

# Optimalizace

## 7. Volné lokální extrémy

---

Tom Werner, Tom Kroupa

FEL ČVUT

## Analytické podmínky na volné lokální extrémy

### Věta (nutná podmínka prvního řádu)

Nechť funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je v bodě  $\mathbf{x} \in \mathbb{R}^n$  (totálně) diferencovatelná.

Jestliže  $\mathbf{x}$  je lokální extrém funkce  $f$ , pak  $f'(\mathbf{x}) = \mathbf{0}$ .

Každý bod  $\mathbf{x} \in \mathbb{R}^n$  splňující  $f'(\mathbf{x}) = \mathbf{0}$  se nazývá **stacionární bod** funkce  $f$ .

### Věta (podmínky druhého řádu)

Nechť funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  je v bodě  $\mathbf{x} \in \mathbb{R}^n$  dvakrát diferencovatelná.

- Jestliže  $\mathbf{x}$  je lokální minimum [maximum] funkce  $f$ , pak  $f'(\mathbf{x}) = \mathbf{0}$  a Hessova matice  $f''(\mathbf{x})$  je pozitivně [negativně] semidefinitní.
- Jestliže  $f'(\mathbf{x}) = \mathbf{0}$  a Hessova matice  $f''(\mathbf{x})$  je pozitivně [negativně] definitní, pak  $\mathbf{x}$  je ostré lokální minimum [maximum] funkce  $f$ .

Tedy když  $f''(\mathbf{x})$  je indefinitní, pak  $\mathbf{x}$  není lokální extrém.

Bod  $\mathbf{x}$ , ve kterém  $f'(\mathbf{x}) = \mathbf{0}$  a  $f''(\mathbf{x})$  je indefinitní, se nazývá **sedlový bod** funkce  $f$ .

# **Iterační metody na volné lokální extrémů**

---

## Rychlost konvergence iteračních algoritmů

Nechť posloupnost bodů  $\mathbf{x}_k \in \mathbb{R}^n$  konverguje k bodu  $\mathbf{x}^*$ .

Pak posloupnost čísel  $r_k = \|\mathbf{x}_k - \mathbf{x}^*\| \geq 0$  konverguje k nule.

**Definice:** Pokud existuje limita

$$\lim_{k \rightarrow \infty} \frac{r_{k+1}}{r_k} = \rho$$

řekneme, že posloupnost  $\mathbf{x}_k$  (příp.  $r_k$ ) konverguje

- **sublineárně**, pokud  $\rho = 1$ ,
- **lineárně**, pokud  $0 < \rho < 1$ ,
- **superlineárně**, pokud  $\rho = 0$ .

**Příklady:**

- Posloupnost  $r_k = \frac{1}{k} = (1, \frac{1}{2}, \frac{1}{3}, \frac{1}{4}, \dots)$  konverguje sublineárně.
- Posloupnost  $r_k = 2^{-k} = (\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \dots)$  konverguje lineárně.
- Posloupnost  $r_k = 2^{-2^k} = (\frac{1}{4}, \frac{1}{16}, \frac{1}{256}, \dots)$  konverguje superlineárně.


# Sestupné metody, názvosloví

Hledáme lokální minimum diferencovatelné funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ .

- Zvolíme **počáteční odhad**  $\mathbf{x}_0 \in \mathbb{R}^n$
- Tvoříme posloupnost  $\mathbf{x}_1, \mathbf{x}_2, \dots$  pomocí iterace

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

kde  $\mathbf{v}_k$  je **směr hledání** a  $\alpha_k > 0$  **délka kroku**.



- **Sestupné metody**: pro každé  $k$  platí  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$
- $\mathbf{v}_k$  je **sestupný směr** jestliže

$$f_{\mathbf{v}_k}(\mathbf{x}_k) = f'(\mathbf{x}_k)\mathbf{v}_k < 0$$

**Tvrzení:** Je-li  $\mathbf{v}_k$  sestupný, pak existuje  $\alpha_k > 0$  takové, že  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$ .

- $\mathbf{v}_k, \alpha_k$  mohou záviset na hodnotách a derivacích funkce  $f$  v bodech  $\mathbf{x}_k, \mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \dots$

**Řád metody** je nejvyšší řád použitých derivací.

- **Optimální délka kroku (exact line search):**

$\alpha_k$  je globální minimum funkce  $\varphi(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{v}_k)$  na intervalu  $(0, \infty)$ .


- **Suboptimální délka kroku (approximate/inexact line search):**

Hledáme  $\alpha_k > 0$  tak, že  $\varphi(\alpha_k) < \varphi(0)$ .

**Backtracking line search:** Začneme od nějakého  $\alpha > 0$  a zmenšujeme ho (násobením konstantou), dokud nesplňuje **Armijo-Goldsteinovo pravidlo**

$$\varphi(\alpha) \leq \varphi(0) + c\varphi'(0)\alpha$$

kde  $c \in (0, 1)$  je zvolená konstanta.



- **Pevná posloupnost délek kroku**  $(\alpha_k)_{k=0}^{\infty}$ . Musí splňovat např.

$$\lim_{k \rightarrow \infty} \alpha_k = 0, \quad \sum_{k=1}^{\infty} \alpha_k = \infty.$$

- **Konstantní délka kroku:**  $\alpha_k = \alpha > 0$  pro každé  $k$

Tyto dvě volby negarantují monotónní pokles funkce  $f$ .

# Gradientní metoda

---





# Gradientní metoda (Gradient Descent)

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

- Směr  $\mathbf{v}_k = -f'(\mathbf{x}_k)^T = -\nabla f(\mathbf{x}_k)$  je vždy sestupný:

$$f'(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)f'(\mathbf{x}_k)^T = -\|\nabla f(\mathbf{x}_k)\|^2 < 0$$

- Robustní: za velmi obecných předpokladů konverguje, a to obvykle **lineárně**.
- Pomalá konvergence je-li funkce okolo minima protažená (cik-cak chování).



## Závislost gradientní metody na lineární transformaci souřadnic

Grad. metoda v souřadnicích  $\mathbf{y} = \mathbf{A}\mathbf{x}$  (kde  $\mathbf{A}$  je regulární):

- Označme  $f(\mathbf{x}) = f(\mathbf{A}^{-1}\mathbf{y}) = g(\mathbf{y})$
- Iterace metody v souřadnicích  $\mathbf{y}$ :

$$\mathbf{y}_{k+1} = \mathbf{y}_k - \alpha_k g'(\mathbf{y}_k)^T$$

Dosazením a úpravou získáme iteraci v souřadnicích  $\mathbf{x}$ :

$$\begin{aligned}\mathbf{A}\mathbf{x}_{k+1} &= \mathbf{A}\mathbf{x}_k - \alpha_k \underbrace{\mathbf{A}^{-T} f'(\mathbf{x}_k)^T}_{g'(\mathbf{y}_k)^T} \\ \mathbf{x}_{k+1} &= \mathbf{x}_k - \alpha_k (\mathbf{A}^T \mathbf{A})^{-1} f'(\mathbf{x}_k)^T\end{aligned}$$

Zobecnění grad. metody:

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

- Je-li  $\mathbf{C}_k$  je pozitivně definitní, směr  $\mathbf{v}_k = -\mathbf{C}_k^{-1} f'(\mathbf{x}_k)^T$  bude sestupný.
- **Preconditioning:** 'levná' volba  $\mathbf{C}_k$  zrychlující konvergenci.

# Newtonova metoda

---

## Newtonova metoda na řešení soustavy rovnic


Dáno diferencovatelné zobrazení  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^n$ , řešíme soustavu rovnic  $\mathbf{g}(\mathbf{x}) = \mathbf{0}$ .

**Iterace:** Pro známé  $\mathbf{x}_k$  hledáme  $\mathbf{x}_{k+1}$  splňující

$$\mathbf{T}_{\mathbf{x}_k}^1(\mathbf{x}_{k+1}) = \mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k) = \mathbf{0}$$

To je lineární soustava s řešením

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



- Konverguje, jestliže počáteční odhad  $\mathbf{x}_0$  je 'dost' blízko nějakého kořene.
- Obvykle konverguje **superlineárně**.

# Superlineární konvergence Newtonovy metody

## Věta

Nechť  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^n$ ,  $\mathbf{x}^* \in \mathbb{R}^n$ ,  $\mathbf{g}(\mathbf{x}^*) = \mathbf{0}$  a  $\mathbf{g}'(\mathbf{x}^*)$  je regulární.

Nechť posloupnost  $\mathbf{x}_k$  splňující  $\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1}\mathbf{g}(\mathbf{x}_k)$  konverguje k  $\mathbf{x}^*$ . Pak

$$\lim_{\mathbf{x}_k \rightarrow \infty} \frac{r_{k+1}}{r_k} = \lim_{\mathbf{x}_k \rightarrow \infty} \frac{\|\mathbf{x}_{k+1} - \mathbf{x}^*\|}{\|\mathbf{x}_k - \mathbf{x}^*\|} = 0.$$

**Důkaz:** Chceme dokázat

$$\lim_{\mathbf{x}_k \rightarrow \infty} \frac{\mathbf{x}_{k+1} - \mathbf{x}^*}{\|\mathbf{x}_k - \mathbf{x}^*\|} = \lim_{\mathbf{x}_k \rightarrow \infty} \frac{\mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1}\mathbf{g}(\mathbf{x}_k) - \mathbf{x}^*}{\|\mathbf{x}_k - \mathbf{x}^*\|} = 0.$$

To plyne z následujícího:

$$\begin{aligned} \lim_{\mathbf{x} \rightarrow \mathbf{x}^*} \frac{\mathbf{x} - \mathbf{g}'(\mathbf{x})^{-1}\mathbf{g}(\mathbf{x}) - \mathbf{x}^*}{\|\mathbf{x} - \mathbf{x}^*\|} &= \lim_{\mathbf{x} \rightarrow \mathbf{x}^*} \frac{\mathbf{g}'(\mathbf{x})^{-1}\mathbf{g}'(\mathbf{x})(\mathbf{x} - \mathbf{x}^*) - \mathbf{g}(\mathbf{x})}{\|\mathbf{x} - \mathbf{x}^*\|} \\ &= \mathbf{g}'(\mathbf{x}^*)^{-1} \lim_{\mathbf{x} \rightarrow \mathbf{x}^*} \frac{\mathbf{g}'(\mathbf{x})(\mathbf{x} - \mathbf{x}^*) - \mathbf{g}(\mathbf{x})}{\|\mathbf{x} - \mathbf{x}^*\|} \\ &= \mathbf{g}'(\mathbf{x}^*)^{-1} \lim_{\mathbf{x} \rightarrow \mathbf{x}^*} \frac{\mathbf{g}(\mathbf{x}^*) - \mathbf{g}(\mathbf{x}) - \mathbf{g}'(\mathbf{x})(\mathbf{x}^* - \mathbf{x})}{\|\mathbf{x}^* - \mathbf{x}\|} = 0 \end{aligned}$$

kde poslední limita je nulová z definice derivace (protože  $\mathbf{g}(\mathbf{x}^*) = \mathbf{0}$ ).

## Příklad: Babylónská metoda na výpočet druhé odmocniny

Řešíme

$$g(x) = x^2 - a = 0$$

Iterace:

$$x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)} = x_k - \frac{x_k^2 - a}{2x_k} = \frac{1}{2} \left( x_k + \frac{a}{x_k} \right)$$

Matlab:

```
a=4; x=a;
for i=1:5
    x=(x+a/x)/2;
    fprintf('x=%.12g  g=%.12g\n',x,x^2-a);
end
```

x=2.5 g=2.25

x=2.05 g=0.2025

x=2.0006097561 g=0.00243939619274

x=2.00000009292 g=3.71689187872e-07

x=2 g=8.881784197e-15

## Příklad: Průsečík dvou rovinných křivek

Najdi řešení soustavy dvou rovnic o dvou neznámých:

$$(x - 1)^2 + y^2 = 1$$

$$x^4 + y^4 = 1$$

Iterace:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \end{bmatrix} - \underbrace{\begin{bmatrix} 2(x_k - 1) & 2y_k \\ 4x_k^3 & 4y_k^3 \end{bmatrix}}_{g'(x_k, y_k)}^{-1} \underbrace{\begin{bmatrix} (x_k - 1)^2 + y_k^2 - 1 \\ x_k^4 + y_k^4 - 1 \end{bmatrix}}_{g(x_k, y_k)}$$

```
x = [1;1];  
for iter = 1:5  
    g = [(x(1)-1)^2+x(2)^2-1; x(1)^4+x(2)^4-1];  
    x = x - [2*(x(1)-1) 2*x(2); 4*x.^3] \ g;  
    fprintf('x=(%.12g,%.12g) g=(%.12g,%.12g)\n', x, g);  
end
```

```
x=(0.75,1) g=(0.0625,0.31640625)
```

```
x=(0.678779069767,0.950944767442) g=(0.00747883674452,0.0300334591266)
```

```
x=(0.671937746776,0.944701508411) g=(8.57819836066e-05,0.000339082408219)
```

```
x=(0.671859761262,0.944629025098) g=(1.13355711484e-08,4.46057650816e-08)
```

```
x=(0.671859751039,0.944629015546) g=(0,8.881784197e-16)
```


## Použití Newtonovy metody na minimalizaci funkce

Hledáme lokální minimum dvakrát diferencovatelné funkce  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ .

**Iterace:** Řešíme stacionární podmínku  $\mathbf{g}(\mathbf{x}) = f'(\mathbf{x})^T = \mathbf{0}$  Newtonovou metodou:

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

**Jiné odvození:** Minimalizujeme Taylorův polynom  $T_{\mathbf{x}_k}^2(\mathbf{x})$  funkce  $f$  stupně 2 v okolí  $\mathbf{x}_k$



Pro lepší konvergenci lze přidat délku kroku:

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

Pro  $\alpha_k = 1$  máme **čistou** Newtonovu metodu.



- **Newtonův směr**  $\mathbf{v}_k = -f''(\mathbf{x}_k)^{-1}f'(\mathbf{x}_k)^T$  je sestupný, tj.

$$f'(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)f''(\mathbf{x}_k)^{-1}f'(\mathbf{x}_k)^T < 0,$$

když Hessián  $f''(\mathbf{x}_k)$  je pozitivně definitní.

- V tom případě soustavu  $f''(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)^T$  můžeme řešit Choleského rozkladem.

# Kvasi-newtonovské metody

- Počítání Hessiánu  $f''(\mathbf{x}_k)$  a řešení soustavy  $f''(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)^T$  je drahé.
- Myšlenka kvasi-newtonových metod:  
 $f''(\mathbf{x}_k)$  aproximujeme pomocí minulých hodnot  $f(\mathbf{x}_i)$  a  $f'(\mathbf{x}_i)$ ,  $i \leq k$ .
- Speciálně pro  $n = 1$  proměnnou: metoda sečen (vs. metoda tečen = Newtonova metoda)
- Populární metoda: **Broyden–Fletcher–Goldfarb–Shanno (BFGS)**  
Matlabská funkce `fminunc`.

## **Nelineární úloha nejmenších čtverců**

---

## Nelineární úloha nejmenších čtverců

Pro dané diferencovatelné zobrazení  $\mathbf{g}: \mathbb{R}^n \rightarrow \mathbb{R}^m$  minimalizujeme funkci

$$f(\mathbf{x}) = \|\mathbf{g}(\mathbf{x})\|^2 = \mathbf{g}(\mathbf{x})^T \mathbf{g}(\mathbf{x}) = \sum_{i=1}^m g_i(\mathbf{x})^2$$

- Tedy minimalizujeme součet čtverců daných funkcí.
- Speciální případ je lineární úloha nejmenších čtverců:  $\mathbf{g}(\mathbf{x}) = \mathbf{Ax} - \mathbf{b}$  je afinní.

## Gauss-Newtonova metoda

**Iterace:** Známe  $\mathbf{x}_k$  a najdeme  $\mathbf{x}_{k+1}$  které minimalizuje funkci

$$\|\mathbf{T}_{\mathbf{x}_k}^1(\mathbf{x}_{k+1})\|^2 = \|\mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k)\|^2$$

To je lineární úloha nejmenších čtverců s řešením

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

Můžeme přidat délku kroku:

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

Pro  $\alpha_k = 1$  máme **čistou** Gauss-Newtonovu metodu.

- Gauss-Newtonův směr:

$$\mathbf{v}_k = -\mathbf{g}'(\mathbf{x}_k)^+ \mathbf{g}(\mathbf{x}_k) = -(\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} \underbrace{\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}(\mathbf{x}_k)}_{\frac{1}{2} f'(\mathbf{x}_k)^T}$$

- Je vždy sestupný:

$$f'(\mathbf{x}_k) \mathbf{v}_k = -\frac{1}{2} f'(\mathbf{x}_k) (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T < 0$$

## Rozdíl oproti Newtonově metodě

Minimalizace funkce  $f(\mathbf{x}) = \|\mathbf{g}(\mathbf{x})\|^2$  Newtonovou vs. Gauss-Newtonovou metodou:

- Gauss-Newtonův směr je

$$\mathbf{v}_k = -\frac{1}{2}(\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T$$

- Newtonův směr je

$$\begin{aligned} \mathbf{v}_k &= -f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T \\ &= -\frac{1}{2} \left( \mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k) + \sum_{i=1}^m g_i(\mathbf{x}_k) g_i''(\mathbf{x}_k) \right)^{-1} f'(\mathbf{x}_k)^T \end{aligned}$$

Gauss-Newtonova metoda zanedbává **členy druhého řádu** v Hessiánu  $f''(\mathbf{x})$ .

- Proto obvykle konverguje o něco pomaleji než Newtonova metoda.
- Ale výhoda: nemusíme počítat Hessiány  $g_i''(\mathbf{x}_k)$

## Příklad: Průsečík dvou rovinných křivek

Najdi přibližné řešení soustavy tří rovnic o dvou neznámých:

$$(x - 1)^2 + y^2 = 1$$

$$x^4 + y^4 = 1$$

$$x^2 + (y - 1)^2 = \frac{1}{2}$$

Tedy minimalizujeme funkci

$$f(x, y) = \mathbf{g}(x, y)^T \mathbf{g}(x, y) = ((x - 1)^2 + y^2 - 1)^2 + (x^4 + y^4 - 1)^2 + (x^2 + (y - 1)^2 - \frac{1}{2})^2$$

Iterace čisté Gauss-Newtonovy metody:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \end{bmatrix} - \underbrace{\begin{bmatrix} 2(x_k - 1) & 2y_k \\ 4x_k^3 & 4y_k^3 \\ 2x_k & 2(y_k - 1) \end{bmatrix}}_{\mathbf{g}'(x_k, y_k)} \underbrace{\begin{bmatrix} (x_k - 1)^2 + y_k^2 - 1 \\ x_k^4 + y_k^4 - 1 \\ x_k^2 + (y_k - 1)^2 - \frac{1}{2} \end{bmatrix}}_{\mathbf{g}(x_k, y_k)}$$

## Matlab:

```
x = [1;1];
for iter = 1:10
    g = [(x(1)-1)^2+x(2)^2-1; x(1)^4+x(2)^4-1; x(1)^2+(x(2)-1)^2-.5];
    x = x - [2*(x(1)-1) 2*x(2); 4*x'.^3; 2*x(1) 2*(x(2)-1)] \ g;
    fprintf('x=(%.12g,%.12g) g=(%.12g,%.12g,%.12g)\n',x,g);
end

x=(0.75,1) g=(0,1,0.5)
x=(0.696777860013,0.945770115246) g=(0.0625,0.31640625,0.0625)
x=(0.691092552216,0.940578214706) g=(-0.0135752229284,0.0358061117489,-0.0115597333957)
x=(0.691002680826,0.94054818438) g=(-0.0198888107249,0.0107820331379,-0.0188601357041)
x=(0.691002154829,0.940548357781) g=(-0.0198897696029,0.0105634499047,-0.0189807767107)
x=(0.691002152527,0.940548357855) g=(-0.0198891183559,0.0105633328127,-0.0189815242591)
x=(0.691002152516,0.940548357857) g=(-0.0198891167934,0.0105633300224,-0.0189815274491)
x=(0.691002152516,0.940548357857) g=(-0.0198891167821,0.0105633300147,-0.0189815274653)
x=(0.691002152516,0.940548357857) g=(-0.019889116782,0.0105633300146,-0.0189815274654)
x=(0.691002152516,0.940548357857) g=(-0.019889116782,0.0105633300146,-0.0189815274654)
```



# Levenberg-Marquardtova metoda

Zopakujme:

- $\|\mathbf{Ax} - \mathbf{b}\|^2$  nabývá minima pro  $\mathbf{x} = \mathbf{A}^+\mathbf{b} = (\mathbf{A}^T\mathbf{A})^{-1}\mathbf{A}^T\mathbf{b}$ .
- $\|\mathbf{Ax} - \mathbf{b}\|^2 + \mu\|\mathbf{x}\|^2$  (kde  $\mu > 0$ ) nabývá minima pro  $\mathbf{x} = (\mathbf{A}^T\mathbf{A} + \mu\mathbf{I})^{-1}\mathbf{A}^T\mathbf{b}$ .
- Matice  $\mathbf{A}^T\mathbf{A} + \mu\mathbf{I}$  je regulární pro každou  $\mathbf{A}$ . Člen  $\mu\|\mathbf{x}\|^2$  je **regularizátor**.

**Iterace L-M metody:** Známe  $\mathbf{x}_k$  a najdeme  $\mathbf{x}_{k+1}$  které minimalizuje funkci

$$\|\mathbf{g}(\mathbf{x}_k) + \mathbf{g}'(\mathbf{x}_k)(\mathbf{x}_{k+1} - \mathbf{x}_k)\|^2 + \mu_k\|\mathbf{x}_{k+1} - \mathbf{x}_k\|^2.$$

Ta nabývá minimum pro

$$\mathbf{x}_{k+1} = \mathbf{x}_k - (\mathbf{g}'(\mathbf{x}_k)^T\mathbf{g}'(\mathbf{x}_k) + \mu_k\mathbf{I})^{-1}\mathbf{g}'(\mathbf{x}_k)^T\mathbf{g}(\mathbf{x}_k).$$

- Pro  $\mu_k \approx 0$  se blíží Gauss-Newtonově iteraci.
- Pro  $\mu_k \gg 0$  se blíží iteraci grad. metody:  $\mathbf{x}_{k+1} \approx \mathbf{x}_k - \frac{1}{\mu_k} \underbrace{\mathbf{g}'(\mathbf{x}_k)^T\mathbf{g}(\mathbf{x}_k)}_{\frac{1}{2}f'(\mathbf{x}_k)^T}$




Heuristika pro volbu  $\mu_k$  (také nahrazuje line search):

- Pokud  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$ , iteraci přijmeme a  $\mu_k$  zmenšíme (např. 2 krát).
- Pokud  $f(\mathbf{x}_{k+1}) \geq f(\mathbf{x}_k)$ , iteraci odmítneme a  $\mu_k$  zvětšíme (např. 2 krát).

# Příklad: Rekonstrukce scény z fotografií




3D Reconstruction



## Model kamery

- $\mathbf{X} \in \mathbb{R}^3$  je bod ve scéně
- $\theta$  jsou parametry kamery
- $\mathbf{x} \in \mathbb{R}^2$  je obraz bodu  $\mathbf{X}$  v kameře




Model perspektivní kamery bez radiálního zkreslení:

$$\mathbf{x} = \mathbf{p}(\mathbf{X}, \theta) = \pi(\mathbf{K}\mathbf{R}(\mathbf{X} - \mathbf{t})) \quad \text{kde} \quad \pi(x, y, z) = (x/z, y/z)$$

- $\theta = (\mathbf{R}, \mathbf{t}, \mathbf{K})$
- $\mathbf{R} \in \mathbb{R}^{3 \times 3}$  je rotační matice,  $\mathbf{t} \in \mathbb{R}^3$  je poloha středu kamery (vnější parametry kamery)
- $\mathbf{K} \in \mathbb{R}^{3 \times 3}$  je horní trojúhelníková matice (vnitřní parametry: ohnisková vzdálenost atd.)

## Rekonstrukce jednoho bodu

**Úloha:** Známe obrazy  $\mathbf{x}_1, \dots, \mathbf{x}_m$  bodu  $\mathbf{X}$  v kamerách a parametry kamer  $\theta_1, \dots, \theta_m$ . Odhadni bod  $\mathbf{X}$ .



Řešení:

1. Najdi počáteční odhad bodu  $\mathbf{X}$  vhodnou lineární metodou.

2. Upřesni odhad  $\mathbf{X}$  minimalizací funkce 
$$\sum_{i=1}^m \|\mathbf{p}(\mathbf{X}, \theta_i) - \mathbf{x}_i\|^2.$$

**Úloha:** Známe obrazy  $\mathbf{x}_{ij}$  bodů  $\mathbf{X}_j$  v kamerách  $\theta_i$  (kde  $i = 1, \dots, m$ ,  $j = 1, \dots, n$ ). Odhadni body  $\mathbf{X}_1, \dots, \mathbf{X}_n$  a parametry  $\theta_1, \dots, \theta_m$ .

Řešení:

1. Najdi počáteční odhad  $\mathbf{X}_1, \dots, \mathbf{X}_n$  a  $\theta_1, \dots, \theta_m$  vhodnou lineární metodou.

2. Upřesni odhad minimalizací funkce 
$$\sum_{i=1}^m \sum_{j=1}^n \|\mathbf{p}(\mathbf{X}_j, \theta_i) - \mathbf{x}_{ij}\|^2$$

Tento krok je známý jako **bundle adjustment**.

# Přehled probraných metod

| úloha   | metoda                  | iterace metody   |
|---|-------------------------|--|
| $\min_{\mathbf{x}} f(\mathbf{x})$   | obecná sestupná         | $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{v}_k$  |
| $\min_{\mathbf{x}} f(\mathbf{x})$   | gradient                | $\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f'(\mathbf{x}_k)^T$  |
| $\min_{\mathbf{x}} f(\mathbf{x})$   | preconditioned gradient | $\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{C}_k^{-1} f'(\mathbf{x}_k)^T$  |
| $\mathbf{g}(\mathbf{x}) = \mathbf{0}$   | Newton                  | $\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1} \mathbf{g}(\mathbf{x}_k)$  |
| $\min_{\mathbf{x}} f(\mathbf{x})$   | Newton                  | $\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T$   |
| $\min_{\mathbf{x}} \underbrace{\ \mathbf{g}(\mathbf{x})\ ^2}_{f(\mathbf{x})}$ | Gauss-Newton            | $\begin{aligned} \mathbf{x}_{k+1} &= \mathbf{x}_k - \alpha_k \mathbf{g}'(\mathbf{x}_k)^+ \mathbf{g}(\mathbf{x}_k) \\ &= \mathbf{x}_k - \alpha_k \frac{1}{2} (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T \end{aligned}$ |
| $\min_{\mathbf{x}} \underbrace{\ \mathbf{g}(\mathbf{x})\ ^2}_{f(\mathbf{x})}$ | Levenberg-Marquardt     | $\mathbf{x}_{k+1} = \mathbf{x}_k - \frac{1}{2} (\mathbf{g}'(\mathbf{x}_k)^T \mathbf{g}'(\mathbf{x}_k) + \mu_k \mathbf{I})^{-1} f'(\mathbf{x}_k)^T$   |

Hledejte v tabulce souvislosti!