



## Métodos Iterativos

### Resultados preliminares

**Normas Matriciales Inducidas.** Toda norma vectorial  $\|\cdot\|$  sobre  $\mathbb{R}^n$  induce una **norma matricial** sobre  $\mathbb{R}^{n \times n}$  (espacio de matrices cuadradas  $n \times n$ ):

$$\|A\| := \max_{x \in \mathbb{R}^n: x \neq \theta} \frac{\|Ax\|}{\|x\|}, \quad A \in \mathbb{R}^{n \times n}.$$

Es fácil verificar que esto define efectivamente una norma sobre  $\mathbb{R}^{n \times n}$ .

Esta norma se dice que es una norma matricial **inducida** por la norma vectorial y se denota con el mismo símbolo que la norma vectorial.

**Proposición.** Toda norma **matricial inducida** por una norma vectorial satisface las siguientes propiedades:

$$\begin{aligned} \|Ax\| &\leq \|A\| \|x\| & \forall A \in \mathbb{R}^{n \times n}, \quad \forall x \in \mathbb{R}^n & \quad (\text{compatibilidad}), \\ \|AB\| &\leq \|A\| \|B\| & \forall A, B \in \mathbb{R}^{n \times n} & \quad (\text{submultiplicatividad}). \end{aligned}$$

Hay formas más sencillas de calcular algunas de las **normas matriciales** más usuales.

**Proposición.** Sea  $A = (a_{ij}) \in \mathbb{R}^{n \times n}$ . Entonces:

- $\|A\|_\infty = \max_{1 \leq i \leq n} \left( \sum_{1 \leq j \leq n} |a_{ij}| \right)$  (**máxima suma de filas**).
- $\|A\|_1 = \max_{1 \leq j \leq n} \left( \sum_{1 \leq i \leq n} |a_{ij}| \right)$  (**máxima suma de columnas**).
- $\|A\|_2 = \sqrt{\rho(A^t A)}$  (**norma espectral**).

### Valores y Vectores Propios.

**Definición.** Dada una matriz cuadrada  $A$ , diremos que un número  $\lambda \in \mathbb{C}$  es un **valor propio** (o **autovalor**) de  $A$  si existe un vector no nulo,  $v \neq \theta$ , tal que  $Av = \lambda v$ . Se dice que  $v$  es **vector propio** (o **autovector**) asociado al valor propio  $\lambda$ .

Por otro lado  $\lambda$  es un valor propio si y sólo si es raíz de la **ecuación característica**  $\det(A - \lambda I) = 0$ .

**Definición.** El **espectro** de  $A$  es el conjunto de todos sus valores propios:

$$\sigma(A) := \left\{ \lambda \in \mathbb{C} : \lambda \text{ es un valor propio de } A \right\}.$$

**Definición.** El **radio espectral** de  $A$  es el máximo módulo de sus autovalores:

$$\rho(A) := \max_{\lambda \in \sigma(A)} |\lambda|.$$



**Teorema.** Si  $A \in \mathbb{R}^{n \times n}$  es **simétrica** ( $A^t = A$ ), entonces  $\|A\|_2 = \rho(A)$ .

### Matrices dispersas.

- Una **matriz dispersa** (o sparse) es una matriz de gran tamaño en la que la mayor parte de sus elementos son cero. Estas matrices son ampliamente usadas en la optimización a gran escala, teoría de grafos, teoría de redes, análisis estructural y de circuitos, dinámica de fluidos computacionales y en general en solución numérica de ecuaciones diferenciales parciales, entre otros.
- Cuando la matriz  $A$  del sistema a resolver es **dispersa, pero no banda**, los métodos (directos) estudiados hasta ahora (eliminación de Gauss o Cholesky) presentan el defecto denominado **llenado (fill-in)**.
- El llenado consiste en que, a medida que el proceso de eliminación avanza, se van creando elementos no nulos en posiciones de  $L$  y  $U$  en donde la matriz  $A$  tiene ceros.
- Como consecuencia del llenado se tiene, por una parte, el **aumento del número de flop** y con ello el **aumento del error de redondeo**. Por otra parte se tiene el **aumento en las necesidades de memoria** para almacenar las matrices  $L$  y  $U$ , lo que puede llegar a hacer imposible aplicar estos métodos cuando  $A$  es de gran tamaño.
- Los métodos que estudiaremos a continuación, llamados **iterativos**, evitan el llenado y sus consecuencias, al trabajar resolviendo reiteradamente sistemas con matriz diagonal o triangular-dispersa.

### Esquema general

- Considere el sistema de ecuaciones lineales:

$$Ax = b,$$

con  $A \in \mathbb{R}^{n \times n}$  no singular y  $b \in \mathbb{R}^n$ .

Un **método iterativo** para resolver el sistema construye, a partir de un vector inicial  $x^{(0)}$ , una sucesión de vectores  $x^{(1)}, x^{(2)}, \dots, x^{(k)}, \dots$  la que, bajo condiciones apropiadas, resultará convergente a  $x$ , es decir,

$$\lim_{k \rightarrow \infty} x^{(k)} = x.$$

- Si suponemos  $A = N - P$ , donde  $N$  debe ser invertible, entonces

$$Ax = b \iff Nx = Px + b \iff x = N^{-1}Px + N^{-1}b.$$

- Se usa la igualdad  $Nx = Px + b$  para definir un esquema general para construir la sucesión  $\{x^{(k)}\}$ .

- **Algoritmo del esquema general:**

Dado el vector inicial  $x^{(0)}$ ,  
 para  $k = 1, 2, \dots$  resolver:  

$$Nx^{(k)} = Px^{(k-1)} + b,$$
  
 hasta que se satisfaga un criterio de detención.

- Definiendo  $M := N^{-1}P$  (**matriz de iteración**) y  $e^{(k)} := x - x^{(k)}$  (**error de  $x^{(k)}$** ), para cada  $k = 1, 2, \dots$  se tiene

$$e^{(k)} = M^k e^{(0)}, \quad k = 1, 2, \dots$$



## Convergencia de métodos iterativos.

- **Lema.** Sea  $B \in \mathbb{R}^{n \times n}$ . Entonces

$$\lim_{k \rightarrow \infty} B^k = \mathbf{0} \iff \rho(B) < 1.$$

- **Teorema.** (Convergencia) La sucesión  $\{\mathbf{x}^{(k)}\}$  converge a la solución  $\mathbf{x}$  de  $A\mathbf{x} = \mathbf{b}$ , si y sólo si,  $\rho(M) < 1$ .

**Observación.** Si la sucesión  $\{\mathbf{x}^{(k)}\}$  converge, necesariamente lo hace a la solución  $\mathbf{x}$  de  $A\mathbf{x} = \mathbf{b}$ .

- **Lema.** (Cota para el radio espectral) Sea  $A$  una matriz cuadrada. Para cualquier norma matricial se tiene que

$$\rho(A) \leq \|A\|.$$

- **Corolario.** (Condición suficiente de convergencia) Una condición suficiente para que la sucesión  $\{\mathbf{x}^{(k)}\}$  sea convergente a la solución  $\mathbf{x}$  de  $A\mathbf{x} = \mathbf{b}$  es que

$$\|M\| < 1,$$

donde  $M$  es la matriz de iteración del método que genera a  $\{\mathbf{x}^{(k)}\}$ .

## Criterio de detención

- **Detención del proceso.** Cuando el proceso iterativo es convergente, éste se debe detener para un  $\mathbf{x}^{(k+1)}$  tal que  $\|e^{(k+1)}\| = \|\mathbf{x} - \mathbf{x}^{(k+1)}\| \leq \text{tol}$ , donde  $\text{tol}$  indica un nivel de tolerancia prefijado para el error.

- **Lema.** Para  $\|M\| < 1$ , se tiene que

$$\|\mathbf{x} - \mathbf{x}^{(k+1)}\| \leq \frac{\|M\|}{1 - \|M\|} \|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|.$$

- El criterio de detención implica calcular  $\|M\|$ , lo que en general es difícil. El siguiente lema indica una manera de estimar  $\|M\|$ .

- **Lema.** Para  $k = 1, 2, \dots$  se tiene:

$$m_k := \frac{\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|}{\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|} \leq \|M\|.$$

**Demostración.**

$$\begin{aligned} m_k &= \frac{\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|}{\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|} = \frac{\|[\mathbf{x}^{(k+1)} - \mathbf{x}] - [\mathbf{x}^{(k)} - \mathbf{x}]\|}{\|[\mathbf{x}^{(k)} - \mathbf{x}] - [\mathbf{x}^{(k-1)} - \mathbf{x}]\|} \\ &= \frac{\|e^{(k+1)} - e^{(k)}\|}{\|e^{(k)} - e^{(k-1)}\|} = \frac{\|M[e^{(k)} - e^{(k-1)}]\|}{\|e^{(k)} - e^{(k-1)}\|} \leq \max_{\mathbf{y} \in \mathbb{R}^n: \mathbf{y} \neq \mathbf{0}} \frac{\|M\mathbf{y}\|}{\|\mathbf{y}\|} = \|M\|. \end{aligned}$$





- Para la norma infinito de  $M$  se tiene que  $\|M\|_\infty = \max_{1 \leq i \leq n} \left\{ \frac{1}{|a_{ii}|} \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \right\}$ .
- Cuando  $A$  es de **diagonal dominante estricta**, es decir, cuando se tiene que

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|, \quad i = 1, \dots, n,$$

entonces  $\|M\|_\infty < 1$  y el método de Jacobi resulta convergente.

### Método de Gauss-Seidel

- El **método de Gauss-Seidel** corresponde al esquema iterativo general con

$$N := D - E \quad \text{y} \quad P := F.$$

La matriz de iteración es entonces  $M = (D - E)^{-1}F$ .

- Algoritmo de Gauss-Seidel:**

Dado el vector inicial  $x^{(0)}$ ,  
 para  $k = 1, 2, \dots$ , resolver:  
 $(D - E)x^{(k)} = Fx^{(k-1)} + b$ ,  
 hasta que se satisfaga un criterio de detención.

- En la iteración  $k$ , el vector  $x^{(k)}$  puede obtenerse **por componentes** como sigue:

Para  $i = 1, \dots, n$ :

$$x_i^{(k)} = \frac{1}{a_{ii}} \left[ b_i - \sum_{j=1}^{i-1} a_{ij}x_j^{(k)} - \sum_{j=i+1}^n a_{ij}x_j^{(k-1)} \right].$$

Notemos que esto corresponde a aprovechar en el paso  $k$ , los valores  $x_j^{(k)}$  ya calculados.

### Convergencia de los métodos de Jacobi y de Gauss-Seidel

- Teorema.** Si  $A$  es de diagonal dominante estricta, entonces los métodos de Jacobi y de Gauss-Seidel convergen.

**Observación.** Para una matriz arbitraria  $A$ , la convergencia de uno de estos métodos no implica la convergencia del otro.

- Teorema.** Si  $A$  es simétrica y definida positiva, el método de Gauss-Seidel es convergente.

**Observación.** Aunque  $A$  sea simétrica y definida positiva, el método de Jacobi puede ser divergente.