potenciálně opravdu mnoha proměnných) za jistých omezujících podmínek.



# Obecná optimalizační úloha

V maximální obecnosti by matematická formulace „obecné optimalizační úlohy“ mohla znít následovně:

## Obecná optimalizační úloha

Nalezněte maximum/minimum (existuje-li; alespoň lokální) funkce  $f : D_f \rightarrow \mathbb{R}$ , kde  $D_f \subset \mathbb{R}^n$ , na množině






$$M = \{\mathbf{x} \in D_f \mid g_i(\mathbf{x}) = 0, i \in \hat{I}, h_j(\mathbf{x}) \leq 0, j \in \hat{J}\},$$

kde  $I$  a  $J$  jsou nezáporná celá čísla a  $g_i$  a  $h_j$  funkce s definičními obory ležícími v  $\mathbb{R}^n$ ,  $i \in \hat{I}$ ,  $j \in \hat{J}$ , připouštíme i  $I$  nebo  $J$  nulové a pak odpovídající podmínky nemáme ( $\hat{0} = \emptyset$ ).

Podle různých situací rozlišujeme řadu různých typů této optimalizační úlohy (pouze lineární funkce, pouze kvadratické funkce, konvexní funkce, funkce definované na  $\mathbb{Z}^n$  nebo dokonce jenom  $\{0, 1\}^n$ , ...).



# Obecná optimalizační úloha

- V  BI-MA2 se budeme věnovat úlohám bez rovnostních i bez nerovnostních omezení a s reálnými proměnnými.
- Tj. úloze nalézt (lokální) minima/maxima reálné funkce více reálných proměnných.
- Koncepty, které zde zavedeme, hrají ale důležitou roli i v případě úloh s omezeními, nebo v případě implementace numerických algoritmů snažících se tyto úlohy řešit.
- Úlohy s omezeními potkáte v magisterském povinném předmětu  NI-MPI nebo ve specializovaných předmětech  NI-LOM,  NI-NON, nebo  NI-KOP, ale i jinde.



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

1 Motivace: Optimalizační úlohy

2 Extrémy funkcí více proměnných

3 Nutné podmínky

$$\nabla f(\mathbf{a}) = \theta$$

4 Postačující podmínka

5 Příklady

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$





# Extrémy funkcí více proměnných

Následující definice jako by z oka vypadla té z BI-MA1:

## Definice (Extrémy funkcí více proměnných):

Mějme funkci  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ , a bod  $\mathbf{a} \in D_f$ . Funkce  $f$  má v bodě  $\mathbf{a}$

- **ostré lokální minimum**, právě když existuje okolí  $U_{\mathbf{a}}$  bodu  $\mathbf{a}$  takové, že pro všechna  $\mathbf{x} \in U_{\mathbf{a}} \cap D_f$  různá od  $\mathbf{a}$  platí  $f(\mathbf{x}) > f(\mathbf{a})$ .
- **ostré lokální maximum**, právě když existuje okolí  $U_{\mathbf{a}}$  bodu  $\mathbf{a}$  takové, že pro všechna  $\mathbf{x} \in U_{\mathbf{a}} \cap D_f$  různá od  $\mathbf{a}$  platí  $f(\mathbf{x}) < f(\mathbf{a})$ .
- **lokální minimum**, právě když existuje okolí  $U_{\mathbf{a}}$  bodu  $\mathbf{a}$  takové, že pro všechna  $\mathbf{x} \in U_{\mathbf{a}} \cap D_f$  platí  $f(\mathbf{x}) \geq f(\mathbf{a})$ .
- **lokální maximum**, právě když existuje okolí  $U_{\mathbf{a}}$  bodu  $\mathbf{a}$  takové, že pro všechna  $\mathbf{x} \in U_{\mathbf{a}} \cap D_f$  platí  $f(\mathbf{x}) \leq f(\mathbf{a})$ .

Hodnota tohoto extrému je ve všech případech  $f(\mathbf{a})$ .


Souhrnně budeme mluvit o (ostrém) lokálním extrému.




# Extrémy funkcí více proměnných

- Nejprve se budeme soustředit na analytické hledání lokálních extrémů.
- Odvodíme nutné i postačující podmínky pro jejich existenci.
- V pozdější části přednášky si ukážeme i jeden z možných numerických přístupů k řešení tohoto problému (gradientní sestup).
- Je dobré si uvědomit, že struktura množiny bodů, kde je nabýván extrém, může být poměrně komplikovaná.

$$f(x, y) = \frac{\sin \sqrt{x^2 + y^2}}{\sqrt{x^2 + y^2}}$$



$$f(x, y) = \sin(x) \cos(y)$$



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

1 Motivace: Optimalizační úlohy

2 Extrémy funkcí více proměnných

3 Nutné podmínky

$$\nabla f(\mathbf{a}) = \theta$$


4 Postačující podmínka

5 Příklady

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$



# Nutná podmínka prvního řádu

Vzpomeňte si na známé tvrzení z  BI-MA1: pokud má reálná funkce reálné proměnné lokální extrém v bodě  $a$ , pak její derivace v bodě  $a$  buď neexistuje, nebo je rovna nule.

## Věta (Nutná podmínka existence lokálního extrému I):

Mějme funkci  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ , mající v bodě  $\mathbf{a}$  (ostrý) lokální extrém. Potom parciální derivace funkce  $f$  v bodě  $\mathbf{a}$  podle  $j$ -té proměnné je rovna nule nebo neexistuje.

## Důkaz.

Stačí použít výše zmíněné tvrzení na funkci  $g(x) = f(\mathbf{a} + x\mathbf{e}_j)$  a vztahu mezi  $g'(0)$  a  $\partial_j f(\mathbf{a})$ . □


## Důsledek:

Mějme funkci  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ , mající v bodě  $\mathbf{a}$  (ostrý) lokální extrém a mající parciální derivace v bodě  $\mathbf{a}$  podle všech proměnných. Potom  $\nabla f(\mathbf{a}) = \theta$ .

# Nutná podmínka prvního řádu

Ukázkou extrému (ostrého lokálního minima; snadno ukážeme z definice) v bodě s neexistujícím gradientem je například kužel:


$$f(x, y) = \sqrt{x^2 + y^2}$$



## Nutná podmínka druhého řádu

Opět upozorněme, že jde pouze o nutnou podmínku! Z nulovosti gradientu neplyne existence extrému. Například: pro  $f(x, y) = x^2 - y^2$  sice platí  $\nabla f(0, 0) = \theta$ , ale v  $(0, 0)$  očividně (viz definice) extrém nenastává!

$$f(x, y) = x^2 - y^2$$



### Definice (Stacionární bod / stationary point):

Mějme funkci  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ . Bod  $\mathbf{a} \in D_f$  splňující  $\nabla f(\mathbf{a}) = \theta$  nazýváme **stacionárním bodem** (kritickým bodem nazýváme bod, kde neexistuje gradient nebo je stacionární).

# Nutná podmínka druhého řádu

- V případě funkce jedné proměnné jsme často při hledání extrémů hledali nulové body první derivace a poté zkoumali znaménko první derivace na okolí takového bodu.
- U funkcí více proměnných tento přístup použitelný není. Musíme se podívat na analog druhé derivace.


## Věta (Nutná podmínka existence lokálního extrému II):

Nechť funkce  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ , má spojité všechny druhé parciální derivace na okolí bodu  $\mathbf{a}$  a nechť má v tomto bodě lokální minimum (resp. maximum), potom je Hesseova matice  $\nabla^2 f(\mathbf{a})$  PSD (resp. NSD).



# Nutná podmínka druhého řádu


$$f(x, y) = x^2 + y^2$$



$$\begin{aligned}\nabla f(0, 0) &= \theta \\ \nabla^2 f(0, 0) &= \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}\end{aligned}$$

Ostré lokální minimum a PD Hesseova matice.

$$f(x, y) = x^4 + y^4$$



$$\begin{aligned}\nabla f(0, 0) &= \theta \\ \nabla^2 f(0, 0) &= \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix}\end{aligned}$$

Ostré lokální minimum a **pouze PSD** Hesseova matice.






# Podmínka druhého řádu: důkaz

1/2

BÚNO  $\mathbf{a} = \theta$ . Buď  $U_\theta$  okolí bodu  $\theta$  kde má funkce  $f$  spojitě všechny parciální derivace až do druhého řádu (včetně) a platí  $f(\mathbf{x}) \geq f(\theta)$  pro každé  $\mathbf{x} \in U_\theta$ .



Mějme  $\mathbf{x} \in U_\theta$  libovolné nenulové a uvažme funkci  $g(h) = f(h\mathbf{x})$  definovanou určitě na nějakém okolí  $U_0 \subset \mathbb{R}$  obsahujícím 1 ( $\mathbf{x} \in U_\theta$ ).

Tato funkce má v bodě 0 lokální minimum ( $g(h) \geq f(\theta)$ ) a pro její derivace podle pravidla o derivaci složené funkce platí

$$g'(h) = \sum_{j=1}^n \frac{\partial f}{\partial x_j}(h\mathbf{x}) \cdot x_j,$$

$$g''(h) = \sum_{j,k=1}^n \frac{\partial^2 f}{\partial x_k \partial x_j}(h\mathbf{x}) \cdot x_j x_k.$$

$g$  má proto spojitou druhou derivaci a navíc dle předpokladu platí  $g'(0) = 0$ .



# Podmínka druhého řádu: důkaz

2/2

Podle Taylorovy věty pro  $h \in U_0$  platí

$$0 \leq g(h) - g(0) = \frac{1}{2}g''(\xi_h)h^2, \quad (*)$$

kde  $\xi_h$  leží mezi 0 a  $h$  (a tedy  $\xi_h \rightarrow 0$  když  $h \rightarrow 0$ ).

Dále podle předchozího slide platí

$$g''(\xi_h) = \mathbf{x}^T \cdot \nabla^2 f(\xi_h \mathbf{x}) \cdot \mathbf{x}.$$

Dosazením tohoto vztahu do (\*), podělením nerovnosti  $h^2$  a provedením limity  $h \rightarrow 0$  získáváme nerovnost

$$\mathbf{x}^T \cdot \nabla^2 f(\theta) \cdot \mathbf{x} \geq 0,$$

kde  $\mathbf{x}$  bylo libovolné z  $U_\theta$ .

Libovolné  $\mathbf{x} \neq \theta$  ale snadno přenásobením vhodnou kladnou konstantou lze převést do  $U_\theta$ , kde nerovnost platí a poté opět vytknout škálovací faktor.

Tím je důkaz dokončen.




# Nutná podmínka prvního řádu

Opět upozorníme, že jde pouze o nutnou podmínku! Z nulovosti gradientu a PSD (resp. NSD) Hesseovy matice v daném bodě neplyne existence lokálního extrému. Například: pro  $f(x, y) = x^2 - y^4$  sice platí  $\nabla f(0, 0) = \theta$  a Hesseova matice

$$\nabla^2 f(0, 0) = \begin{pmatrix} 2 & 0 \\ 0 & 0 \end{pmatrix}$$

je PSD, ale v  $(0, 0)$  očividně (viz definice) extrém nenastává!



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

1 Motivace: Optimalizační úlohy

2 Extrémy funkcí více proměnných

3 Nutné podmínky

$$\nabla f(\mathbf{a}) = \theta$$

4 Postačující podmínka

5 Příklady

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$



# Postačující podmínka

Po studiu nutných podmínek konečně přistupme k postačující podmínce. Stačí zpřísnit podmínku definitnosti (ze semidefinitnosti na definitnost).

Navíc dále ukážeme, že ID existenci extrému vylučuje (tzv. **sedlový bod**).

## Věta (Postačující podmínka existence lokálního extrému):

Mějme funkci  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ , mající spojitě všechny třetí parciální derivace na okolí bodu  $\mathbf{a}$  a necht' jsou splněny následující dvě podmínky

- 1  $\nabla f(\mathbf{a}) = \theta$ ,
- 2  $\nabla^2 f(\mathbf{a})$  je PD (resp. ND).

Potom má funkce  $f$  v bodě  $\mathbf{a}$  ostré lokální minimum (resp. maximum).

Pokud platí první podmínka a Hesseova matice  $\nabla^2 f(\mathbf{a})$  je ID, pak tato funkce v bodě  $\mathbf{a}$  lokální extrém nemá.



## Postačující podmínka

Než se pustíme do důkazu, tak opět upozorníme na záludnosti předchozí věty. Studenti mají tendenci v předchozí větu rozšiřovat i na případ PSD (resp. NSD) a z toho pak vyvozovat existenci *neostrého* lokálního extrému. Následující příklad ukazuje, že nic takového neplatí.

### Příklad.

Funkce  $f(x, y) = x^2 + y^3$  má v bodě  $\theta$  nulový gradient, skutečně:

$$\nabla f(x, y) = (2x, 3y^2) \Rightarrow \nabla f(\theta) = \theta.$$

Pro Hessovu matici platí


$$\nabla^2 f(x, y) = \begin{pmatrix} 2 & 0 \\ 0 & 6y \end{pmatrix}$$

a proto  $\nabla^2 f(\theta) = \begin{pmatrix} 2 & 0 \\ 0 & 0 \end{pmatrix}$ . Odpovídající kvadratická forma je rovna  $(x_1, x_2) \mapsto 2x_1^2$  a je PSD.

Funkce  $f$  v bodě  $\theta$  extrém nemá:  $f(0, y) = y^3$  je kladná pro  $y > 0$  a záporná pro  $y < 0$ ,  $f(\theta) = 0$ .

# Postačující podmínka

$$f(x, y) = x^2 + y^3$$



# Postačující podmínka

Klíčem k důkazu je v podstatě Taylorova věta, kterou zde zformulujeme jenom v jednodušší verzi využívající pouze kvadratické členy.

## Lemma (Taylorova věta do kvadratických členů s odhadem chyby):

Mějme funkci  $f : D_f \rightarrow \mathbb{R}$ ,  $D_f \subset \mathbb{R}^n$ , mající spojitě všechny parciální derivace do třetího řádu včetně na okolí  $U_{\mathbf{a}}$  bodu  $\mathbf{a} \in D_f$ . Potom existuje konstanta  $M > 0$  taková, že pro každé  $\mathbf{x} \in U_{\mathbf{a}}$  platí

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x}),$$

kde  $|R_2(\mathbf{x})| \leq M \|\mathbf{x} - \mathbf{a}\|^3$ .





# Postačující podmínka: důkaz

1/3

## Náčrt důkazu Lemmatu.

Uvažme  $\mathbf{x} \in U_{\mathbf{a}}$  a funkci  $g(t) := f(\mathbf{a} + (\mathbf{x} - \mathbf{a})t)$ , definovanou pro všechna přípustná  $t$  (zcela jistě pro nějaký otevřený interval obsahující interval  $\langle 0, 1 \rangle$ ). Funkce  $g$  má na tomto intervalu spojité derivace do řádu 3 včetně.

Podle Taylorovy věty pro funkci  $g$  a  $t \in \langle 0, 1 \rangle$  platí

$$g(t) = g(0) + g'(0)t + \frac{1}{2}g''(0)t^2 + \frac{1}{3!}g'''(\xi)t^3, \quad \text{kde } \xi \in \langle 0, t \rangle.$$

Použitím věty o derivaci složené funkce opět zjistíme, že

$$g'(0) = \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) \quad \text{a} \quad g''(0) = (\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}).$$

Konečně, pro  $g'''$  platí

$$g'''(t) = \sum_{i,j,k=1}^n \frac{\partial^3 f}{\partial x_i \partial x_j \partial x_k} (\mathbf{a} + (\mathbf{x} - \mathbf{a})t) (\mathbf{x} - \mathbf{a})_i (\mathbf{x} - \mathbf{a})_j (\mathbf{x} - \mathbf{a})_k.$$

Díky spojitosti parciálních derivací a uzavřenosti intervalu  $\langle 0, 1 \rangle$  můžeme v absolutní hodnotě tento výraz odhadnout výrazem tvaru  $C \cdot \left( \sum_{j=1}^n |(\mathbf{x} - \mathbf{a})_j| \right)^3$ . Lze ukázat, že tento výraz je dále menší než  $M \|\mathbf{x} - \mathbf{a}\|^3$  a konstanta  $M$  nezávisí na  $\mathbf{x}$ . Nyní stačí položit  $t = 1$ . □

# Postačující podmínka: důkaz

2/3

**Důkaz případu PD:** Mějme okolí  $\mathcal{U} := U_{\mathbf{a}}$  bodu  $\mathbf{a}$ , na kterém má funkce  $f$  spojitě všechny třetí parciální derivace a necht' platí uvedené podmínky:  $\nabla f(\mathbf{a}) = \theta$  a  $\nabla^2 f(\mathbf{a})$  je PD.

Uvažme libovolný bod  $\mathbf{x} \in U_{\mathbf{a}}$  různý od  $\mathbf{a}$ . Podle předchozího Lemmatu existuje konstanta  $M > 0$  nezávislá na  $\mathbf{x}$  taková, že

$$f(\mathbf{x}) - f(\mathbf{a}) = 0 + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x}),$$

kde  $|R_2(\mathbf{x})| < M\|\mathbf{x} - \mathbf{a}\|^3$ .

Z PD kvadratické formy  $q(\mathbf{y}) = \mathbf{y}^T \nabla^2 f(\mathbf{a}) \mathbf{y}$  plyne existence ortogonální regulární matice  $\mathbf{P}$  splňující

$$q(\mathbf{y}) = (\mathbf{P}\mathbf{y})^T \text{diag}(\lambda_1, \dots, \lambda_n) \mathbf{P}\mathbf{y} = \sum_{j=1}^n \lambda_j (\mathbf{P}\mathbf{y})_j^2 \geq \lambda_* \sum_{j=1}^n (\mathbf{P}\mathbf{y})_j^2 = \lambda_* \|\mathbf{y}\|^2,$$

kde  $\lambda_*$  je nejmenší z kladných vlastních čísel  $\nabla^2 f(\mathbf{a})$ .

Je-li nyní  $\mathbf{x} \in U_{\mathbf{a}}(\varepsilon) \subset \mathcal{U}$ , kde  $M\varepsilon < \frac{\lambda_*}{4}$ , pak

$$f(\mathbf{x}) - f(\mathbf{a}) \geq \frac{\lambda_*}{2} \|\mathbf{x} - \mathbf{a}\|^2 - M\|\mathbf{x} - \mathbf{a}\|^3 > \|\mathbf{x} - \mathbf{a}\|^2 \left( \frac{\lambda_*}{2} - M\varepsilon \right) > \frac{\lambda_*}{4} \|\mathbf{x} - \mathbf{a}\|^2$$



# Postačující podmínka: důkaz

3/3

**Případ ND** ihned plyne z PD (jaký je vztah mezi typem extrému funkce  $f$  a  $-f$ , definitností formy  $q$  a  $-q$ ?)

**Případ ID** se ošetří analogicky, využijeme existence  $\mathbf{x}$  a  $\mathbf{y}$  takových, že

$$(\mathbf{x} - \mathbf{a})^T \nabla^2 f(\mathbf{a})(\mathbf{x} - \mathbf{a}) > 0,$$

$$(\mathbf{y} - \mathbf{a})^T \nabla^2 f(\mathbf{a})(\mathbf{y} - \mathbf{a}) < 0,$$

k tomu, abychom v odpovídajícím směru od  $\mathbf{a}$  našli vhodným škálováním (dost blízko k  $\mathbf{a}$ ) kladná  $h$  a  $t$  splňující

$$f(\mathbf{a} + h\mathbf{x}) > f(\mathbf{a}) \quad \text{a} \quad f(\mathbf{a} + t\mathbf{y}) < f(\mathbf{a}).$$



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

1 Motivace: Optimalizační úlohy

2 Extrémy funkcí více proměnných

3 Nutné podmínky

$$\nabla f(\mathbf{a}) = \theta$$

4 Postačující podmínka

5 Příklady

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$



# Příklad

## Příklad.

Nalezněte extrémy a sedlové body funkce

$$f(x, y) = x^4 + y^4 - x^2 - 2xy - y^2.$$

Definičním oborem této funkce je  $D_f = \mathbb{R}^2$ . Pro gradient platí

$$\nabla f(x, y) = (4x^3 - 2x - 2y, 4y^3 - 2x - 2y), \quad (x, y)^T \in \mathbb{R}^2.$$

Jeho nulovost je ekvivalentní podmínkám

$$2x^3 = x + y \wedge 2y^3 = x + y,$$

které nutně vyžadují  $x^3 = y^3$ , tj.  $x = y$ . Dosazením do původních rovnic dostaneme podmínku  $x^3 - x = x(x^2 - 1) = 0$ .

Stacionární body existují proto celkem 3:

$$\mathbf{a} = (-1, -1)^T, \quad \mathbf{b} = (0, 0)^T, \quad \mathbf{c} = (1, 1)^T.$$



## Příklad: pokračování

Pro Hessovu matici funkce  $f$  dále platí

$$\nabla^2 f(x, y) = \begin{pmatrix} 12x^2 - 2 & -2 \\ -2 & 12y^2 - 2 \end{pmatrix}, \quad (x, y)^T \in \mathbb{R}^2.$$

Ve stacionárních bodech pak máme

$$\nabla^2 f(\mathbf{a}) = \begin{pmatrix} 10 & -2 \\ -2 & 10 \end{pmatrix} = \nabla^2 f(\mathbf{c}), \quad \nabla^2 f(\mathbf{b}) = \begin{pmatrix} -2 & -2 \\ -2 & -2 \end{pmatrix}.$$

První matice je PD (Sylvester:  $10 > 0$  a  $100 - 4 = 96 > 0$ ). **V bodech  $\mathbf{a}$  a  $\mathbf{c}$  má naše funkce proto ostrá lokální minima.**

Druhá matice je NSD:  $-2x^2 - 4xy - 2y^2 = -2(x + y)^2$ . Naše kritéria proto ohledně ne/existence extrému v bodě  $\mathbf{b}$  nic neimplikují. Musíme provést podrobnější inspekci.



## Příklad: pokračování

Pro naši funkci platí  $f(x, y) = x^4 + y^4 - x^2 - 2xy - y^2 = x^4 + y^4 - (x + y)^2$ .

Využitím u  $\mathbf{b} = \theta$  podstatnějšiho (ale vynulovatelného) záporného členu se zkusme k bodu  $\theta$  blížit následujícími dvěma způsoby:

$$\begin{aligned} f(t, -t) &= 2t^4 > 0, & \text{pro } t \neq 0, \\ f(t, 0) &= t^4 - t^2 = t^2(t^2 - 1) < 0, & \text{pro } t \in (-1, 1) \setminus \{0\}. \end{aligned}$$


**V bodě  $\mathbf{b}$  proto extrém nenastává.** Vzhledem k výše popsanému chování bychom ho také mohli označit za sedlový bod.

Na následujícím slide pro ukázkou uvádíme graf této funkce.



# Příklad: pokračování

$$f(x, y) = x^4 + y^4 - x^2 - 2xy - y^2$$





## Příklad: Regrese pomocí metody nejmenších čtverců

Předpokládejme, že máme k dispozici sadu dat  $\{(x_i, y_i)\}_{i=1}^n$  a chceme nalézt **lineární kombinaci daných funkcí**  $f_1, f_2, \dots, f_m$ , tj. funkci

$$f_{\mathbf{c}} = \sum_{i=1}^m c_i f_i,$$

tak, aby funkční hodnoty funkce  $f$  v bodech  $x_i$  co **nejlépe** odpovídaly hodnotám  $y_i$  pro každé  $i \in \hat{n}$ . Alternativně: snažíme se dobře vystihnout hypotetickou závislost  $y \approx f(x)$ .

Úkolem je určit neznámé koeficienty lineární kombinace:  $c_1, c_2, \dots, c_m$ .

Předpokládejme, že  $m \leq n$ . To není na závadu, neboť typicky je množství dat  $n$  mnohem větší než počet funkcí  $m$ .

Funkce  $f_i$  mohou být např. voleny tak, že  $f_i(x) = x^i$ . V tomto případě prokládáme data polynomiální křivkou. Funkce  $f_1, f_2, \dots, f_m$  nelze volit úplně libovolně, jedna podmínka svazující funkce  $f_1, f_2, \dots, f_m$  a data  $x_1, x_2, \dots, x_n$  nám vypadne z výpočtu dále.



# Příklad: Regrese pomocí metody nejmenších čtverců

Metoda nejmenších čtverců spočívá v myšlence **minimalizovat kvadrát celkové chyby** mezi  $y_i$  a  $f(x_i)$ . Přesněji, hledáme hodnoty  $c_1, c_2, \dots, c_m$  tak, aby hodnota

$$F(\mathbf{c}) := \sum_{i=1}^n (y_i - f_{\mathbf{c}}(x_i))^2 = \sum_{i=1}^n (y_i - (\mathbf{A}\mathbf{c})_i)^2 = \|\mathbf{y} - \mathbf{A}\mathbf{c}\|_2^2$$

byla co nejmenší. Zde jsme označili

$$(\mathbf{A}\mathbf{c})_i = \sum_{j=1}^m f_j(x_i)c_j.$$

Matice  $\mathbf{A} \in \mathbb{R}^{n,m}$  je dána hodnotami jednotlivých funkcí  $f_1, f_2, \dots, f_m$  v bodech  $x_1, x_2, \dots, x_n$ :

$$\mathbf{A} = \begin{pmatrix} f_1(x_1) & f_2(x_1) & f_3(x_1) & \cdots & f_m(x_1) \\ f_1(x_2) & f_2(x_2) & f_3(x_2) & \cdots & f_m(x_2) \\ f_1(x_3) & f_2(x_3) & f_3(x_3) & \cdots & f_m(x_3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_1(x_n) & f_2(x_n) & f_3(x_n) & \cdots & f_m(x_n) \end{pmatrix}. \quad (1)$$



# Příklad: Regrese pomocí metody nejmenších čtverců

Metodu nejmenší čtverců tedy můžeme shrnout takto

$$\left\{ \begin{array}{l} \text{minimalizuj } \|\mathbf{y} - \mathbf{A}\mathbf{c}\|_2^2, \\ \text{vůči } \mathbf{c} = (c_1, c_2, \dots, c_m)^T \in \mathbb{R}^m, \\ \text{kde } \mathbf{y} = (y_1, y_2, \dots, y_n)^T \in \mathbb{R}^n \text{ a } \mathbf{A}_{ij} = f_j(x_i) \text{ jsou dány.} \end{array} \right. \quad (2)$$

Aplikujme analytický postup pro hledání extrémů funkcí více proměnných. Předpokládejme navíc, že matice  $\mathbf{A}$  má plnou hodnotu, tzn.  $h(\mathbf{A}) = m$  (předpokládáme  $m \leq n$ ).

Nejprve hledejme gradient funkce  $F$ . Pro její parciální derivaci platí

$$\begin{aligned} (\partial_{c_j} F)(\mathbf{c}) &= -2 \sum_{i=1}^n (y_i - (\mathbf{A}\mathbf{c})_i) \mathbf{A}_{ij} = -2 \sum_{i=1}^n (\mathbf{A}^T)_{ji} y_i + 2 \sum_{i=1}^n (\mathbf{A}^T)_{ji} (\mathbf{A}\mathbf{c})_i = \\ &= -2(\mathbf{A}^T \mathbf{y})_j + 2(\mathbf{A}^T \mathbf{A}\mathbf{c})_j. \end{aligned}$$



# Příklad: Regrese pomocí metody nejmenších čtverců

Pro její gradient proto platí

$$(\nabla_{\mathbf{c}} F)(\mathbf{c})^T = -2\mathbf{A}^T \mathbf{y} + 2\mathbf{A}^T \mathbf{A} \mathbf{c}, \quad (3)$$

kde spodní index u symbolu  $\nabla_{\mathbf{c}}$  nám připomíná, vůči kterým proměnným derivujeme.

Hledáme bod  $\mathbf{c}$ , kde  $\nabla_{\mathbf{c}} F(\mathbf{c}) = \theta$ . Protože  $\mathbf{A}$  má dle předpokladu plnou hodnost, je matice  $\mathbf{A}^T \mathbf{A} \in \mathbb{R}^{m,m}$  regulární. Z rovnosti (3) potom dostáváme řešení

$$\mathbf{c} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}, \quad (4)$$

resp. umíme vždy vyřešit příslušnou nehomogenní lineární soustavu.



## Příklad: Regrese pomocí metody nejmenších čtverců

Hessovou maticí funkce  $F$  je shodou okolností právě matice  $\mathbf{A}^T \mathbf{A}$  (až na multiplikativní číselný faktor). Skutečně, pro prvek Hessovy matice funkce  $F$  platí

$$\partial_{c_i c_j}^2 F(c) = 2(\mathbf{A}^T \mathbf{A})_{ji}.$$

Matice  $\mathbf{A}^T \mathbf{A}$  je **pozitivně definitní**, neboť pro  $\mathbf{x} \in \mathbb{R}^m$  je

$$\mathbf{x}^T (\mathbf{A}^T \mathbf{A}) \mathbf{x} = (\mathbf{A} \mathbf{x})^T (\mathbf{A} \mathbf{x}) = \|\mathbf{A} \mathbf{x}\|^2 \geq 0$$

a rovnost nastává pouze pro  $\mathbf{x} = 0$ , protože je  $\mathbf{A}^T \mathbf{A}$  regulární.

Shrnutí: prakticky tedy stačí sestavit příslušnou matici a vyřešit uvedenou soustavu lineárních rovnic.



# Hlavní body

$$f(\mathbf{x}) = f(\mathbf{a}) + \nabla f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + \frac{1}{2}(\mathbf{x} - \mathbf{a})^T \cdot \nabla^2 f(\mathbf{a}) \cdot (\mathbf{x} - \mathbf{a}) + R_2(\mathbf{x})$$

## 6 Dodatek

$$\nabla f(\mathbf{a}) = \theta$$

$$\nabla^2 f(\mathbf{a}) \text{ PD/ND}$$





# Komentář

TBA

