

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 λ^* 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 ϵ ?
 - Debe ser dependiente en la precisión, la cual depende a su vez de la plataforma (compilador y máquina).
 - $\epsilon_{\text{maq}} = \text{mín} \{ \epsilon : 1 + \epsilon' \neq 1 \}$ ($\epsilon' \neq$ 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 φ .

1.3. Método de la secante

- La idea es reemplazar en el método de Newton la segunda derivada (φ'') 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 φ .
- 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, ϵ, 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 λ_k^* el cual es un minimizador de $\varphi(\lambda) = f(x^k + \lambda d^k)$ cuando λ varía en \mathbb{R} :

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

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
 $\lambda_k^* = \arg \min_{\lambda \geq 0} f(x^k + \lambda d^k)$
 $x^{k+1} = x^k + \lambda_k^* d^k$
 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 $j = 1, \dots, n$
 $\lambda_j^* = \arg \min_{\lambda} f(y^j + \lambda e^j)$
 $y^{j+1} = y^j + \lambda_j^* e^j$
 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 $i \neq j$.