

SME0212/SME5720 – Otimização Não-Linear

Direções de descida e busca de Armijo

Elias S. Helou Neto

Diferenciabilidade

Dizemos que uma função $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é diferenciável em um ponto $\mathbf{x} \in \mathbb{R}^n$ quando

$$f(\mathbf{x} + \mathbf{h}) = f(\mathbf{x}) + \nabla f(\mathbf{x})^T \mathbf{h} + \|\mathbf{h}\| E(\mathbf{x}, \mathbf{h})$$

onde

$$\lim_{\mathbf{h} \rightarrow \mathbf{0}} E(\mathbf{x}, \mathbf{h}) = 0.$$

Direção de descida

Dizemos que $\mathbf{d} \in \mathbb{R}^n$ é uma direção de descida para $f : \mathbb{R}^n \rightarrow \mathbb{R}$ a partir de $\mathbf{x} \in \mathbb{R}^n$ quando existe $\Lambda > 0$ tal que para todo $\lambda \in (0, \Lambda)$ temos que

$$f(\mathbf{x} + \lambda \mathbf{d}) < f(\mathbf{x}).$$

Direção de máxima descida

Se $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é diferenciável em $x \in \mathbb{R}^n$ e $\nabla f(x) \neq \mathbf{0}$ então
 $-\nabla f(x)$ é uma direção de descida para f a partir de x .

Direção de máxima descida

Se $f : \mathbb{R}^n \rightarrow \mathbb{R}$ é diferenciável em $\mathbf{x} \in \mathbb{R}^n$ e $\nabla f(\mathbf{x}) \neq \mathbf{0}$ então, para qualquer $\sigma \in (0, 1)$, existe $\Lambda_\sigma > 0$ tal que para $\lambda \in (0, \Lambda_\sigma)$ temos:

$$f(\mathbf{x} - \lambda \nabla f(\mathbf{x})) < f(\mathbf{x}) - \lambda \sigma \|\nabla f(\mathbf{x})\|^2$$

Algoritmo de máxima descida

Passo fixo

Data: $x_0 \in \mathbb{R}^n$, $\lambda > 0$, $\epsilon > 0$

Result: $x \in \mathbb{R}^n$ tal que $\|\nabla f(x)\| \leq \epsilon$

$k \leftarrow 0$;

while $\|\nabla f(x_k)\| > \epsilon$ **do**

$x_{k+1} \leftarrow x_k - \lambda \nabla f(x_k)$;

$k \leftarrow k + 1$;

end

$x \leftarrow x_k$;

Algoritmo 1: Máxima descida com passo fixo

Algoritmo de máxima descida

Busca linear de Armijo

O mesmo passo fixo ao longo de todas as iterações atrasa o algoritmo.

Algoritmo de máxima descida

Busca linear de Armijo

O mesmo passo fixo ao longo de todas as iterações atrasa o algoritmo.

Dado $\sigma \in (0, 1)$, sabemos que, em uma iteração k , existe $\Lambda_k > 0$ tal que para $\lambda_k \in (0, \Lambda_k)$ temos

$$f(\mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)) < f(\mathbf{x}_k) - \lambda_k \sigma \|\nabla f(\mathbf{x}_k)\|^2.$$

Algoritmo de máxima descida

Busca linear de Armijo

O mesmo passo fixo ao longo de todas as iterações atrasa o algoritmo.

Dado $\sigma \in (0, 1)$, sabemos que, em uma iteração k , existe $\Lambda_k > 0$ tal que para $\lambda_k \in (0, \Lambda_k)$ temos

$$f(\mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)) < f(\mathbf{x}_k) - \lambda_k \sigma \|\nabla f(\mathbf{x}_k)\|^2.$$

A ideia de Armijo é escolher o maior valor da forma

$$\{\lambda, \lambda\beta, \lambda\beta^2, \lambda\beta^3, \dots\}$$

que satisfaça tal condição de descida. Aqui, $\beta \in (0, 1)$.

Algoritmo de máxima descida

Busca linear de Armijo

Data: $\mathbf{x}_0 \in \mathbb{R}^n$, $\lambda > 0$, $\beta \in (0, 1)$, $\sigma \in (0, 1)$, $\epsilon > 0$

Result: $\mathbf{x} \in \mathbb{R}^n$ tal que $\|\nabla f(\mathbf{x})\| \leq \epsilon$

$k \leftarrow 0$;

while $\|\nabla f(\mathbf{x}_k)\| > \epsilon$ **do**

$\lambda_k \leftarrow \lambda$;

while $f(\mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)) \geq f(\mathbf{x}_k) - \lambda_k \sigma \|\nabla f(\mathbf{x}_k)\|^2$ **do**

$\lambda_k \leftarrow \lambda_k \beta$;

end

$\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k - \lambda_k \nabla f(\mathbf{x}_k)$;

$k \leftarrow k + 1$;

end

$\mathbf{x} \leftarrow \mathbf{x}_k$;

Algoritmo 2: Máxima descida com busca de Armijo

Algoritmo de descida

Busca linear de Armijo

Data: $x_0 \in \mathbb{R}^n$, $\lambda > 0$, $\beta \in (0, 1)$, $\sigma \in (0, 1)$, $\epsilon > 0$, $\gamma \in (0, 1)$, $\kappa \in (0, 1)$

Result: $x \in \mathbb{R}^n$ tal que $\|\nabla f(x)\| \leq \epsilon$

$k \leftarrow 0$;

while $\|\nabla f(x_k)\| > \epsilon$ **do**

$\lambda_k \leftarrow \lambda$;

Seja d_k tal que

$$d_k^T \nabla f(x_k) < -\gamma \|d_k\| \|\nabla f(x_k)\|$$

e

$$\|d_k\| > \kappa \|\nabla f(x_k)\|$$

while $f(x_k + \lambda_k d_k) \geq f(x_k) + \lambda_k \sigma d_k^T \nabla f(x_k)$ **do**

$\lambda_k \leftarrow \lambda_k \beta$;

end

$x_{k+1} \leftarrow x_k + \lambda_k d_k$;

$k \leftarrow k + 1$;

end

$x \leftarrow x_k$;

Algoritmo 3: Descida com busca de Armijo