

# IF824 - Otimização

## Otimização não-linear irrestrita: Algoritmos

Gurvan Huiban

### 1 Otimização unidimensional: Busca de intervalo

Dada uma função  $f : \mathbb{R}^+ \rightarrow \mathbb{R}$  contínua e decrescente em  $x = 0$ , o algoritmo 1 busca um intervalo  $[c_1, c_2]$  contendo um mínimo local de  $f$ .

**Data:** Função  $f$ , passo inicial  $\delta$

**Result:** Intervalo  $[c_1, c_2]$

$c_1 \leftarrow 0$ ;

**if**  $f(c_1 + \delta) \leq f(c_1)$  **then**

$x_m \leftarrow c_1 + \delta$ ;

$\delta \leftarrow 2\delta$ ;

**while**  $f(x_m) > f(x_m + \delta)$  **do**

$c_1 \leftarrow x_m$ ;

$x_m \leftarrow x_m + \delta$ ;

$\delta \leftarrow 2\delta$

**end**

$c_2 \leftarrow x_m + \delta$ ;

**else**

$c_2 \leftarrow c_1 + \delta$ ;

$\delta \leftarrow \frac{\delta}{2}$ ;

**while**  $f(c_1 + \delta) > f(c_1)$  **do**

$c_2 \leftarrow c_1 + \delta$ ;

$\delta \leftarrow \frac{\delta}{2}$ ;

**end**

$x_m \leftarrow c_1 + \delta$ ;

**end**

**Algorithm 1:** Busca de intervalo incluindo um mínimo local

### 2 Otimização unidimensional: Seção áurea

Dada uma função  $f : \mathbb{R}^+ \rightarrow \mathbb{R}$  contínua e dado um intervalo  $[c_1, c_2]$  contendo um mínimo local de  $f$ , o algoritmo da seção áurea (algoritmo 2) calcula um mínimo local de  $f$  sobre  $[c_1, c_2]$  com precisão  $\epsilon$ .

**Data:** Função  $f$ , intervalo  $[c_1, c_2]$ , precisão  $\epsilon$

**Result:** Mínimo local de  $f$  sobre  $[c_1, c_2]$

$x_1 \leftarrow c_2 - \alpha (c_2 - c_1);$

$x_2 \leftarrow c_1 + \alpha (c_2 - c_1);$

**while**  $\frac{(c_2 - c_1)}{2} > \epsilon$  **do**

**if**  $f(x_1) \leq f(x_2)$  **then**

$c_2 \leftarrow x_2;$

$x_2 \leftarrow x_1;$

$x_1 \leftarrow c_2 - \alpha (c_2 - c_1);$

**else**

$c_1 \leftarrow x_1;$

$x_1 \leftarrow x_2;$

$x_1 \leftarrow c_1 + \alpha (c_2 - c_1);$

**end**

**end**

**Algorithm 2:** Otimização unidimensional com seção áurea

### 3 Otimização multidimensional: Algoritmos de descida

Seja uma função  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  diferenciável e seja o problema de otimização irrestrita seguinte:

$$\min_{X \in \mathbb{R}^n} f(X)$$

Dado um ponto  $X_0 \in \mathbb{R}^n$ , um algoritmo de descida vai convergir para um mínimo local da bacia de atração contendo  $X_0$ , caso houver. A forma padrão de um algoritmo de descida é dada pelo algoritmo 3.

**Data:** Função  $f$ , ponto inicial  $X_0$

**Result:** Aproximação numérica de um mínimo local de  $f$

$k \leftarrow 0;$

**repeat**

    Calcular  $d_k;$

    Resolver o problema de otimização unidimensional:  $\alpha_k = \arg \min_{\alpha \geq 0} f(X_k + \alpha d_k);$

$X_{k+1} \leftarrow X_k + \alpha_k d_k;$

$k \leftarrow k + 1;$

**until** *Condição de parada;*

**Algorithm 3:** Algoritmo de descida padrão

#### 3.1 Algoritmo do gradiente

No caso do algoritmo do gradiente, temos:

- $d_k \leftarrow -\nabla f(X_k)$

$\nabla f(X_k)$  representa o vetor gradiente de  $f$  em  $X_k$ .

#### 3.2 Algoritmo de Newton

O algoritmo de Newton padrão é definido pelo algoritmo 4. O algoritmo de Newton só pode ser usado com funções duas vezes diferenciáveis.  $\nabla^2 f(X_k)$  representa a matriz hessiana de  $f$  em  $X_k$ .

O algoritmo de Newton pode ser modificado de forma a seguir o padrão dos algoritmos de descida. Neste caso temos:

- $d_k \leftarrow -[\nabla^2 f(X_k)]^{-1} \nabla f(X_k)$

**Data:** Função  $f$ , ponto inicial  $X_0$

**Result:** Aproximação numérica de um mínimo local de  $f$

$k \leftarrow 0$ ;

**repeat**

$X_{k+1} \leftarrow X_k - [\nabla^2 f(X_k)]^{-1} \nabla f(X_k)$ ;  
     $k \leftarrow k + 1$ ;

**until** Condição de parada;

**Algorithm 4:** Algoritmo de Newton

### 3.3 Algoritmos quasi-Newton

Os algoritmos quasi-Newton aproximam a hessiana de  $f$  em  $X_k$  por uma sequência de matrizes. Neste caso temos:

•  $d_k \leftarrow -H_k \nabla f(X_k)$  onde:

–  $H_0 \leftarrow I$

–  $H_{k+1} = H_k + C_k$

–  $C_k$  é calculado a partir das fórmulas:

$$\text{BFGS: } C_k = \left( 1 + \frac{r_k^T H_k r_k}{v_k^T r_k} \right) \frac{v_k v_k^T}{v_k^T r_k} - \frac{v_k r_k^T H_k + H_k r_k v_k^T}{v_k^T r_k} \quad (1)$$

$$\text{DFP: } C_k = \frac{v_k v_k^T}{v_k^T r_k} - \frac{H_k r_k r_k^T H_k}{r_k^T H_k r_k} \quad (2)$$

onde  $v_k = X_k - X_{k-1}$  e  $r_k = \nabla f(X_k) - \nabla f(X_{k-1})$

### 3.4 Algoritmos do gradiente conjugado

O algoritmo do gradiente conjugado padrão é definido para as funções quadráticas. Uma forma de aplicá-lo para funções não quadráticas é fazendo uma aproximação quadrática da função. Neste caso, a função deve ser duas vezes diferenciável. O algoritmo 5 mostra o que seria o algoritmo resultante.

**Data:** Função  $f$ , ponto inicial  $X_0$

**Result:** Aproximação numérica de um mínimo local de  $f$

$d_0 \leftarrow -\nabla f(X_0)$ ;

$k \leftarrow 0$ ;

**repeat**

$X_{k+1} \leftarrow X_k + \alpha_k d_k$  com  $\alpha_k = -\frac{[\nabla f(X_k)]^T d_k}{d_k^T \nabla^2 f(X_k) d_k}$ ;

$k \leftarrow k + 1$ ;

**if**  $k \equiv 0 \pmod{n}$  **then**

$d_k = -\nabla f(X_k) + \beta_{k-1} d_{k-1}$  com  $\beta_{k-1} = \frac{[\nabla f(X_k)]^T \nabla^2 f(X_{k-1}) d_{k-1}}{d_{k-1}^T \nabla^2 f(X_{k-1}) d_{k-1}}$ ;

**else**

$d_k = -\nabla f(X_k)$ ;

**end**

**until** Condição de parada;

**Algorithm 5:** Algoritmo do gradiente conjugado

O algoritmo do gradiente conjugado pode ser modificado de forma a seguir o padrão dos algoritmos de descida, trocando o uso da hessiana com o uso de uma matriz aproximada da hessiana. Neste caso temos:

- Se  $k \equiv 0 \pmod n$ ,  $d_k = -\nabla f(X_k)$
- Senão  $d_k = -\nabla f(X_k) + \beta_{k-1}d_{k-1}$
- $\beta_k$  é calculado a partir das fórmulas:

$$\text{Fletcher-Reeves} \quad \beta_k = \frac{[\nabla f(X_{k+1})]^T \nabla f(X_{k+1})}{[\nabla f(X_k)]^T \nabla f(X_k)} \quad (3)$$

$$\text{Polak-Ribière} \quad \beta_k = \frac{[\nabla f(X_{k+1}) - \nabla f(X_k)]^T \nabla f(X_{k+1})}{[\nabla f(X_k)]^T \nabla f(X_k)} \quad (4)$$