

Princip gradientních optimalizačních metod

Tomáš Kroupa

20. května 2014



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Obsah

Úkol a základní princip

Obecné značení

Výpočet gradientu

Vybrané metody neomezené
optimalizace

Metoda největšího spádu

Metoda sdružených
gradientů

Newtonova metoda

Kvazi-Newtonovo metody

Porovnání metod

Úkol a základní princip

Úkol a základní princip

Obecné značení

Výpočet gradientu

Vybrané metody neomezené
optimalizace

Metoda největšího spádu

Metoda sdružených
gradientů

Newtonova metoda

Kvazi-Newtonovo metody

Porovnání metod

Úkol

Nalézt

$$\min_{\mathbf{x}} \{f(\mathbf{x})\} \quad (1)$$

kde f je funkcí mnoha proměnných (parametrů)

$$f = f(x_1, x_2, \dots, x_N), \quad (2)$$

na oblasti Ω , která je definovaná tak, že $x_1 \in \langle x_1^{lb}, x_1^{ub} \rangle$ atd.

Často se značí

$$\mathbf{x} = [x_1, x_2, \dots, x_N]^T. \quad (3)$$


Často je nutné uvažovat ještě podmínky rovnosti a nebo nerovnosti¹

$$\mathbf{0} \geq \mathbf{h}_{in}(\mathbf{x}) \quad \text{a nebo} \quad \mathbf{0} = \mathbf{h}_{eq}(\mathbf{x}). \quad (4)$$

¹Pak ovšem musí být algoritmy více propracované, princip těchto algoritmů snad bude jednou ukázán.

Úkol

Funkce f nemusí být popsána jen analyticky, ale i tak, že pomocí parametrů \mathbf{x} se postaví MKP model a výstup bude například maximální průhyb modelu, nebo první vlastní frekvence. A funkce f může být rozdíl mezi vlastními frekvencemi, na kterou chceme model „naladit“ nebo ten samotný průhyb, který chceme minimalizovat apod.



Praktické příklady

1. Identifikace materiálových parametrů

f – Rozdíl mezi MKP a exp.

\mathbf{x} – $E_1, E_2, \sigma^y, \dots$

$0 \geq h$ – Relaxační časy u viskoelastického modelu větší než 0

2. Minimalizace hmotnosti lávky

f – Hmotnost lávky

\mathbf{x} – Všechny možné rozměry, skladba vrstev laminátu,...

$0 \geq h$ – Průhyb, První vlastní frekvence > 6 Hz

3. Identifikace místa dopadu impaktoru

f – Rozdíl mezi signály z analýzy a exp.

\mathbf{x} – Pozice razníku v analýze

$0 \geq h$ – Hodnoty rázové funkce musí být vždy větší nebo rovny 0

Základní princip

Sestavení posloupnosti

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k \quad (5)$$

kde

- ▶ \mathbf{x}^k je vektor hodnot parametrů v kroku k .
- ▶ α^k je délka kroku.
- ▶ \mathbf{d}^k je směr kroku.

Rychlost konvergence a dost často i schopnost algoritmu nalézt minimum ovlivňuje volba \mathbf{x}^0 .

Další obecné informace

- ▶ Při vhodné volbě \mathbf{d}^k a vlastnostech funkce f lze dokázat, že výše zmíněná posloupnost konverguje k minimu (v okolí bodu minima).
- ▶ Volba \mathbf{d}^k se liší metodu od metody.
- ▶ Parametr α^k se určuje jako řešení 1D optimalizace

$$\min_{\alpha^k} \left\{ f \left(\mathbf{x}^{k+1} \right) \right\} = \min_{\alpha^k} \left\{ f \left(\mathbf{x}^k + \alpha^k \mathbf{d}^k \right) \right\}. \quad (6)$$

- ▶ V praxi často nelze nalézt přesné minimum, proto se výpočet ukončuje podmínkou kdy

$$|f| \leq \epsilon, \quad (7)$$

kde ϵ je velmi malé číslo např. 10^{-6} .

Značení a co je co?

Gradient

$$\mathbf{c}(\mathbf{x}) = \nabla f(\mathbf{x}) = \left[\frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \dots, \frac{\partial f}{\partial x_N} \right]^T \quad (8)$$

Hessova matice

$$\mathbf{H}(\mathbf{x}) = \nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_N} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_N \partial x_1} & \frac{\partial^2 f}{\partial x_N \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_N \partial x_N} \end{bmatrix} \quad (9)$$

Výpočet gradientu

- ▶ Analyticky – to snad nebudeme probírat, ne? ;-)
- ▶ Numericky je nutné definovat interval, na kterém bude gradient vypočten Δx_i .
 - ▶ Single sided


$$\frac{\partial f}{\partial x_1} = \frac{f(x_1 + \Delta x_1, x_2, \dots) - f(x_1, x_2, \dots)}{\Delta x_1} \quad (10)$$

- ▶ Central differences

$$\frac{\partial f}{\partial x_1} = \frac{f(x_1 + \Delta x_1, x_2, \dots) - f(x_1 - \Delta x_1, x_2, \dots)}{2\Delta x_1} \quad (11)$$

- ▶ A mnoho dalších ještě fikanějších způsobů.

Výpočet gradientu - ukázka na paraboloidu



$$f = x_1^2 + 2x_2^2$$

$$\nabla f(x_1, x_2) = [2x_1, 4x_2]^T$$

Analyticky

$$\nabla f(1.0, 1.0) = [2.0, 4.0]^T$$

Numericky -- single sided

$$\nabla f(1.0, 1.0) = [3.0, 6.0]^T, [\Delta x_1, \Delta x_2]^T = [1, 1]^T$$

$$\nabla f(1.0, 1.0) = [2.5, 5.0]^T, [\Delta x_1, \Delta x_2]^T = [0.5, 0.5]^T$$

$$\nabla f(1.0, 1.0) = [2.1, 4.2]^T, [\Delta x_1, \Delta x_2]^T = [0.1, 0.1]^T$$

$$\nabla f(1.0, 1.0) = [2.01, 4.02]^T, [\Delta x_1, \Delta x_2]^T = [0.01, 0.01]^T$$

Numericky -- central differences

$$\nabla f(1.0, 1.0) = [2.0, 4.0]^T, [\Delta x_1, \Delta x_2]^T = [1, 1]^T$$

$$\nabla f(1.0, 1.0) = [2.0, 4.0]^T, [\Delta x_1, \Delta x_2]^T = [0.01, 0.01]^T$$

Top



Front



Side



Vybrané metody neomezené optimalizace

Úkol a základní princip

Obecné značení

Výpočet gradientu

Vybrané metody neomezené optimalizace

Metoda největšího spádu

Metoda sdružených gradientů

Newtonova metoda

Kvazi-Newtonovo metody

Porovnání metod

Metoda největšího spádu

Připomeňme, že

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k.$$

Základní myšlenkou této metody je, že

$$\mathbf{d}^k = -\mathbf{c}^k = -\mathbf{c}(\mathbf{x}^k). \quad (12)$$

Metoda sdružených gradientů

Připomeňme, že

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k.$$

Základní myšlenkou této metody je, že

$$\mathbf{d}^k = -\mathbf{c}^k + \left(\frac{\|\mathbf{c}^k\|}{\|\mathbf{c}^{k-1}\|} \right)^2 \mathbf{d}^{k-1}. \quad (13)$$

Platí, že $\mathbf{d}^0 = -\mathbf{c}^0$.

Newtonova metoda

Připomeňme, že

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k.$$

Základní myšlenkou této metody je, že

$$\mathbf{d}^k = -(\mathbf{H}^k)^{-1} \mathbf{c}^k, \quad (14)$$

kde se v praxi \mathbf{d}^k získá jako řešení soustavy lineárních algebraických rovnic $-\mathbf{H}^k \mathbf{d}^k = \mathbf{c}^k$.

Newtonova metoda

- ▶ Typicky dochází k problémům pokud je v \mathbf{H}^k singulární.
- ▶ Pokud ovšem je funkce f šikvná, má tato metoda nejrychlejší konvergenci.
- ▶ Pokud je $\alpha = 1$ jedná se o klasickou Newtonovou metodu, pokud se určuje délka kroku α jde o modifikovanou Newtonovu metodu.

BFGS – Broyden-Fletcher-Goldfarb-Shanno

Připomeňme, že

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k.$$

Základní myšlenkou této metody je, že

$$\mathbf{d}^k = -(\mathbf{B}^k)^{-1} \mathbf{c}^k, \quad (15)$$

kde

$$\mathbf{s}^k = \mathbf{x}^{k+1} - \mathbf{x}^k \text{ rozdíl parametrů,} \quad (16)$$

$$\mathbf{y}^k = \mathbf{c}^{k+1} - \mathbf{c}^k \text{ rozdíl gradientu,} \quad (17)$$

$$\mathbf{B}^{k+1} = \mathbf{B}^k - \frac{\mathbf{B}^k \mathbf{s}^k \mathbf{s}^{k\top} \mathbf{B}^k}{\mathbf{s}^{k\top} \mathbf{B}^k \mathbf{s}^k} + \frac{\mathbf{y}^k \mathbf{y}^{k\top}}{\mathbf{y}^{k\top} \mathbf{s}^k}, \quad (18)$$

přičemž opět lze řešit $-\mathbf{B}^k \mathbf{d}^k = \mathbf{c}^k$.

BFGS – Broyden-Fletcher-Goldfarb-Shanno

Případně lze inverzi matice \mathbf{B}^{k+1} vypočítat i jiným způsobem a to pomocí Sherman–Morisson vztahu ²

$$(\mathbf{B}^{k+1})^{-1} = (\mathbf{B}^k)^{-1} + \frac{(\mathbf{s}^k \mathbf{T} \mathbf{y}^k + \mathbf{y}^{k \mathbf{T}} (\mathbf{B}^k)^{-1} \mathbf{y}^k) (\mathbf{s}^k \mathbf{s}^{k \mathbf{T}})}{(\mathbf{s}^k \mathbf{T} \mathbf{y}^k)^2} + \frac{(\mathbf{B}^k)^{-1} \mathbf{y}^k \mathbf{s}^{k \mathbf{T}} + \mathbf{s}^k \mathbf{y}^{k \mathbf{T}} (\mathbf{B}^k)^{-1}}{\mathbf{s}^k \mathbf{T} \mathbf{y}^k}. \quad (19)$$

Často se bere $\mathbf{B}^0 = \mathbf{I}$ nebo $\mathbf{B}^0 = \mathbf{H}(\mathbf{x}^0)$.

² k a $k + 1$ – jde jen o to z jakého kroku se na daný vztah koukáme.
Vybrané metody neomezené optimalizace

Porovnání metod

Úkol a základní princip

Obecné značení

Výpočet gradientu

Vybrané metody neomezené
optimalizace

Metoda největšího spádu

Metoda sdružených
gradientů

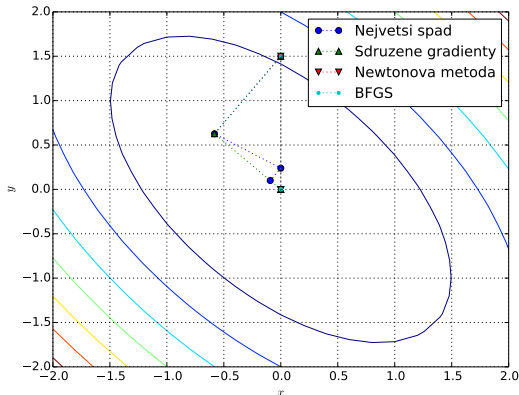
Newtonova metoda

Kvazi-Newtonovo metody

Porovnání metod

Porovnání

$$f = x^2 + xy + \frac{3}{4}y^2$$



▶ Metoda největšího spádu

#	x	y	f
0	0.00	1.50	1.688
1	-0.58	0.63	0.269
2	-0.00	0.24	0.042
3	-0.09	0.10	0.006

▶ Metoda sdružených gradientů

#	x	y	f
0	0.00	1.50	1.688
1	-0.58	0.63	0.269
2	-0.00	0.00	0.000

▶ Newtonova metoda

#	x	y	f
0	0.00	1.50	1.688
1	-0.00	0.00	0.000

▶ BFGS

#	x	y	f
0	0.00	1.50	1.688
1	-0.00	0.00	0.000

Tato prezentace je spolufinancována Evropským sociálním fondem a státním rozpočtem České republiky v rámci projektu
č. CZ.1.07/2.2.00/28.0206
„Inovace výuky podpořená praxí“.



evropský
sociální
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenceschopnost

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tento studijní materiál je spolufinancován Evropským sociálním fondem a státním rozpočtem České republiky.