

1.II.4 Métodos basados en técnicas de optimización

Bibliografía

Kincaid-Cheney, pg. 209 y ss.

Conde-Winter, pg. 247 y ss.

Bulirsch-Stoer, pg. 572 y ss.

1. Problema de optimización asoc.

A matriz $n \times n$, simétrica def. posit.

A $x = b \iff \min J(x)$, siendo

$$J: \mathbb{R}^n \longrightarrow \mathbb{R}$$

$$J(x) = \frac{1}{2} x^T A x - x^T b$$

A def. posit. $\Rightarrow J$ es convexo (estricto)

$$J(\lambda x + (1 - \lambda)y) \leq \lambda J(x) + (1 - \lambda)J(y)$$

luego, existe un solo mínimo (la solución del sist. lineal)

♠ Métodos de descenso:

Dado un vector inicial $x^{(0)}$, elegir iterativamente una dirección v_k y un incremento t_k que minimice el valor de $J(x^{(k)} + t_k v_k)$

2. Método del gradiente.

Elegir:

• $v_k = -grad(J(x) = b - Ax^{(k)})$, máx. desc.

• t_k tal que $J(x^{(k+1)}) = \min J(x^{(k)} + t_k v_k)$

$$\implies t_k = \frac{v_k^T v_k}{v_k^T A v_k}$$

♠ Algoritmo

• Input: $x^{(0)}$ arbitrario, Tol

• $v_k = b - Ax^{(k)}$

• $t_k = \frac{v_k^T v_k}{v_k^T A v_k}$

• $x^{(k+1)} = x^{(k)} + t_k v_k$

• crit. de parada: $\|x^{(k+1)} - x^{(k)}\| \leq \text{Tol}$

♠ Observaciones:

a) Sucesivas direc. v_k no tienen relación

b) Suele ser lentamente convergente.

♠ Expresión del error:

$$\|x^{(k)} - x^*\| \leq \beta^k \|x^{(0)} - x^*\|, \quad \beta = \frac{K_2(A) - 1}{K_2(A) + 1}$$

3. Método del gradiente conjugado.

• Elegir: $v_0 = b - Ax^{(0)} = -grad(J(x^{(0)}))$ (máximo descenso)

t_0 como en met. gradiente.

• v_k comb. lineal de $r_k = b - Ax^{(k)}$ y de v_{k-1} que sea A-ortogonal a v_{k-1} ,

es decir,

$$v_k = r_k + \alpha_{k-1} v_{k-1}, \quad \alpha_{k-1} = -\frac{r_k^T A v_{k-1}}{v_{k-1}^T A v_{k-1}}$$

• $x^{(k+1)} = x^{(k)} + t_k v_k$, con $t_k = \frac{v_k^T r_k}{v_k^T A v_k}$

Teorema.

i) $r_i^T v_j = v_j^T r_i = 0$, $0 \leq j < i \leq N_0$

ii) $r_i^T r_i = r_i^T v_i = v_i^T r_i$, $0 \leq i \leq N_0$

iii) $v_i^T A v_j = 0$, $0 \leq i < j \leq N_0$

$v_i^T A v_i > 0$, $0 \leq i < N_0$

iv) $r_i^T r_j = 0$, $0 \leq i < j \leq N_0$

Resultado: $\exists N_0 \leq n$ tal que $v_{N_0} = 0 \implies$ convergencia en N_0 iteraciones.

Algoritmo

• Input: $x^{(0)}$ arbitrario, Tol, Nmax

• $d_0 = b - Ax^{(0)}$

• Para $k = 0, 1, 2, \dots$

$$- t_k = \frac{r_k^T r_k}{v_k^T A v_k}$$

$$- x^{(k+1)} = x^{(k)} + t_k v_k$$

$$- r_{k+1} = b - Ax^{(k+1)} = r_k - t_k A v_k$$

$$- \alpha_k = -\frac{r_{k+1}^T r_{k+1}}{r_k^T r_k}$$

$$- v_{k+1} = r_{k+1} + \alpha_k v_k$$

- test converg.: $\|r_{k+1}\| \leq \text{Tol}$

- test parada: $k \leq N_{\max}$

- resultados

Gradiente conjugado con preconditionamiento

- acelerar la convergencia
- disminuir la influencia de los errores de redondeo
- Resolver: $Gw = c$ con $w = Mx$ y $c = M^{-1}b$

problema asociado al funcional

$$J(x) = \bar{J}(w) = \frac{1}{2}w^T Gw - c^T w$$

con la idea de que: $\text{cond}_2(G) < \text{cond}_2(A)$

- Elegir M tal que $\text{cond}_2(M^{-1}A) < \text{cond}_2(A)$
- Elegir M que no implique realizar muchas operaciones
- Elección basada en la factorización de A

Gradiente conjug. matrices no simétricas definidas positivas

- Ecuación normal
- Error mínimo
- Residuo mínimo
- Doble gradiente conjugado