

Nepodmíněná optimalizace

- Uvažujeme (striktně) konvexní funkce f
- Obor hodnot $\mathcal{H} \subset \mathcal{R}$ – jednokriteriální optimalizace
- Definiční obor $\mathcal{O} = \mathcal{R}^N$ – žádné omezující podmínky
- Jedná se o tzv. *nepodmíněnou optimalizaci* – základní úloha matematického programování
- Pro jednoduchost uvažujeme dostatečně hladké funkce
- Základní myšlenka – aproximace kvadratickými funkcemi

Nepodmíněná optimalizace v jednom rozměru

- Taylorův rozvoj funkce f v bodě x_0

$$f(x) \approx f(x_0) + \frac{df}{dx}(x_0)(x - x_0) + \frac{1}{2} \frac{d^2 f}{d^2 x^2}(x_0)(x - x_0)^2$$

- V obecném případě by přibyly ještě členy $(\xi - x_0)^3$, kde

$$x_0 \leq \xi \leq x,$$

ty ale můžeme pro x blízko x_0 zanedbat.

- Zvolíme optimální řešení x_{opt} jako x_0 :

$$\begin{aligned} f(x) &\approx f(x_{opt}) + \frac{df}{dx}(x_{opt})(x - x_{opt}) + \frac{1}{2} \frac{d^2 f}{d^2 x^2}(x_{opt})(x - x_{opt})^2 \\ &> f(x_{opt}) \end{aligned}$$

- Pro hladkou konvexní funkci je

$$\frac{d^2 f}{d x^2}(x_{opt}) > 0$$

- Podmínka optimality

$$\frac{d f}{d x}(x_{opt}) = 0$$

- Pokud pro x_0 není předchozí podmínka splněna, provedeme opravu

$$\begin{aligned} 0 &= \frac{d f}{d x}(x_{opt}) \approx \frac{d f}{d x}(x_0) + \frac{d^2 f}{d x^2}(x_0)(x_{opt} - x_0) \\ \Rightarrow x_{opt} &\approx x_0 - \left(\frac{d^2 f}{d x^2}(x_0)\right)^{-1} \frac{d f}{d x}(x_0) \end{aligned}$$

- Newtonova metoda pro podmínky optimality \Rightarrow velmi rychle konverguje k optimálnímu řešení

- Jak zkonstruovat algoritmus založený na podmínkách optimality?

1. Nastav $k = 0$ a zvol počáteční bod x_0

2. Urči

$$g_k = \frac{df}{dx}(x_k)$$

3. Pokud $|g_k| < \text{tolerance}$ $x_k \rightarrow x_{opt}$ a ukonči algoritmus

4. Urči

$$h_k = \frac{d^2 f}{d x^2}(x_k)$$

5. Proveď aktualizaci

$$x_{k+1} = x_k - h_k^{-1} g_k$$

6. $k = k + 1$, jdi na krok 2

Nepodmíněná optimalizace ve více rozměrech

- Taylorův rozvoj funkce f v bodě \mathbf{x}_0

$$f(\mathbf{x}) \approx f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)^\top \nabla^2 f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

- ∇f je *gradient* funkce f [směr největšího spádu]

$$\nabla f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_N} \end{bmatrix} (\mathbf{x})$$

- $\nabla^2 f$ označuje Hessián funkce f :

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_N} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_N \partial x_1} & \frac{\partial^2 f}{\partial x_N \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_N^2} \end{bmatrix} (\mathbf{x})$$

- Pro striktně konvexní funkci platí $\mathbf{a}^\top \nabla^2 f(\mathbf{x}) \mathbf{a} > 0$ pro $\mathbf{a} \neq \mathbf{0}$, Hessián je tedy *pozitivně definitní* a tudíž invertovatelný
- Opět zvolíme optimální řešení \mathbf{x}_{opt} jako \mathbf{x}_0 :

$$\begin{aligned} f(\mathbf{x}_{opt}) &\approx f(\mathbf{x}_{opt}) + \nabla f^\top(\mathbf{x}_{opt})(\mathbf{x} - \mathbf{x}_{opt}) \\ &+ \frac{1}{2} (\mathbf{x} - \mathbf{x}_{opt})^\top \nabla^2 f(\mathbf{x}_{opt}) (\mathbf{x} - \mathbf{x}_{opt}) > f(\mathbf{x}_{opt}) \end{aligned}$$

- Podmínka optimality

$$\nabla \mathbf{f}(\mathbf{x}_{opt}) = \mathbf{0}$$

- Pokud pro \mathbf{x}_0 není předchozí podmínka splněna, provedeme lineární opravu

$$\mathbf{x}_{opt} \approx \mathbf{x}_0 - (\nabla^2 \mathbf{f}(\mathbf{x}_0))^{-1} \nabla \mathbf{f}(\mathbf{x}_0)$$

- Algoritmus

1. Nastav $k = 0$ a zvol počáteční bod \mathbf{x}_0

2. Urči

$$\mathbf{g}_k = \nabla \mathbf{f}(x_k)$$

3. Pokud $\|\mathbf{g}_k\| < \text{tolerance}$ $\mathbf{x}_k \rightarrow \mathbf{x}_{opt}$ a ukonči algoritmus

4. Urči

$$\mathbf{H}_k = \nabla^2 \mathbf{f}(\mathbf{x}_k)$$

5. Proved' aktualizaci

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{H}_k^{-1} \mathbf{g}_k$$

6. $k = k + 1$, jdi na krok 2

Výhody a nevýhody předchozího algoritmu

- Metoda konverguje velmi rychle
- V každém kroku se řeší *plná* soustava lineárních rovnic → může být časově náročné → Navrženy iterační metody které “rekonstruuji” Hessian [2] nebo ho vůbec nepotřebují – např. metoda sdružených gradientů [3]
- Silně závisí na požadavcích konvexity cílové funkce, pro jiné úlohy může být nestabilní
- *Globální* varianty těchto algoritmů → zajištěna konvergence v konečném množství kroků do *lokálního* minima [1, 2]

Reference

- [1] J. F. Bonnans, J. C. Gilbert, J. C. Lemarechal, and C. A. Sagastizabal, *Numerical optimization: Theoretical and practical aspects*, Springer-Verlag, Berlin, Heidelberg, 2004.
- [2] L. Lukšan, *Numerické optimalizační metody*, Tech. Report 930, Ústav informatiky AVČR, 2005, <http://www.cs.cas.cz/ics/reports/v930-05.ps>.
- [3] J.R. Shewchuk, *An introduction to the conjugate gradient method without the agonizing pain*, Tech. report, Computer Science Division, University of California at Berkeley, 1994, <http://www.cs.cmu.edu/~quake-papers/painless-conjugate-gradient.pdf>.

□

Prosba. V případě, že v textu objevíte nějakou chybu nebo budete mít námět na jeho vylepšení, ozvěte se prosím na zemanj@cml.fsv.cvut.cz.

Verze –003