

Přednáška 23 - nelineární LS a minimalizace

opáčko - nelineární nejmenší čtverce: $\min_{\vec{\theta}} \left\| \left[\frac{1}{\sigma_i} f(x_i, \vec{\theta}) - b_i \right]_{i=1}^m \right\|^2$

\leadsto zdefinujeme $g_i(x_i, \vec{\theta}) := \frac{1}{\sigma_i} f(x_i, \vec{\theta}) - b_i$

$\leadsto \min_{\vec{\theta}} \sqrt{g_1(x_1, \vec{\theta})^2 + \dots + g_m(x_m, \vec{\theta})^2}$

\leadsto potřebujeme metody pro numerickou minimalizaci

\rightarrow chceme řešit $\min_{\vec{\theta}} F(\vec{\theta})$ (to se samozřejmě hodí i v jiných aplikacích)

My si tu víceméně představíme „jen hlavní myšlenky“

- všechny minimalizační metody jsou iterativní
 \Rightarrow produkují posloupnost $\vec{\theta}_0, \vec{\theta}_1, \dots, \vec{\theta}_n$
- myšlenky „jak získat $\vec{\theta}_n$ z $\vec{\theta}_{n-1}, \vec{\theta}_{n-2}, \dots$ “ se liší:

Derivative-based

\leadsto založené na používání (parciálních)

derivací funkce $F(\vec{\theta}_n)$. Často založeno

na hledání bodů $\vec{\theta}_{\text{kandidát}}$: $[\nabla F](\vec{\theta}_{\text{kandidát}}) = \vec{0}$.

ponocí nějaké iterací metody

Derivative-free

\leadsto odvozené pouze z vyhodnocování

$F(\vec{\theta})$ v několika bodech a iterativním

procesu založeném na jejich hodnotách.

Používáme interpolace/heuristiky.

first-order

pouze derivace 1. řádu,
tedy pouze gradient F

second-order

derivace 1. a 2. řádu,
tedy gradient a Hessian

téměř všechny základní
myšlenky „kopírují“ hledání

minima fce $\mathbb{R} \rightarrow \mathbb{R}$ z prvéku

např.:

- $f'(x) < 0 \Rightarrow f$ je v bodě

- x klesající („ve směru $-f'(x)$ “)

- nutná podmínka

$$f'(x_{\text{opt}}) = 0$$

V praxi můžeme mít i tzv. constrained minim. problémy

kde parametry $\vec{\theta}$ jsou uvažovány pouze v nějaké množině, např.

$$\vec{\theta} \in \{ \|\vec{\theta}\|^2 = 1 \} \text{ nebo } \{ \max_{i=1, \dots, n} |\theta_i| < 5 \} \text{ nebo } \{ \vec{\theta} \in \mathbb{R}^n \mid C \cdot \vec{\theta} = \vec{d} \}$$

pro dané $C \in \mathbb{R}^{m \times n}$, $\vec{d} \in \mathbb{R}^m$

Derivative-free metody (příklad: Nelder-Mead)

$\vec{\theta} \in \mathbb{R}^2 \rightarrow$ pracujeme s trojúhelníky (určeno 2+1 body v \mathbb{R}^2)

$\mathbb{R}^3 \rightarrow$ pracujeme se čtyřstěny (určeno 3+1 body v \mathbb{R}^3)

$\mathbb{R}^n \rightarrow$ pracujeme se „simplexy v \mathbb{R}^n “ :

$$\vec{x}_1, \dots, \vec{x}_{n+1} \in \mathbb{R}^n \Rightarrow S_{\vec{x}_1, \dots, \vec{x}_{n+1}} := \left\{ \sum_{i=1}^{n+1} d_i \cdot \vec{x}_i \mid d_i \in (0,1) \wedge d_1 + \dots + d_{n+1} = 1 \right\} \text{ je tzv. simplex}$$

$\&$ $\vec{x}_2 - \vec{x}_1, \dots, \vec{x}_{n+1} - \vec{x}_1$ lin. nezávl.


Předpokládejme, že máme body $\vec{\theta}_1, \dots, \vec{\theta}_{n+1}$.
 Chceme přidat bod $\vec{\theta}_{n+2}$.

} předhod od simplexu $S_{\vec{\theta}_1, \dots, \vec{\theta}_{n+1}}$ k novému, lepšímu $S^{(new)}$ výměnou jednoho bodu $\vec{\theta}_1, \dots, \vec{\theta}_{n+1}$

Krok 1: spočítat $F(\vec{\theta}_1), \dots, F(\vec{\theta}_{n+1})$

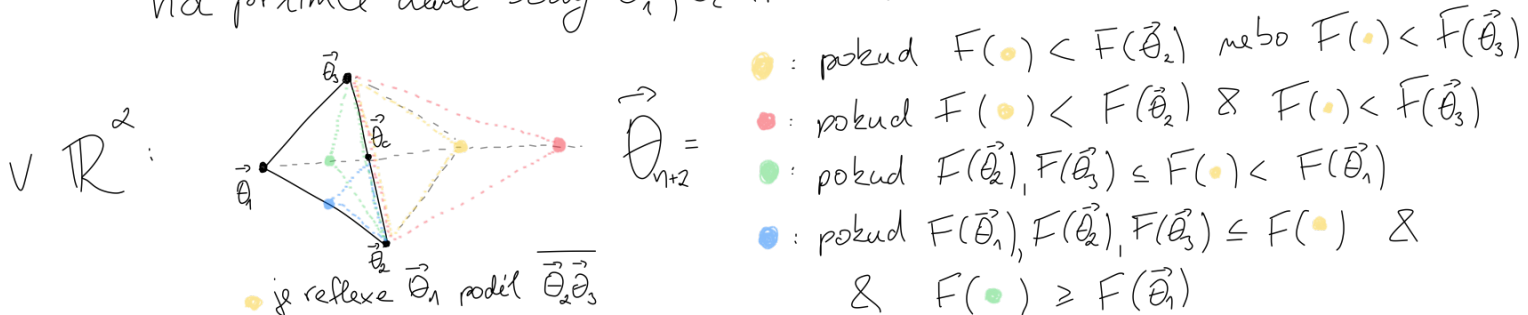
\rightarrow vyměníme $\vec{\theta}_{\max} \equiv \vec{\theta}_{\hat{i}} = \operatorname{argmax}_i |F(\vec{\theta}_i)|$

\rightarrow zachováme $\vec{\theta}_1, \dots, \vec{\theta}_{\hat{i}-1}, \vec{\theta}_{\hat{i}+1}, \dots, \vec{\theta}_{n+1} \rightarrow$ n bodů, které určují „protější stěnu“
 (tj. protější stěnu simplexu $S_{\vec{\theta}_1, \dots, \vec{\theta}_{n+1}}$ k bodu $\vec{\theta}_{\hat{i}}$) \rightsquigarrow označíme $\vec{\theta}_c$ jako centrum této stěny



Krok 2: za co $\vec{\theta}_{\hat{i}}$ vyměnit?


\rightarrow heuristika: $\vec{\theta}_{\hat{i}}$ bylo nejhorší \rightsquigarrow vezmeme $\vec{\theta}_{n+2}$ jako nějaký bod na přímce dané body $\vec{\theta}_{\hat{i}}, \vec{\theta}_c$ (pokud nejsou „všechny horší“)



Obdobné heuristické postupy jsou dáány i pro obecné \mathbb{R}^n .

Příklad vývoje v \mathbb{R}^2 :

počáteční simplex $\vec{\theta}_1, \vec{\theta}_2, \vec{\theta}_3$



barvičky jsou tedy "pouze" pořadí iterací, tj. $\bullet, \bullet, \bullet, \bullet, \bullet$ nesouvisí s předchozí stránkou a tím jak z jednoho simplexu dostanete následující

a algoritmus Nelder-Mead by odtud pokračoval dále

Záruky konvergence "skoro neexistují", ale v praxi často dobře funguje (speciálně v nižších dimenzích), je robustní & výpočetně "nendrobný" (1 iterace \approx 2x vyhodnocení funkce F)

Derivative-based metody

Analýza/kalkulus: $F: \mathbb{R}^n \rightarrow \mathbb{R}, \vec{\theta}_0 \in \mathbb{R}^n \implies$ funkce F klesá nejrychleji ve směru $(-\nabla F)(\vec{\theta}_0)$

$\vec{\theta}_{opt} \in \mathbb{R}^d$ je lokální extrém F & $(\nabla_{\vec{\theta}} F)(\vec{\theta}_{opt})$ existuje $\implies (\nabla_{\vec{\theta}} F)(\vec{\theta}_{opt}) = \vec{0}$

1st order metody (příklad: Steepest descent metody \implies založeno na \bullet) pouze směr, tj. $\|\vec{d}_k\| = 1$

idea: máme $\vec{\theta}_k$ a chceme $\vec{\theta}_{k+1} = \vec{\theta}_k + \text{update}$ \implies update = nějaký vektor $\equiv \alpha_k \cdot \vec{d}_k$
 \rightarrow jak volíme \vec{d}_k ? Jako směr ve kterém okolo $\vec{\theta}_k$ klesá F nejrychleji \implies podle \bullet $\vec{d}_k = (-\nabla F)(\vec{\theta}_k) / \|\nabla F(\vec{\theta}_k)\|$
 jak daleko přijde ve směru \vec{d}_k

V praxi buď musí user poskytnout rutinou pro výpočet $\vec{\theta} \mapsto \nabla F(\vec{\theta})$ nebo se používají aproximace $\rightarrow [\nabla F(\vec{\theta})]_i = \lim_{h \rightarrow 0} \frac{F(\vec{\theta} + h \vec{e}_i) - F(\vec{\theta})}{h} \approx \frac{F(\vec{\theta} + h \vec{e}_i) - F(\vec{\theta})}{h}$

\rightarrow jak volíme α_k ? Záleží na konkrétním typu metody. Nalezení optimálního α_k už je samo o sobě pouze 1D minimalizace (argument $F(\vec{\theta}_k + \alpha_k \vec{d}_k)$) \rightarrow tzv. line-search.
 V praxi používáme spoustu různých heuristik (Armijo rule, trust region, ...).
 Ale v principu lze použít i např. Nelder-Mead (v \mathbb{R}^1) na nalezení optimálního α_k

2nd order metody (příklad: quasi-Newton metody → založeno na •)

idea: chceme najít body $\vec{\theta}_{\text{kand}}^{(1)}, \vec{\theta}_{\text{kand}}^{(2)}, \dots, \vec{\theta}_{\text{kand}}^{(d)}$ pro které $\nabla F(\vec{\theta}_{\text{kand}}^{(i)}) = \vec{0}$,

tj. chceme vyřešit (nelineární) soustavu rovnic → Newtonova metoda.

⇒ budu potřebovat „aproximovat“ moji nelineární funkci ∇F pomocí lineární → Jacobian funkce ∇F

⇒ tzv. Hessian funkce F :

$$\vec{\theta} \mapsto \begin{bmatrix} \frac{\partial^2 F}{\partial \theta_1^2}(\vec{\theta}) & \dots & \frac{\partial^2 F}{\partial \theta_1 \partial \theta_n}(\vec{\theta}) \\ \vdots & & \vdots \\ \frac{\partial^2 F}{\partial \theta_n \partial \theta_1}(\vec{\theta}) & \dots & \frac{\partial^2 F}{\partial \theta_n^2}(\vec{\theta}) \end{bmatrix} =: H_{\vec{\theta}}$$

→ z Newtonovy metody:

$$\vec{\theta}_{k+1} = \vec{\theta}_k - \vec{v}_k \quad \text{kde} \quad [H_{\vec{\theta}_k}] \vec{v}_k = \nabla_{\vec{\theta}} F(\vec{\theta}_k)$$

→ Jak získat $\nabla F(\vec{\theta}_k)$ & $[H_{\vec{\theta}_k}]$? ⇒ buď máme user poskytnuté routiny $\vec{\theta} \mapsto \nabla F(\vec{\theta})$ & $\vec{\theta} \mapsto [H_{\vec{\theta}}]$ nebo aproximace.

• Aproximace ve stylu „diferenci“:

$$(\nabla F(\vec{\theta}))_i = \lim_{h \rightarrow 0} \frac{F(\vec{\theta} + h \vec{e}_i) - F(\vec{\theta})}{h} \approx \frac{F(\vec{\theta} + h \vec{e}_i) - F(\vec{\theta})}{h}$$

• Aproximace ve stylu „update“:

→ tzv. quasi-Newton metody, protože nepočítáme „správný“ Hessian,

ale místo toho položíme

$$[H_{\vec{\theta}_{k+1}}] = [H_{\vec{\theta}_k}] + \text{update}$$

↑
např. rank-1: $\beta_k \vec{w}_k \vec{w}_k^T$
& volíme $\beta_k \vec{w}_k$ „optimálně“

