



# ALN – Métodos Iterativos Básicos

In. Co.

Facultad de Ingeniería

Universidad de la República

# Introducción

## ■ Los métodos directos para resolver sistemas de ecuaciones lineales:



- Llegan a la solución en un número específico de pasos, en función del tamaño del sistema a resolver.
- Consiguen, a menos de errores numéricos, la solución exacta del sistema lineal.



- Son demasiado costosos y se vuelven prohibitivos para matrices grandes!!

# Introducción

## ■ Métodos iterativos:

□ Buscan aproximar la solución mediante una sucesión generada iterativamente.

□ La solución exacta al problema es  $x^* = A^{-1}b$   
entonces buscamos una sucesión  $\{x_k\}_{k=0}^{\infty}$   
tal que  $\lim_{k \rightarrow \infty} x_k = x^*$

# Introducción

- Métodos iterativos:

- Si el método converge se obtiene una solución aproximada del problema, cuyo error satisface algún criterio prefijado.
- Es importante asegurar la convergencia y estimar tasa de convergencia (error al aumentar  $k$ ).

# Introducción

- Cuando detener la iteración ?!

- Dependiendo del error !!! Pero no conocemos  $x^*$
- $r_k = b - Ax_k$

$$\frac{\|r_k\|}{\|r_0\|} < tol$$

# Introducción

Quando detener la iteración ?!

□ Estamos trabajando en una máquina !!!, hay una precisión alcanzable !!!

□ Es del orden de  $\varepsilon_{mach} \times \kappa(A) \times \|b\|$

# Punto fijo

- Reescribimos el problema como una iteración de punto fijo.

$$x^{(k+1)} = Bx^{(k)} + c$$

- La matriz  $B$  se denomina matriz de amplificación

# Diferentes familias

$$x^{(k+1)} = Bx^{(k)} + c$$

- Estacionarios:  $B$  y  $c$  no dependen de  $k$ .  
Generalmente más sencillos de implementar pero con menos capacidad de convergencia.
- No estacionarios



# Métodos estacionarios

# Deducción

Agregamos una matriz  $M$  invertible:

$$Ax = b \Leftrightarrow Mx = (M - A)x + b$$

Y consideramos la siguiente recursión:

$$Mx^{(k+1)} = (M - A)x^{(k)} + b \quad (1)$$

# Deducción

Partiendo de una solución inicial  $x_0$ . Si la solución converge tendremos:

$$(2) \quad Mx^{(\infty)} = (M - A)x^{(\infty)} + b \Leftrightarrow Ax^{(\infty)} = b$$

# Deducción

Si se resta (2) de (1) se obtiene:

$$M \underbrace{(x^{(\infty)} - x^{(k+1)})}_{e^{(k+1)}} = (M - A) \underbrace{(x^{(\infty)} - x^{(k)})}_{e^k}$$

$$e^{(k+1)} = M^{-1} (M - A) e^{(k)}$$

# Deducción

$$M^{-1}(M - A) = -M^{-1}A = Q$$

$$e^{(k+1)} = Qe^{(k)} = Q^k e^{(0)}$$

Por lo tanto:

$$e^{(k)} \xrightarrow[k]{} 0 \leftrightarrow \|Q^k\| \xrightarrow[k]{} 0$$

# Convergencia

## Propiedad 1

Una condición suficiente para lo anterior es que para alguna norma se tenga que  $\|Q\| < 1$ .

Demostración:

En ese caso basta utilizar la propiedad de norma de matriz que dice:

$$\|AB\| \leq \|A\| \|B\| \rightarrow \|Q^k\| \leq (\|Q\|)^k$$

# Convergencia

## Propiedad 2

La condición necesaria y suficiente es que el radio espectral de  $Q$  sea menor que 1.

Demostración: (suficiencia)

$$\rho(Q) < 1$$

Sea  $\mu$  un valor propio de  $Q$  y  $v$  el vector propio de norma 1 correspondiente.

Tenemos  $\|Q^k v\| = \|\mu^k v\| = |\mu^k| \rightarrow 0$  entonces  $\|Q^k\| \rightarrow 0$

# Convergencia

## Propiedad 2 (necesidad)

Si  $\|Q^k\| \rightarrow 0$  y  $v$  es un vector propio de norma 1, entonces:

$$\|Q^k v\| \leq \|Q^k\| \text{ por lo tanto } \|Q^k v\| \rightarrow 0$$

$\|Q^k v\| = |\mu^k|$  para algún valor propio  $\mu$  y como  $|\mu^k| \rightarrow 0$  entonces  $\mu < 1$

# Convergencia

Propiedad 3 (velocidad de convergencia)

Si llamamos  $q^k = \frac{\|e^{(k+1)}\|}{\|e^{(k)}\|}$

Para matrices Normales se cumple que  $q^{(k)} \approx \rho(Q)$

Para otros tipos de matriz es más difícil de determinar

# Método de Jacobi

Consiste en tomar la matriz  $M$  como la diagonal de  $A$  (si  $a_{ii} \neq 0$ ) en cuyo caso la inversa de  $M$  es trivial

$$x_i^{(k)} = \frac{(b_i - \sum_{j \neq i} a_{i,j} x_j^{(k-1)})}{a_{i,i}}$$

# Método de Jacobi

- En forma matricial el método es equivalente a:

$$x^{(k)} = D^{-1}(-L-U)x^{(k-1)} + D^{-1}b$$

donde  $D$  es la matriz diagonal,  $L$  es la matriz triangular inferior y  $U$  es la triangular superior

# Método de Gauss-Seidel

$$x_i^{(k)} = \frac{(b_i - \sum_{j<i} a_{i,j} x_j^{(k)} - \sum_{j>i} a_{i,j} x_j^{(k-1)})}{a_{i,i}}$$

# Método de Gauss-Seidel

- En forma matricial el método es equivalente a:

$$x^{(k)} = (D + L)^{-1} (-Ux^{(k-1)} + b)$$

donde  $D$  es la diagonal,  $L$  es la parte triangular inferior y  $U$  es la triangular superior de  $A$ . ( $A=L+D+U$ )

# Comparación de los métodos

- Jacobi, no se necesitan conocer las componentes del vector previamente calculadas.
- En general la velocidad de convergencia del método Gauss-Seidel es mayor a la de Jacobi.

# Convergencia

Ejemplo:  $\begin{bmatrix} 2 & -1 \\ -1 & 2 \end{bmatrix} x = b$

## ■ Jacobi

$$\begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} x^{(k+1)} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} x^{(k)} + b \rightarrow x^{(k+1)} = \underbrace{\begin{bmatrix} 0 & \frac{1}{2} \\ \frac{1}{2} & 0 \end{bmatrix}}_{\varrho} x^{(k)} + \frac{b}{2} \quad \lambda_i = \pm \frac{1}{2}$$

## ■ Gauss-Seidel

$$\begin{bmatrix} 2 & 0 \\ -1 & 2 \end{bmatrix} x^{(k+1)} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} x^{(k)} + b \rightarrow x^{(k+1)} = \underbrace{\begin{bmatrix} 0 & \frac{1}{2} \\ 0 & \frac{1}{4} \end{bmatrix}}_{\varrho} x^{(k)} + \begin{bmatrix} \frac{1}{2} & 0 \\ \frac{1}{4} & \frac{1}{2} \end{bmatrix} b \quad \lambda_i = 0, \frac{1}{4}$$

# Otras variantes

Backward GS

GS simétrico

Relajación SOR

SSOR

# SOR (Successive Over-Relaxation)

- Se basa en aplicar una extrapolación al método de Gauss-Seidel

$$x_i^{(k)} = w\tilde{x}_i^{(k)} + (1-w)x_i^{(k-1)}$$

- Aquí  $\tilde{x}_i^{(k)}$  es la iteración de GS y  $w$  es un parámetro definido de antemano.
- La idea es que el parámetro mejore la velocidad de convergencia de GS.
- Es difícil conocer el  $w$  óptimo
- *Kahan* demostró que el método solo converge para  $w \in (0,2)$