

Optimalizace bez omezení

(unconstraint)

Nederivační (ad hoc) metody

Jednoduché metody

Nelder-Meadova (simplexová) metoda

Derivační metody

První derivace

Metoda největšího spádu + další spádové metody

Metoda konjugovaných gradientů

Druhá derivace

Newton-Raphsonova metoda

Quasi-Newtonova metoda

Metoda největšího spádu

-obecně II

Algoritmus:

- zvolíme výchozí bod $x^{(0)}$
- k -tá iterace:

bod $x^{(k+1)}$ vypočítáme z bodu $x^{(k)}$ pomocí vztahu:

$$x^{(k+1)} = x^{(k)} - \alpha \cdot g^{(k)}, \text{ kde:}$$

$-g^{(k)}$ zjednodušený zápis $-\nabla f(x^{(k)})$,
určuje **směr přesunu** z bodu $x^{(k)}$

α koeficient, popisující **délku daného přesunu**

Metoda největšího spádu

- volba α v metodě největšího spádu

Z bodu $x^{(k)}$ se přesunujeme po polopřímce:

$$x(\alpha) = x^{(k)} + \alpha \cdot x^{(k)}, \text{ kde } \alpha > 0$$

Hodnotu funkce f na této polopřímce popisuje funkce

$$\phi(\alpha): \quad \phi(\alpha) = f(x(\alpha))$$

Je zřejmé, že musíme zvolit takové α^{OK} , aby platilo:

$$f(x^{(k)}) > f(x^{(k+1)}), \quad \text{kde } x^{(k+1)} = x(\alpha^{OK}) \text{ pro dostatečný počet iterací.}$$


Poznámka: „Dostatečný počet“ = dostačuje k tomu,

aby metoda konvergovala k minimu ($\lim_{k \rightarrow \infty} f(x^{(k)}) = 0$)

Metoda největšího spádu

- volba a v metodě největšího spádu

Funkce $\phi(\alpha)$ má následující tvar:



Metoda největšího spádu

- volba α v metodě největšího spádu

Metoda největšího spádu volí pro každý krok stejnou hodnotu α .

Konkrétně velmi malou hodnotu α .

Poznámka: Hodnoty α musí být dostatečně, aby metoda konvergovala.

Metoda největšího spádu

zhodnocení

Výhody:

- Implementačně jednoduché
- Nízká prostorová složitost

Nevýhody:

- Velmi pomalá konvergence (speciálně v oblastech malého spádu => nízkých hodnot gradientu).
- Chyby, způsobené zaokrouhlením. Mohou vést i k tomu, že se výpočet vůbec nedostane rozumně blízko k minimu. Ale při (ideální) přesné aritmetice metoda konverguje vždy k nějakému lokálnímu minimu.

Metoda největšího spádu

- příklad

Rosenbrockova funkce:

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$

Gradient Rosenbrockovy funkce:

$$\nabla f(x_1, x_2) = (-400x_1(x_2 - x_1^2) + 2(1 - x_1), 200(x_2 - x_1^2))$$

Výchozí bod:

$$x_0 = (-2, 2)$$

Parametry:

$$\alpha = 0,001$$


Výpočet první iterace - dobrovolník u tabule :-).

Další iterace - příklad v Excelu.

Metoda největšího spádu

- příklad II

Ukázka konvergence metody největšího spádu pro Rosenbrockovu funkci:



Spádové metody

- obecně

Jsou založeny na stejném principu jako metoda největšího spádu:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha \cdot \mathbf{s}^{(k)}, \text{ kde:}$$

$\mathbf{s}^{(k)}$ je **směr přesunu** z bodu $\mathbf{x}^{(k)}$,
nejčastěji jako směr volíme $-\mathbf{g}^{(k)}$

α koeficient, popisující **délku daného přesunu**

Využívají sofistikovanější metody k určení koeficientu α .
Hodnota koeficientu α je různá pro každou iteraci.


Spádové metody

- obecně II

Podmínka pro ideální hodnotu (α^*) koeficientu α :

funkce $\phi(\alpha) = f(x(\alpha))$ má v α^* minimum [1]

Poznámka: Jedná se o nejmenší hodnotu α , v níž má $\phi(\alpha)$ minimum. Navíc samozřejmě platí $\alpha > 0$.



Tuto podmínku nelze využít
k volbě koeficientu α .

Potřebujeme totiž určit
hodnotu α pro danou
iteraci v konečném a
pokud možno velmi
malém počtu kroků.


Spádové metody

- obecně III

Předpokládejme, že funkce f má průběh naznačený na obrázku.

Pak existuje $\alpha > 0$ tak, že:
$$f(\mathbf{x}^{(k)} + \alpha \mathbf{s}^{(k)}) = f(\mathbf{x}^{(k+1)})$$

Nejmenší takové α
označujeme α' .



\Rightarrow Nutné podmínky pro koeficient α :

$$0 < \alpha < \alpha'$$

[2]

Spádové metody

- obecně IV

=> Při volbě koeficientu α musíme dodržet podmínky [2]
a co nejvíce se přiblížit podmínce [1].

Metody pro nalezení α :

- Goldsteinovy podmínky
- Wolfe-Powellovy podmínky

Značení:

$$f(x^{(k+1)}) = f(x^{(k)} + \alpha \cdot s^{(k)}) \quad \text{budeme značit } \phi(\alpha)$$

$$f(x^{(k)}) \quad \text{budeme značit } \phi(0)$$

Spádové metody

- Goldsteinovy podmínky I

1. Goldsteinova podmínka zaručuje, že α nebude zvoleno příliš blízko α' :

$$\phi(\alpha) \leq \phi(0) + \rho \cdot \alpha \cdot \phi'(0)$$

Parametr ρ je zde pevně zvolené číslo z intervalu $(0, \frac{1}{2})$.

I když α' neexistuje {tj. $\phi(\alpha) < \phi(0)$ pro všechna $\alpha > 0$ }, je 1GP schopna omezit volbu $\alpha^{(k)}$. (Pokud je tedy funkce f zdola omezená.)

Spádové metody

- Goldsteinovy podmínky II


2. Goldsteinova podmínka zaručuje, že α nebude zvoleno příliš blízko 0:

$$\phi(\alpha) \geq \phi(0) + (1 - \rho) \cdot \alpha \cdot \phi'(0)$$

Pravé strany Goldsteinových podmínek určují dvě přímky se zápornou směrnici. Hodnoty α_1 a α_2 , které přísluší průsečíkům těchto přímek s $\phi(\alpha)$, určují interval vhodných hodnot α .

Spádové metody


- Goldsteinovy podmínky III



Spádové metody

- Goldsteinovy podmínky IV

Zdůvodnění Goldsteinových podmínek:



Spádové metody

- Goldsteinovy podmínky V

Věta: Necht' funkce f je spojitě diferenciovatelná a necht' její gradient $\mathbf{g} = \nabla f$ je lipschitzovsky spojitý na \mathbb{R}^n .

Je-li $\{\mathbf{x}^{(k)}\}$ posloupnost generována spádovou metodou a volba α vyhovuje Goldsteinovým podmínkám, pak platí:

$$f(\mathbf{x}^{(k)}) - f(\mathbf{x}^{(k-1)}) \geq -\rho \cdot \mathbf{g}^{(k)} \cdot \delta^{(k)}$$

$$\text{kde } \delta^{(k)} = \alpha^{(k)} \mathbf{s}^{(k)} = \mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}$$

\Rightarrow Metoda vždy konverguje k minimu funkce f (pro vhodné ρ).


Poznámka: Volba koeficientu $\rho < 1/2$ zaručuje konvergenci metody pro kvadratické funkce.

Spádové metody

- Goldsteinovy podmínky VI

Nevýhoda Goldsteinových podmínek:

V intervalu mezi α_1 a α_2 se nemusí nacházet minimum funkce $\phi(\alpha)$.



Spádové metody

- Wolfe-Powellovy podmínky

Místo GP2 se testuje sklon funkce $\phi(\alpha)$ v bodě α .

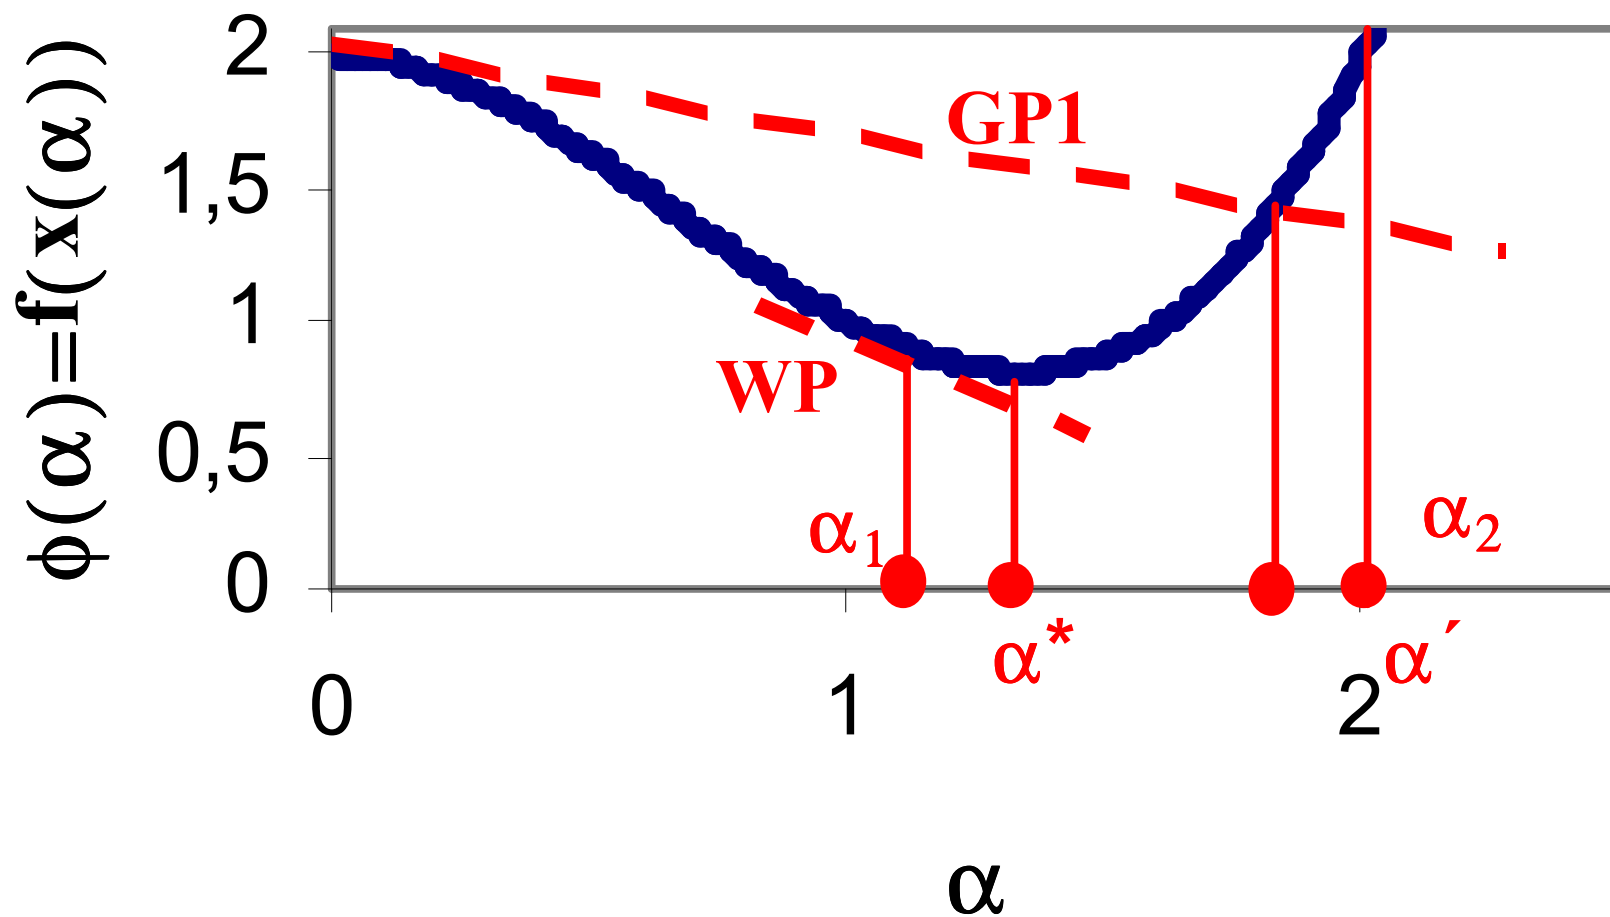
Využívá se tedy následující podmínka:

$$|\phi'(\alpha)| \leq \sigma |\phi'(0)|$$

kde $\sigma \in (\rho, 1)$.

Spádové metody

- Wolfe-Powellovy podmínky II



Metody konjugovaných gradientů

- obecně

- = metody sdružených gradientů
- = conjugate gradient method
- = speciální případ metod sdružených směrů

Základní myšlenka: Pro určení směru přesunu z bodu $x^{(k)}$ do bodu $x^{(k+1)}$ se využívají nejen hodnotu $g^{(k+1)}$, ale rovněž hodnotu $g^{(k)}$. (V obecném případě je možno využít hodnot $g^{(1)}, g^{(2)}, \dots, g^{(k)}, g^{(k+1)}$.)

Zdůvodnění: Spojení informací o současném a předchozím sklonu studované funkce umožňuje rychlejší sestup do minima (zlepšení konvergence na plochých oblastech).

Metody konjugovaných gradientů

- algoritmus

Výpočet $\mathbf{x}^{(k+1)}$:

$\mathbf{x}^{(k+1)}$ se určuje pomocí stejného vztahu jako u spádových metod:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha^{(k)} \cdot \mathbf{s}^{(k)} \quad [2.1]$$

kde:

$\mathbf{s}^{(k)}$ **směr přesunu z bodu $\mathbf{x}^{(k)}$**

$\alpha^{(k)}$ **koeficient, popisující délku daného přesunu**

Metody konjugovaných gradientů

- algoritmus II

Výpočet $\alpha^{(k)}$:

Analogické jako u spádových metod:

1) Je nutno zvolit koeficient $\alpha^{(k)}$ tak, aby platilo:

$$0 < \alpha^{(k)} < \alpha^{(k)'}$$

$$\text{kde: } f(\mathbf{x}^{(k)} + \alpha^{(k)'} \cdot \mathbf{s}^{(k)}) = f(\mathbf{x}^{(k+1)})$$

2) $\alpha^{(k)}$ by se měla co nejvíce blížit $\alpha^{(k)*}$,

kde $\alpha^{(k)*}$ je minimum funkce $f(\mathbf{x}^{(k)} + \alpha^{(k)} \cdot \mathbf{s}^{(k)})$.

Metody konjugovaných gradientů

- algoritmus III

Výpočet $\mathbf{s}^{(k+1)}$:

$\mathbf{s}^{(k+1)}$ se vypočte pomocí gradientu $\mathbf{g}^{(k+1)}$ a směru $\mathbf{s}^{(k)}$.
(Přičemž $\mathbf{s}^{(k)}$ byl vypočítán pomocí předchozích hodnot gradientů ...). Konkrétně:

$$\mathbf{s}^{(k+1)} = -\mathbf{g}^{(k+1)} + \beta^{(k)} \cdot \mathbf{s}^{(k)} \quad [2.2]$$

Kde $\beta^{(k)}$ je koeficient, který určuje míru vlivu směru přesunu v kroku k ($\mathbf{s}^{(k)}$) na směr přesunu v následujícím kroku ($\mathbf{s}^{(k+1)}$).

Výpočet $\mathbf{s}^{(0)}$:

$$\mathbf{s}^{(0)} = -\mathbf{g}^{(0)}$$

Metody konjugovaných gradientů

- algoritmus III

Výpočet $\beta^{(k+1)}$:

Existuje více možností, jak volit číslo $\beta^{(k+1)}$.

Nyní odvodíme hodnotu $\beta^{(k+1)}$ za předpokladu, že minimalizovaná funkce je kvadratická a má pozitivně definitní Hessovou matici \mathbf{G} . V tomto případě platí:

$$\mathbf{y}^{(k)} = \mathbf{G} \cdot \boldsymbol{\delta}^{(k)} \quad [2.3]$$

kde $\mathbf{y}^{(k)} = \mathbf{g}^{(k+1)} - \mathbf{g}^{(k)}$ a $\boldsymbol{\delta}^{(k)} = \mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}$.

Protože vektory $\mathbf{s}^{(k+1)}$ a $\mathbf{s}^{(k)}$ mají být sdružené vzhledem ke \mathbf{G} , musí platit:

$$\mathbf{s}^{(k+1)T} \cdot \mathbf{G} \cdot \boldsymbol{\delta}^{(k)} = 0 \quad [2.4]$$

Z [2.3] a [2.4] vyplývá:

$$0 = \mathbf{s}^{(k+1)T} \cdot \mathbf{G} \cdot \boldsymbol{\delta}^{(k)} = \mathbf{s}^{(k+1)T} \cdot \mathbf{y}^{(k)}$$

Metody konjugovaných gradientů

- algoritmus IV

$$\mathbf{s}^{(k+1)} = -\mathbf{g}^{(k+1)} + \beta^{(k)} \cdot \mathbf{s}^{(k)} \quad [2.2]$$

Po transponování rovnice [2.2] a násobení vektorem $\mathbf{y}^{(k)}$ zprava dostáváme:

$$0 = -\mathbf{g}^{(k+1)T} \cdot \mathbf{y}^{(k)} + \beta^{(k)} \cdot \mathbf{s}^{(k)T} \cdot \mathbf{y}^{(k)} \quad [2.5]$$

Odtud plyne hodnota, kterou navrhli Hestenes a Stiefel v roce 1952:

$$\beta_{HS}^{(k)} = \frac{\mathbf{g}^{(k+1)T} (\mathbf{g}^{(k+1)} - \mathbf{g}^{(k)})}{\mathbf{s}^{(k)T} (\mathbf{g}^{(k+1)} - \mathbf{g}^{(k)})} \quad [2.6]$$

Metody konjugovaných gradientů

- algoritmus V

Pokud je $\mathbf{x}^{(k)}$ v rovnici [2.1] přesně určeným minimem ve směru $\mathbf{s}^{(k)}$, musí platit $\mathbf{s}^{(k)T} \cdot \mathbf{g}^{(k+1)} = 0$ (jinak by se hodnota f ve směru $\mathbf{s}^{(k)}$ dala ještě snížit), obdobně $\mathbf{s}^{(k-1)T} \cdot \mathbf{g}^{(k)} = 0$. Pak je jmenovatel ve vztahu [2.6] roven:

$$\begin{aligned} \mathbf{s}^{(k)T} \left(\mathbf{g}^{(k+1)} - \mathbf{g}^{(k)} \right) &= -\mathbf{s}^{(k)T} \cdot \mathbf{g}^{(k)} = \left[\mathbf{g}^{(k)} - \beta^{(k-1)} \cdot \mathbf{s}^{(k-1)} \right]^T \cdot \mathbf{g}^{(k)} = \\ &= \mathbf{g}^{(k)} \cdot \mathbf{g}^{(k)} = \left\| \mathbf{g}^{(k)} \right\|_2^2 \end{aligned} \quad [2.7]$$

Metody konjugovaných gradientů

- algoritmus VI

Po dosazení [2.7] do [2.6] získáme vyjádření $\beta^{(k)}$, které poprvé publikovali Polak a Ribiere v roce 1969:

$$\beta_{PR}^{(k)} = \frac{\mathbf{g}^{(k+1)T} (\mathbf{g}^{(k+1)} - \mathbf{g}^{(k)})}{\|\mathbf{g}^{(k)}\|_2^2} \quad [2.8]$$

Obdobně lze ukázat, že $\mathbf{g}^{(k+1)T} \cdot \mathbf{g}^{(k)} = 0$, odtud plyne vztah pro $\beta^{(k)}$ podle Fletchera a Reevese (1963):

$$\beta_{FR}^{(k)} = \frac{\|\mathbf{g}^{(k+1)}\|_2^2}{\|\mathbf{g}^{(k)}\|_2^2}$$

Metody konjugovaných gradientů

- algoritmus VII

Pro kvadratické funkce je $\beta_{HS}^{(k)} = \beta_{PR}^{(k)} = \beta_{FR}^{(k)}$.

To ale neplatí pro obecnější funkce. Při testovacích úlohách dává obvykle nejlepší výsledky varianta Polaka a Ribiera.

Metody konjugovaných gradientů

- zhodnocení

Výhody:

Spolehlivější než spádové metody.

Vhodná i v oblastech poblíž minima

Nevýhody:

Výpočetně náročnější.

Větší prostorová složitost (nutnost ukládat několik n -prvkových vektorů).

Metody konjugovaných gradientů

- porovnání


Vhodná i v oblastech poblíž Porovnání metody největšího spádu a metody konjugovaných gradientů (Rosenbrockova funkce):

	Daleko od minima (gradient $< 1 \text{ kcal.A}^{-2}$)		Poblíž minima (gradient $< 0,1 \text{ kcal.A}^{-2}$)	
	CPU	Počet iter.	CPU	Počet iter.
Nejv. spád	67	98	1405	1893
Konj. grad.	149	213	257	367

Metody konjugovaných gradientů

- porovnání II


Ukázka konvergence spádové metody pro Rosenbrockovu funkci:



Metody konjugovaných gradientů

- porovnání III

Ukázka konvergence metody konjugovaných gradientů pro Rosenbrockovu funkci:



Cvičení

Proved'te první 2 kroky optimalizace funkce:

$$f(x_1, x_2) = x_1^2 + 2x_2^2$$

- a) pomocí metody největšího spádu
- b) pomocí metody konjugovaných gradientů

Poznámka: Využijte $\alpha = 0,25$. Počáteční bod je $(2,1)$

Funkce: $f(x_1, x_2) = x_1^2 + 2x_2^2$

Výchozí bod: $x^0 = (2, 1)$

Parametry: $\alpha = 0.25$

Gradient funkce: $\nabla f(x_1, x_2) = (2x_1, 4x_2)$

Směr funkce: $s^k = -g^k$

Následující bod: $x^{k+1} = x^k + \alpha \cdot s^k$

Gradient v bodě x^0 : $g^0 = (4, 4)$

Směr v bodě x^0 : $s^0 = (-4, -4)$

Bod x^1 : $x^1 = (2, 1) + 0,25 \cdot (-4, -4) = (1, 0)$

Gradient v bodě x^1 : $g^1 = (2, 0)$

Směr v bodě x^0 : $s^0 = (-2, 0)$

Bod x^1 : $x^1 = (1, 0) + 0,25 \cdot (-2, 0) = (0,5, 0)$

Funkce: $f(x_1, x_2) = x_1^2 + 2x_2^2$

Výchozí bod: $x^0 = (2, 1)$

Parametry: $\alpha = 0.25$

Gradient funkce: $\nabla f(x_1, x_2) = (2x_1, 4x_2)$

Beta: $\beta_{FR}^{(k)} = \frac{\|g^{(k+1)}\|_2^2}{\|g^{(k)}\|_2^2}$

Směr funkce: $s^k = -g^k + \beta^k \cdot s^k$

Následující bod: $x^{k+1} = x^k + \alpha \cdot s^k$

Gradient v bodě x^0 : $g^0 = (4, 4)$

Směr v bodě x^0 : $s^0 = (-4, -4)$

Bod x^1 : $x^1 = (2, 1) + 0,25 \cdot (-4, -4) = (1, 0)$

Gradient v bodě x^1 : $g^1 = (2, 0)$

Beta v bodě x^1 : $b^1 = (2,2)/(4,4+4,4) = 4/32 = 0,125$

Směr v bodě x^1 : $s^1 = -(2,0)+0,125 \cdot (-4,-4) = (-2,5, -0,5)$

Bod x^1 : $x^1 = (1,0) + 0,25 \cdot (-2,5,-0,5) = (0,375,-0,125)$

Příloha

Příklad je řešen v přiloženém excelovém souboru
„3uncon_metody_prvni_derivace.xlsx“