Optimalizace

7. Volné lokální extrémy

Tomáš Werner, Tomáš Kroupa

12. listopadu 2024

FEL ČVUT

Analytické podmínky na volné lokální extrémy

Věta (podmínka prvního řádu)

Nechť funkce $f\colon \mathbb{R}^n \to \mathbb{R}$ je v bodě $\mathbf{x} \in \mathbb{R}^n$ (totálně) diferencovatelná.
Jestliže $\mathbf{x}$ je lokální extrém funkce f, pak $f'(\mathbf{x}) = \mathbf{0}$.

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 $f\colon \mathbb{R}^n \to \mathbb{R}$ 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 positivně [negativně] semidefinitní.
- Jestliže $f'(\mathbf{x}) = \mathbf{0}$ a Hessova matice $f''(\mathbf{x})$ je positivně [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 extrémy

Rychlost konvergence iteračních algoritmů

Nechť posloupnost bodů $\mathbf{x}_k \in \mathbb{R}^n$ $(k = 0, 1, 2, \ldots)$ konverguje k bodu $\mathbf{x}^*$.
Pak posloupnost čísel $r_k = \|\mathbf{x}_k - \mathbf{x}^*\| \geq 0$ konverguje k nule.

Definice: Jestliže existuje limita

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

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

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

Příklady:

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

Co když limita neexistuje? Existuje-li posloupnost r'_k tak, že r'_k konverguje např. lineárně a $r_k \leq r'_k \; \forall k$, řekneme že r_k konverguje **alespoň** lineárně.

Sestupné metody, názvosloví

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

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

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

  kde $\mathbf{v}_k$ je **směr hledání** a $\alpha_k > 0$ určuje **délku kroku**.
- $\mathbf{v}_k, \alpha_k$ mohou záviset na hodnotách a derivacích funkce f v bodech $\mathbf{x}_k, \mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \ldots$ (často závisí jen na $\mathbf{x}_k$).
  Řád metody je nejvyšší řád použitých derivací.

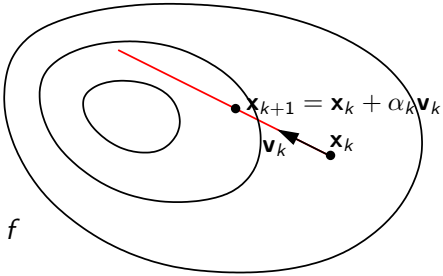

Sestupné metody: pro každé k platí $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$.

- $\mathbf{v}_k$ 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 $\alpha_k > 0$ tak, že $f(\mathbf{x}_{k+1}) = f(\mathbf{x}_k + \alpha_k \mathbf{v}_k) < f(\mathbf{x}_k)$.

Volba součinitele délky kroku α_k

- **Optimální délka kroku (exact line search)**:
  α_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 nějaké $\alpha > 0$ tak, aby $\varphi(\alpha) < \varphi(0)$.

  Backtracking line search: Začneme od nějakého velkého $\alpha > 0$ 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 libovolná konstanta (stejná pro všechny iterace).

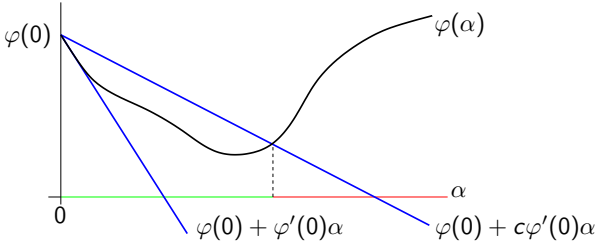

- **Pevná posloupnost** součinitelů α_k. Obvykle splňuje

$$\lim_{k\to\infty} \alpha_k = 0, \qquad \sum_{k=1}^{\infty} \alpha_k = \infty.$$

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

Tyto dvě volby negarantují monotónní pokles funkce f.

Gradientní metoda

Gradientní metoda (Gradient Descent)

Iterace: $\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \nabla f(\mathbf{x}_k)$

- Směr $\mathbf{v}_k = -\nabla'(\mathbf{x}_k) = -f'(\mathbf{x}_k)^T$ 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).

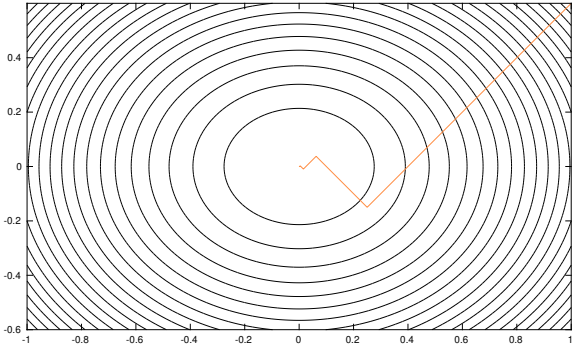

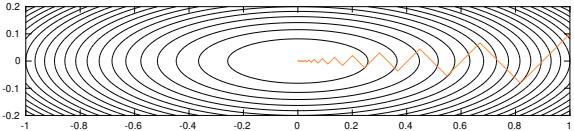

Newtonova metoda

Newtonova metoda na řešení soustavy rovnic

Řešíme soustavu rovnic $\mathbf{g}(\mathbf{x}) = \mathbf{0}$, kde $\mathbf{g}\colon \mathbb{R}^n \to \mathbb{R}^n$ je dané diferencovatelné zobrazení.

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

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

To je lineární soustava s řešením

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

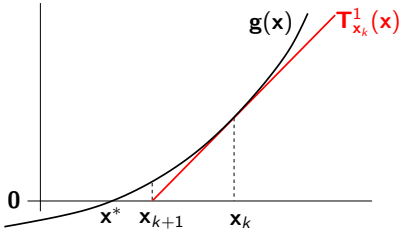

- Konverguje, jestliže počáteční odhad $\mathbf{x}_0$ je ‘dost’ blízko nějakého kořene.
- **Tvrzení:** Jestliže konverguje, pak konverguje **superlineárně**.

Příklad pro $n = 1$: Babylónská metoda na výpočet druhé odmocniny

Řešíme

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

Iterace:

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

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 pro $n = 2$: Průsečík dvou rovinných křivek

Najdi řešení soustavy dvou rovnic o dvou neznámých:

$$(x-1)^2 + y^2 = 1$$
$$x^4 + y^4 = 1$$

Iterace:

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

```
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 $f\colon \mathbb{R}^n \to \mathbb{R}$.

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

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

Jiný pohled: Minimalizujeme Taylorův polynom $T^2_{\mathbf{x}_k}(\mathbf{x}_{k+1})$ funkce f stupně 2 v okolí $\mathbf{x}_k$

$$T^2_{\mathbf{x}_k}(\mathbf{x}_{k+1}) = f(\mathbf{x}_k) + f'(\mathbf{x}_k)\,(\mathbf{x}_{k+1} - \mathbf{x}_k) + \tfrac{1}{2}(\mathbf{x}_{k+1} - \mathbf{x}_k)^T f''(\mathbf{x}_k)\,(\mathbf{x}_{k+1} - \mathbf{x}_k)$$

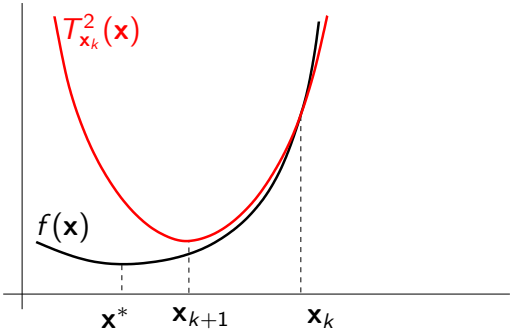

Přidání délky kroku

Pro lepší konvergenci lze přidat součinitel délky 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 $\alpha_k = 1$ se metoda nazývá **čistá** Newtonova metoda.

- **Newtonův směr** $\mathbf{v}_k = -f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T$ je sestupný, když $f''(\mathbf{x}_k)$ je positivně definitní:

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

- Pak je výhodné soustavu $f''(\mathbf{x}_k)\mathbf{v}_k = -f'(\mathbf{x}_k)^T$ 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 $\mathbf{g}\colon \mathbb{R}^n \to \mathbb{R}^m$ 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: zobrazení $\mathbf{g}(\mathbf{x}) = \mathbf{A}\mathbf{x} - \mathbf{b}$ je afinní.

Gaussova-Newtonova metoda

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

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

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 $\alpha_k = 1$ se metoda nazývá **čistá** Gaussova-Newtonova metoda.

Gaussův-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:

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

Rozdíl oproti Newtonově metodě

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

- Gaussův-Newtonův směr je

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

- Newtonův směr je

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

Gaussova-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: Přibližný průsečík tří rovinných křivek

Najdi přibližné řešení soustavy tří rovnic o dvou neznámých:

$$\begin{aligned}(x-1)^2+y^2&=1\\ x^4+y^4&=1\\ x^2+(y-1)^2&=\tfrac{1}{2}\end{aligned}$$

Tedy minimalizujeme funkci

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

Iterace čisté Gaussovy-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)
```

Levenbergova-Marquardtova metoda

Zopakujme lineární úlohu nejmenších čtverců s regularizací:

- $\|\mathbf{A}\mathbf{x} - \mathbf{b}\|^2 + \mu\|\mathbf{x}\|^2$ (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 $\mathbf{A}$.

Iterace LM metody: Pro známé $\mathbf{x}_k$ najdeme $\mathbf{x}_{k+1}$ jako minimum funkce

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

tedy

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

- Pro $\mu_k \approx 0$ se blíží Gaussově-Newtonově iteraci.
- Pro $\mu_k \gg 0$ se blíží iteraci gradientní 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 μ_k (zároveň nahrazuje line search):

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

Příklad: Rekonstrukce scény z mnoha fotografií

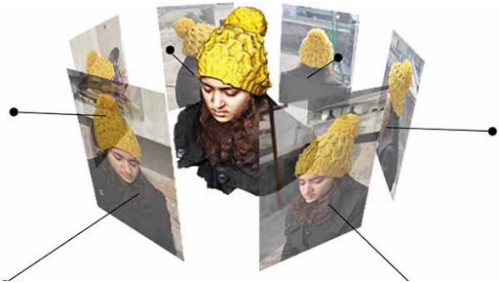

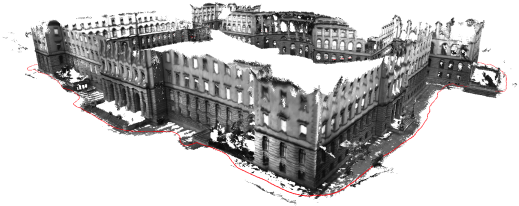

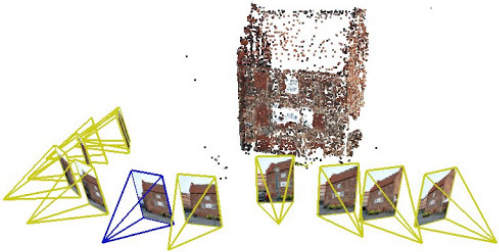

Zobrazení bodu v prostoru kamerou

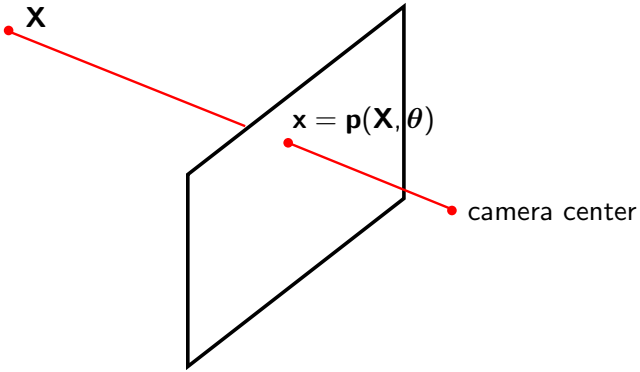

- $\mathbf{X} \in \mathbb{R}^3$ je bod ve scéně
- $\mathbf{x} \in \mathbb{R}^2$ je obraz bodu $\mathbf{X}$ v kameře
- $\boldsymbol{\theta}$ jsou parametry kamery (poloha, natočení, zoom, radiální zkreslení, ...)

Rekonstrukce jednoho bodu

Známe obrazy $\mathbf{x}_1, \ldots, \mathbf{x}_m$ bodu $\mathbf{X}$ v kamerách a parametry kamer $\boldsymbol{\theta}_1, \ldots, \boldsymbol{\theta}_m$. Odhadni bod $\mathbf{X}$.

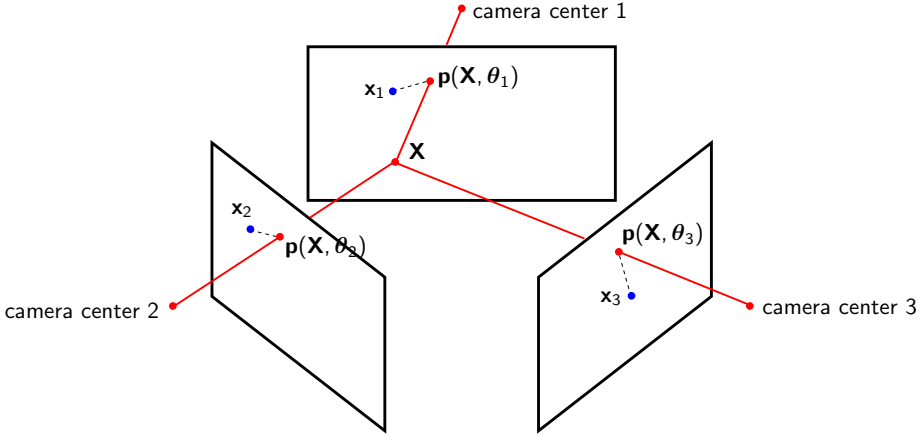

Řešení:

1. Najdi počáteční odhad bodu $\mathbf{X}$ vhodnou lineární metodou (neuvádíme).
2. Upřesni odhad $\mathbf{X}$ minimalizací funkce $\sum_{i=1}^{m} \|\mathbf{p}(\mathbf{X}, \boldsymbol{\theta}_i) - \mathbf{x}_i\|^2$.

Rekonstrukce bodů a kamer

Známe obrazy $\mathbf{x}_{ij}$ bodů $\mathbf{X}_j$ v kamerách $\boldsymbol{\theta}_i$ (kde $i = 1, \ldots, m,\ \ j = 1, \ldots, n$).
Odhadni body $\mathbf{X}_1, \ldots, \mathbf{X}_n$ a parametry $\boldsymbol{\theta}_1, \ldots, \boldsymbol{\theta}_m$.

Řešení:

1. Najdi počáteční odhad $\mathbf{X}_1, \ldots, \mathbf{X}_n$ a $\boldsymbol{\theta}_1, \ldots, \boldsymbol{\theta}_m$ vhodnou lineární metodou.
2. Upřesni odhad minimalizací funkce $\displaystyle\sum_{i=1}^{m}\sum_{j=1}^{n} \|\mathbf{p}(\mathbf{X}_j, \boldsymbol{\theta}_i) - \mathbf{x}_{ij}\|^2$

   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	$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f'(\mathbf{x}_k)^T$
$\mathbf{g}(\mathbf{x}) = \mathbf{0}$	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	$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^T$
$\min_{\mathbf{x}} \underbrace{\lVert\mathbf{g}(\mathbf{x})\rVert^2}_{f(\mathbf{x})}$	Gauss-Newton	$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \mathbf{g}'(\mathbf{x}_k)^{+}\mathbf{g}(\mathbf{x}_k)$ $= \mathbf{x}_k - \alpha_k \frac{1}{2}(\mathbf{g}'(\mathbf{x}_k)^T\mathbf{g}'(\mathbf{x}_k))^{-1} f'(\mathbf{x}_k)^T$
$\min_{\mathbf{x}} \underbrace{\lVert\mathbf{g}(\mathbf{x})\rVert^2}_{f(\mathbf{x})}$	Levenberg-Marquardt	$\mathbf{x}_{k+1} = \mathbf{x}_k - \frac{1}{2}(\mathbf{g}'(\mathbf{x}_k)^T\mathbf{g}'(\mathbf{x}_k) + \mu_k \mathbf{I})^{-1} f'(\mathbf{x}_k)^T$

Neučte se vzorečky nazpaměť, ale naučte se je odvodit!

Hledejte v tabulce souvislosti!