

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

Spádové metody

-obecně

Algoritmus:

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

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

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

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

α koeficient, popisující **délku daného přesunu**

Metoda největšího spádu

-obecně

$$s^{(k)} = -g^{(k)}$$

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:


$f(x^{(k)}) > f(x^{(k+1)})$, kde $x^{(k+1)} = x(\alpha^{OK})$ 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 malá, 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.

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

Výchozí bod: $x^0 = (2, 1)$

Parametry: $\alpha = 0.25$

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

Výchozí bod: $x^0 = (2, 1)$

Parametry: $\alpha = 0.25$

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

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 : $g^0 =$

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 : $s^0 =$

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 : $x^1 =$

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 : $g^1 =$

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^1 : $s^1 =$

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^1 : $s^1 = (-2, 0)$

Bod x^2 : $x^2 =$

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^1 : $s^1 = (-2, 0)$

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

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:

$$\nabla f(\mathbf{x}) = \left(-400x_1(x_2 - x_1^2) - 2(1 - x_1), \quad 200(x_2 - x_1^2) \right)^T$$

Výchozí bod:

$$\mathbf{x}_0 = (-2, 2)$$

Parametry:

$$\alpha = 0,001$$

Vyzkoušejte doma :-)