

# Optimalizace

Pokud máme nelineární problém nejmenších čtverců pak hledáme  $\vec{\theta}_* \in \mathbb{R}^n$  které řeší minimalizaci  $\| [\frac{1}{\sigma_i} f(x_i; \vec{\theta}) - b_i]_{i=1}^m \|_2^2$

tj. řešíme

$$\min_{\vec{\theta} \in \mathcal{C} \subseteq \mathbb{R}^n} F(\vec{\theta}) \quad \text{pro} \quad F(\vec{\theta}) := \sum_{i=1}^m (\frac{1}{\sigma_i} f(x_i; \vec{\theta}) - b_i)^2$$

$\mathcal{C} \subseteq \mathbb{R}^n$  (tak „constraint set“)

Úlohy tohoto typu jsou obecně označovány za tzv. optimalizační (úlohy hledání maxima lze převést na hledání minima změnou znaménka)

Drtivá většina numerických metod pro aproximaci řešení  $\vec{\theta}_*$  funguje opět iteračně  $\rightarrow$  na základě aproximace  $\vec{\theta}_n$  získáme (snad lepší) aproximaci  $\vec{\theta}_{n+1}$  - a tedy je zapotřebí nějaký počáteční odhad  $\vec{\theta}_0$  k nastartování.

Pokud  $\mathcal{C} = \mathbb{R}^n$  mluvíme o „unconstrained optimalizaci“

$\mathcal{C} \neq \mathbb{R}^n$  mluvíme o „constrained optimalizaci“

Zjevně musíme používat „jiné nástroje/metody“ podle  $\mathcal{C}$   
 $\rightarrow$  my se budeme bavit pouze o „unconstrained“ tj.  $\mathcal{C} = \mathbb{R}^n$ .

Metody, které si ukážeme zastupují 3 základní kategorie.

# optimalizační metody

derivative-free

metoda si vystačí s  
vyhodnocováním  $F(\cdot)$

1<sup>st</sup> order

mýšlenka je založena na  
vyhodnocování  $F(\cdot)$  a  $\nabla F(\cdot)$

2<sup>nd</sup> order

mýšlenka je založena na  
vyhodnocování  $F, \nabla F$  a  $[H_F]$

## Derivative-free

- idea je klasicky založena na „porovnávání hodnot a postupu ve směru nejmenších funkčních hodnot“
- nejdražší operace je většinou vyhodnocování  $F(\cdot)$
- konvergenci většinou nelze dokázat, ale v praxi jsou pro  $n$  malé velmi robustní

## Zaštopce: Nelder-Mead algoritmus

→ pracujeme s tzv. simplexy (simplex v  $\mathbb{R}^n$  je dán  $n+1$  body  $\vec{\theta}_0, \dots, \vec{\theta}_n$  a odpovídá všem konvexním kombinacím  $\vec{\theta}_0, \dots, \vec{\theta}_n$ )  
a v každém kroku jeden vrchol nahradíme novým  
- konkrétně ten s nejvyšší funkční hodnotou.

simplex v  $\mathbb{R} \equiv$  úsečka - dána 1+1 body  
simplex v  $\mathbb{R}^2 \equiv$  trojúhelník - dána 2+1 body  
simplex v  $\mathbb{R}^3 \equiv$  čtyřstěn - dána 3+1 body


V každém kroku tedy vyměníme 1 bod  $\equiv$  změníme simplex

To jak volíme ten nový bod je dáno heuristicky a existuje více variant - my si ilustrujeme jednu konkrétní

(shoduje se s Wiki)

# Nelder-Mead: jeden krok

- seřadíme body  $\vec{\Theta}_0, \dots, \vec{\Theta}_n$  tak, aby platilo  $F(\vec{\Theta}_0) \leq F(\vec{\Theta}_1) \leq \dots \leq F(\vec{\Theta}_n)$   
 $\rightarrow$  chceme tedy vyměnit  $\vec{\Theta}_n$  za nový bod  $\vec{\Theta}^{(new)}$




- spočítáme  $\vec{\Theta}^{(c)}$  (= centroid naproti bodu  $\vec{\Theta}_n$ )

- zkusíme najít  $\vec{\Theta}^{(new)}$  na přímce  $\vec{\Theta}_0, \vec{\Theta}^{(c)}$  tak, aby  $F(\vec{\Theta}^{(new)}) < F(\vec{\Theta}_n)$ :

- (i) zkusíme bod  $\vec{\Theta}^{(r)} := \vec{\Theta}^{(c)} + \alpha \cdot (\vec{\Theta}^{(c)} - \vec{\Theta}_n)$   
 $(\alpha > 0$  je tzv. koeficient reflexe, parametr alg.)

Pokud  $F(\vec{\Theta}_0) \leq F(\vec{\Theta}^{(r)}) < F(\vec{\Theta}_n)$ , pak  $\vec{\Theta} := \vec{\Theta}^{(new) - (r)}$



- (ii) pokud  $F(\vec{\Theta}^{(r)}) < F(\vec{\Theta}_0)$ , nabýváme dojem, že  $F(\cdot)$  výrazně klesá ve směru  $\vec{\Theta}^{(c)} - \vec{\Theta}_n \approx \vec{\Theta}^{(c)} - \vec{\Theta}_n$  a vydáme se (expandujeme) ještě o trochu dále:

$\vec{\Theta}^{(e)} := \vec{\Theta}^{(c)} + \beta \cdot (\vec{\Theta}^{(c)} - \vec{\Theta}_n)$  ( $\beta > 0$  je tzv. parametr expanze)  $\&$   $\vec{\Theta}^{(new)} := \begin{cases} \vec{\Theta}^{(e)} & \text{pokud } F(\vec{\Theta}^{(e)}) < F(\vec{\Theta}^{(r)}) \\ \vec{\Theta}^{(r)} & \text{pokud } F(\vec{\Theta}^{(e)}) \geq F(\vec{\Theta}^{(r)}) \end{cases}$

- (iii) pokud  $F(\vec{\Theta}^{(r)}) \geq F(\vec{\Theta}_{n-1})$ , nabýváme dojem, že jsme se ve směru  $\vec{\Theta}^{(c)} - \vec{\Theta}_n$  vydali nejspíše moc daleko a tedy delší krok/posunu zmenšíme (kontrahujeme), podle toho "jak špatný je  $\vec{\Theta}^{(r)}$ ":

$\begin{cases} \text{pokud } F(\vec{\Theta}^{(r)}) < F(\vec{\Theta}_{n-1}), \text{ pak } \vec{\Theta}^{(k)} := \vec{\Theta}^{(c)} + \rho \cdot (\vec{\Theta}^{(c)} - \vec{\Theta}_n) \\ \text{pokud } F(\vec{\Theta}^{(r)}) \geq F(\vec{\Theta}_{n-1}), \text{ pak } \vec{\Theta}^{(k)} := \vec{\Theta}^{(c)} + \rho \cdot (\vec{\Theta}_{n-1} - \vec{\Theta}_n) \end{cases}$   $\&$   $\vec{\Theta}^{(new)} := \vec{\Theta}^{(k)}$  pokud  $F(\vec{\Theta}^{(k)}) < F(\vec{\Theta}_n)$

- pokud jsme  $\vec{\Theta}^{(new)}$  takto nenašli (tj. dostali jsme se do bodu (iii) a podmínka není splněna) pak nevyměníme pouze  $\vec{\Theta}_n$ , ale rovnou  $\vec{\Theta}_1, \vec{\Theta}_2, \dots, \vec{\Theta}_n$  (= smrskneme simplex)

$\forall i > 0$  předefinujeme  $\vec{\Theta}_i := \vec{\Theta}_0 + \sigma \cdot (\vec{\Theta}_i - \vec{\Theta}_0)$

Obecně o konvergenci neteže mnoho dokázat, ale v praxi pro malé  $n$  ( $n \leq 5$ ) je Nelder-Mead robustní algoritmus. Jeho další přednosti jsou výpočetní náklady - nejvýše 2 vyhodnocení  $F(\cdot)$  během každé iterace.

1<sup>st</sup> order (zástupce: Steepest descent method) = metoda největšího spádu

Idea je založena na iterativním procesu: mám aproximaci  $\vec{\theta}_n$  minima funkce  $F(\cdot)$  a chci ji vylepšit  $\rightarrow \vec{\theta}_{n+1} := \vec{\theta}_n + \alpha_{n+1} \vec{v}_{n+1} \equiv$  posuneme se z  $\vec{\theta}_n$  ve směru  $\vec{v}_{n+1}$  o délku  $\alpha_{n+1}$ .  
 $\alpha_{n+1} \geq 0$   $\vec{v}_{n+1} \in \mathbb{R}^n$   $\|\vec{v}_{n+1}\| = 1$

Jak volit  $\vec{v}_{n+1} \in \mathbb{R}^n$  a  $\alpha_{n+1} \geq 0$ ?

Krok 1: předpokládejme, že  $\vec{\theta}_n$  je dobrá aproximace, tj.  $0 < \alpha_{n+1} \ll 1$ .

Pak  $F(\vec{\theta}_{n+1}) = F(\vec{\theta}_n + \alpha_{n+1} \vec{v}_{n+1}) = F(\vec{\theta}_n) + \nabla F(\vec{\theta}_n) \cdot \alpha_{n+1} \vec{v}_{n+1} + \mathcal{O}(\alpha_{n+1}^2)$

V jakém směru se máme vydat? Tak abychom minimalizovali  $F(\vec{\theta}_{n+1})$ .

Člen  $\alpha_{n+1} \nabla F(\vec{\theta}_n) \cdot \vec{v}_{n+1}$  je skalární součin 2 vektorů  $\rightarrow$  minimální pokud mají tyto vektory stejný směr a opačnou orientaci  $\rightarrow \vec{v}_{n+1} := -\nabla F(\vec{\theta}_n)$

Existuje mnoho variant a adaptací, tzv. metody největšího spádu  
ale my nepůjdeme do detailů. (protože  $F$  klesá nejrychleji ve směru  $-\nabla F$ )

Krok 2: jak volit  $\alpha_{n+1}$ ?

Teoreticky jasné  $\rightarrow$  pokud zatixuju  $\vec{v}_{n+1}$ , chci  $\alpha \geq 0$  volit abych minimalizoval  $F(\cdot)$ .

$\rightarrow \alpha_{n+1} := \underset{\alpha \geq 0}{\operatorname{argmin}} F(\vec{\theta}_n - \alpha \cdot \nabla F(\vec{\theta}_n))$  ... tzv. exact line-search  
 $\equiv$  součást optimalizace v  $\mathbb{R}^n$  je pak sekvence optimalizací v  $\mathbb{R}$

V praxi se dá použít, ale často je považováno za overkill  $\rightarrow$  místo toho se používají heuristiky a přibližné aproximace

Vyhodnocení/aproximace  $\nabla F(\cdot)$  může být výpočetně náročné (odpovídá  $\mathcal{O}(n)$  vyhodnocení  $F(\cdot)$ )

Ani zde není zaručena konvergence.

# 2<sup>nd</sup> order (zástupce: Newtonova metoda Levenberg-Marquardt)

Idea je založena na pozorování, že pokud  $\vec{\Theta}_* \in \mathbb{R}^n$  je lokální min.  
pak jistě  $\nabla F(\vec{\Theta}_*) = \vec{0}$ . Stačí tedy najít takové body, pro které platí  
Pokud mám aproximaci  $\vec{\Theta}_n \approx \vec{\Theta}_*$ , pak můžu použít Newtonovu metodu  
pro řešení soustavy rovnic s počátečním odhadem  $\vec{\Theta}_n$ :

$$\vec{\Theta}_{n+1} \stackrel{\text{Newton pro}}{=} \vec{\Theta}_n - \vec{v}_{n+1}, \text{ kde } \vec{v}_{n+1} \text{ je řešení soustavy rovnic } [H_F(\vec{\Theta}_n)] \vec{v}_{n+1} = \nabla F(\vec{\Theta}_n)$$
$$\llcorner = \vec{\Theta}_n - \frac{[H_F(\vec{\Theta}_n)]^{-1} \nabla F(\vec{\Theta}_n)}{\| [H_F(\vec{\Theta}_n)]^{-1} \nabla F(\vec{\Theta}_n) \|}$$

Hessian = matice 2. parciálních derivací  
= Jacobiova matice gradientu

Odpovídá lokální aproximaci  $F$  kvadratickou formou z Taylora z minimal.  
této kvadratické formy v každém kroku.

Newtonova metoda s line-search:  $\vec{\Theta}_{n+1} = \vec{\Theta}_n + \alpha_{n+1} \vec{v}_{n+1}$   
beru pomocí line-search  $\alpha_{n+1}$  beru jako řešení  
tj.  $\alpha_{n+1} = \operatorname{argmin}_{\alpha} F(\vec{\Theta}_{n+1})$

Opět není obecně zaručena konvergence (viz konvergence Newtona)  
Vyžaduje vyhodnocení/aproximaci  $[H_F] \approx \nabla^2 F \Rightarrow$  opět drahé  
Ale pokud jsme "blízko" stacionárního bodu, konvergence je kvadratická (viz Newton).  
"odpovídá  $\mathcal{O}(n^2 \times n)$  vyhod.  $F(\cdot)$ "

Adaptace "do praxe":

- derivace nahradíme "diferencema - skřtneme limity"  $\rightarrow$  aproximace  $\nabla F, [H_F]$  pomocí  $F$
- použijeme  $\nabla F(\vec{\Theta}_n)$  a/nebo  $[H_F(\vec{\Theta}_n)]$  pro několik kroků za sebou
- $\nabla F(\vec{\Theta}_{n+1})$  a/nebo  $[H_F(\vec{\Theta}_{n+1})]$  nepočítáme na novo ale jako levný update  $\nabla F(\vec{\Theta}_n)$  a/nebo  $[H_F(\vec{\Theta}_n)]$

# Metoda Levenberg - Marquardt

„Kompromis mezi metodou největšího spádu & Newtonovou metodou“

$$\vec{\Theta}_{n+1} := \vec{\Theta}_n - \alpha_{n+1} \vec{V}_{n+1}, \text{ kde } \vec{V}_{n+1} \text{ řeší } [H_F(\vec{\Theta}_n) + \beta_{n+1} I] \vec{V} = \nabla F(\vec{\Theta}_n)$$

&  $\beta_{n+1}$  je parametr „kompromisu“  $\rightarrow$

$\rightarrow \beta_{n+1} = +\infty \Rightarrow \vec{V}_{n+1}$  odpovídá <sup>metodě</sup> největšího spádu

“  $\beta_{n+1} = 0 \Rightarrow \vec{V}_{n+1}$  odpovídá Newtonovy

Parametr  $\beta$  volíme adaptivně, podle vývoje  $F \rightarrow$  pokud jsme daleko od minima, častěji používáme „levnější“ největší spád a pokud jsme blízko, chceme využít Newtonovy kvadratické konv.