

# Optimización continua no restringida

2 de septiembre de 2003

## 1. Optimización en una variable

- Problema general:

minimizar  $\varphi(x)$ ,  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$

- Caso especial muy útil:

minimizar  $\varphi(x) = f(x + \lambda d)$

con:  $f : \mathbb{R} \rightarrow \mathbb{R}$ ,  $x, d \in \mathbb{R}$  fijos,  $\lambda \in \Lambda$

- Posibles dominios:

- $\Lambda = \mathbb{R}$
- $\Lambda = [0, \infty]$
- $\Lambda = [0, \lambda_{max}]$

### 1.1. Criterios de terminación

- Generalmente, se construye una sucesión  $\{\lambda_k\}$  tal que

$$\lim_{k \rightarrow \infty} \lambda_k = \lambda^*,$$

donde  $\lambda^*$  es un minimizador global o local.

- $\{\lambda_k\}$  es infinita, de manera que el proceso debe detenerse para un valor de  $k$  finito. Algunos criterios de terminación son:

- $|\lambda_{k+1} - \lambda_k| \leq \epsilon_\lambda$
- $\left| \frac{\lambda_{k+1} - \lambda_k}{\lambda_k} \right| \leq \epsilon'_\lambda$ , u opcionalmente  $\left| \frac{\lambda_{k+1} - \lambda_k}{\lambda_{k+1}} \right| \leq \epsilon'_\lambda$
- $|\varphi(\lambda_{k+1}) - \varphi(\lambda_k)| \leq \epsilon_\varphi$

- $|\varphi'(\lambda_k)| \leq \epsilon_{\varphi'}$  (si se busca un punto crítico)
  - $b_k - a_k \leq \epsilon$  (si se construyen intervalos de certidumbre  $[a_k, b_k]$ )
- Cómo escoger  $\epsilon$ ?
    - Debe ser dependiente en la precisión, la cual depende a su vez de la plataforma (compilador y máquina).
    - $\epsilon_{\text{maq}} = \text{mín} \{ \epsilon : 1 + \epsilon' \neq 1 \}$  ( $\neq$  de acuerdo a la plataforma)
    - $\epsilon = 1$   
 $\epsilon = 1 + \epsilon$   
**mientras**  $s \neq 1$   
 $\epsilon = \epsilon/2$   
 $s = 1 + \epsilon$   
**fin\_mientras**  
 $\epsilon'_{\text{maq}} = 2\epsilon$

## 1.2. Método de Newton

- Es un método para resolver  $g(\lambda) = 0$
- $\lambda_{k+1} = \lambda_k - \frac{g(\lambda_k)}{g'(\lambda_k)}$
- Se puede usar como método de minimización (maximización) resolviendo  $\varphi'(\lambda) = 0$

$$\lambda_{k+1} = \lambda_k - \frac{\varphi'(\lambda_k)}{\varphi''(\lambda_k)}$$

- Desventajas:
  - puede no converger,
  - puede converger a un maximizador,
  - se requiere  $\varphi''(\lambda_k) \neq 0$ ,
  - se necesitan primeras y segundas derivadas de  $\varphi$ .

## 1.3. Método de la secante

- La idea es reemplazar en el método de Newton la segunda derivada ( $\varphi''$ ) por una aproximación:

$$\varphi''(\lambda_k) = \frac{\varphi'(\lambda_k) - \varphi'(\lambda_{k+1})}{\lambda_k - \lambda_{k+1}}$$

- $\lambda_{k+1} = \lambda_k - \frac{\lambda_{k-1}\varphi'(\lambda_k) - \lambda_k\varphi'(\lambda_{k+1})}{\varphi'(\lambda_k) - \varphi'(\lambda_{k+1})}$
- No es necesario evaluar la segunda derivada.

- Desventajas:
  - puede no converger,
  - puede converger a un maximizador,
  - se requiere  $\varphi'(\lambda_k) - \varphi'(\lambda_{k-1}) \neq 0$ ,
  - se necesita calcular primeras \ derivadas de  $\varphi$ .
- En general, es posible reemplazar las primeras derivadas en el método de Newton por aproximaciones numéricas.

## 1.4. Métodos de encajonamiento

- La idea es refinar iterativamente un intervalo  $[a_k, b_k]$  (llamado intervalo de certidumbre).
- Cada sucesivo intervalo debe estar contenido en el anterior:

$$a_k \leq a_{k+1} \text{ y } b_k \geq b_{k+1}$$

- La longitud de los intervalos debe tender a 0:

$$\lim_{k \rightarrow \infty} b_k - a_k = 0$$

- Converge al valor óptimo si:

- La función es cuasiconvexa:

$$\forall x, y \in D, \forall \sigma \in [0, 1] \ f((1 - \sigma)x + \sigma y) \leq \max\{f(x), f(y)\}$$

- El valor óptimo  $\lambda^* \in [a_1, b_1]$

### 1.4.1. Búsqueda secuencial

- La idea es evaluar la función en  $m$  posiciones y usar estos valores para refinar el intervalo.

- Entradas:  $a, b, \epsilon, m$

$$l = b - a$$

**mientras**  $l \geq \epsilon$

$$\delta = l / (m + 1)$$

$$\mu_j = a + \delta j, \ j = 1, \dots, m$$

$$\mu^* = \arg \min\{\varphi(\mu_1), \dots, \varphi(\mu_m)\}$$

$$a = \mu^* - \delta$$

$$b = \mu^* + \delta$$

$$l = b - a$$

**fin-mientras**

$$\lambda^* = \min\{a, \mu^*, b\}$$

- Cuál es el número óptimo de evaluaciones por iteración ( $m$ )?
  - El objetivo es minimizar el número total de evaluaciones:  $mk$  ( $k$  corresponde al número de iteraciones)
  - Asumiendo que el criterio de terminación es  $b_k - a_k \leq \epsilon$ , es posible demostrar que:

$$mk \approx \frac{m}{\log \frac{m+1}{2}} L_0 = c(m)L_0$$

donde  $L_0 = \log \frac{b_0 - a_0}{\epsilon}$

| $m$ | $c(m)$ |
|-----|--------|
| 2   | 4.93   |
| 3   | 4.33   |
| 4   | 4.37   |
| 5   | 4.55   |
| 6   | 4.79   |
| 7   | 5.05   |

## 1.5. Otros métodos

- Sección dorada (o áurea)
 

Método de encajonamiento que tiene un mejor desempeño que la búsqueda secuencial. Solo se realiza una evaluación por iteración y los puntos no están igualmente espaciados.
- Minimización por interpolación cuadrática
 

La idea es encontrar tres valores  $t_1, t_2$  y  $t_3$  que permitan obtener el minimizador  $t_p^*$  de la parábola que pasa por los puntos  $(t_i, \varphi(t_i))$  ( $i = 1, 2, 3$ ). Este punto sirve como nuevo valor para la siguiente iteración.

## 2. Optimización en varias variables

- Problema general:

$$\text{minimizar } f(x), \quad f : \mathbb{R}^n \rightarrow \mathbb{R}$$

- Estrategia general (aplica a varios métodos):
- Dado un punto  $x^k$  se construye una dirección  $d^k \neq 0$  y se obtiene  $\lambda_k^*$  el cual es un minimizador de  $\varphi(\lambda) = f(x^k + \lambda d^k)$  cuando  $\lambda$  varía en  $\mathbb{R}$ :

$$\begin{aligned} \lambda_k^* &= \arg \min_{\lambda \in \mathbb{R}} f(x^k + \lambda d^k), \\ x^{k+1} &= x^k + \lambda_k^* d^k \end{aligned}$$

## 2.1. Método de Newton

- Es una generalización del método para una variable:

$$x_{k+1} = x_k - \frac{g(x_k)}{g'(x_k)}$$

- La anterior fórmula puede ser reescrita como:

$$x_{k+1} = x_k - (g'(x_k))^{-1}g(x_k)$$

- Si  $g : \mathbb{R}^n \rightarrow \mathbb{R}^n$ , la fórmula se puede generalizar a:

$$x^{k+1} = x^k - (g'(x^k))^{-1}g(x^k)$$

donde  $g'(x_k)$  corresponde al jacobiano de la función  $g$ .

- El método de Newton se expresa en dos partes:

$$\begin{aligned} \text{resolver } f''(x^k)d^k &= -f'(x^k) \\ x^{k+1} &= x^k + d^k \end{aligned}$$

donde  $f''$  es el hessiano y  $f'$  es el gradiente.

## 2.2. Método del gradiente o del descenso más pendiente

- La idea es escoger la dirección  $d^k$  como la dirección que produce mayor descenso. Esta dirección corresponde al gradiente multiplicado por -1.
- El algoritmo es el siguiente:

**Entrada:**  $x^0, \epsilon_g, \text{MAXIT}$   
**para**  $k = 0, \dots, \text{MAXIT}$   
  **si**  $\|f'(x^k)\| \leq \epsilon_g$  **entonces parar**  
   $d^k = -f'(x^k)$   
   $\lambda_k^* = \arg \min f(x^k + \lambda d^k), \lambda \geq 0$   
   $x^{k+1} = x^k + \lambda_k^* d^k$   
**fin-para**

### 2.3. Método del gradiente conjugado

- El algoritmo es el siguiente:

**Entrada:**  $x^1, \epsilon_g, \text{MAXIT}$   
**para**  $K = 1, \dots, \text{MAXIT}$   
  **para**  $k = 1, \dots, n$   
    **si**  $\|f'(x^k)\| \leq \epsilon_g$  **entonces parar**  
    **si**  $k = 1$  **entonces**  $d^k = -f'(x^k)$   
    **sino**  
      
$$\alpha_k = \frac{\|f''(x^k)\|_2^2}{\|f''(x^{k-1})\|_2^2}$$
  
      
$$d^k = -f'(x^k) + \alpha_k d^{k-1}$$
  
    **fin-sino**  
     $\lambda_k^* = \arg \min f(x^k + \lambda d^k), \lambda \geq 0$   
     $x^{k+1} = x^k + \lambda_k^* d^k$   
  **fin-para**  
   $x^1 = x^{n+1}$   
**fin-para**

## 2.4. Método cíclico coordinado

- El algoritmo es el siguiente:

**Entrada:**  $x^0, \epsilon_x, \text{MAXIT}$   
**para**  $k = 0, \dots, \text{MAXIT}$   
   $y^1 = x^k$   
  **para**  $j = 1, \dots, n$   
     $\lambda_j^* = \arg \min f(y^j + \lambda e^j)$   
     $y^{j+1} = y^j + \lambda_j^* e^j$   
  **fin-para**  
   $x^{k+1} = y^{n+1}$   
  **si**  $\|x^{k+1} - x^k\| < \epsilon_x$  **entonces parar**  
**fin-para**

Donde  $e^j$  corresponde al vector  $(e_1, \dots, e_n)$  con  $e_j = 1$  y  $e_i = 0$  para todo  $i \neq j$ .