

75.12/95.04 ANÁLISIS NUMÉRICO I
95.10 MODELACIÓN NUMÉRICA
95.13 MÉTODOS MATEMÁTICOS Y NUMÉRICOS
SISTEMAS DE ECUACIONES LINEALES – MÉTODOS ITERATIVOS

Ing. Rodolfo A. Schwarz

Año 2021

Índice

1 MÉTODOS ITERATIVOS

- Métodos Iterativos Estacionarios
 - Método de Jacobi
 - Método de Gauss–Seidel
 - Método de las Sobrerrelajaciones Sucesivas
 - Convergencia
- Métodos Iterativos No Estacionarios
 - Método de los Residuos Mínimos
 - Método del Descenso Más Rápido
 - Método de los Gradientes Conjugados
- Resumen


2 BIBLIOGRAFÍA

Métodos Iterativos

- Los métodos vistos, denominados *Métodos Directos*, son generales.
- Sirven para cualquier sistema de ecuaciones lineales (*Eliminación de Gauss*, *Factorización LU*) o para todo tipo de sistema que tenga una matriz \mathbf{A} simétrica definida positiva (*Método de Cholesky*).
- Una característica importante es que el número de operaciones es «finito».
- Son muy eficientes cuando las matrices de coeficientes están formadas con una mayoría de coeficientes no nulos. Por eso reciben el nombre de *sistemas densos*.
- Existen muchos otros sistemas de ecuaciones lineales con características diferentes:
 - ① Sistemas con matrices diagonales (tridiagonal, por ejemplo),
 - ② Sistemas con matrices «banda»,
 - ③ Sistemas con matrices cuyos coeficientes son mayormente nulos.
- Estos sistemas se suelen denominar *Sistemas de Ecuaciones Lineales Ralos*.

Métodos Iterativos

- Una vez más, veamos otro modelo estructural:



Métodos Iterativos

- El modelo también se resuelve mediante el *Método de los Elementos Finitos*.
- La cantidad de incógnitas es 19.358 , como se indica en el archivo de salida:
PROBLEM STATISTICS

NUMBER OF JOINTS/MEMBER+ELEMENTS/SUPPORTS = 3267/ 3826/
1365

ORIGINAL/FINAL BAND-WIDTH= 2573/ 48/ 293 DOF

TOTAL PRIMARY LOAD CASES = 7,

TOTAL DEGREES OF FREEDOM = 19358

SIZE OF STIFFNESS MATRIX = 5672 DOUBLE KILO-WORDS

REQRD/AVAIL. DISK SPACE = 84.1/ 183907.7 MB

- Una cuestión adicional es que el *Sistema de Ecuaciones Lineales* que representa este tipo de modelos es *ralo*.

Métodos Iterativos

- La transformación de las matrices de los *Sistemas de Ecuaciones Lineales Ralos* por algún método numérico puede significar «cambiar» una componente nula por una nueva no nula, con el consiguiente error.
- Es por eso que se han desarrollado métodos que se utilizan casi con exclusividad para resolver este tipo de sistemas.
- Analicemos otra forma de obtener la solución de nuestro sistema. Podemos hacer lo siguiente:

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{B} \quad \Rightarrow \quad \mathbf{B} - \mathbf{A} \cdot \mathbf{x} = 0. \quad (1)$$

- Si sumamos $\mathbf{M} \cdot \mathbf{x}$ en ambos miembros tenemos:

$$\mathbf{M} \cdot \mathbf{x} = \mathbf{M} \cdot \mathbf{x} + \mathbf{B} - \mathbf{A} \cdot \mathbf{x}. \quad (2)$$

- Al operar algebraicamente, obtenemos:

$$\begin{aligned} \mathbf{x} &= \mathbf{M}^{-1} \cdot \mathbf{M} \cdot \mathbf{x} + \mathbf{M}^{-1} \cdot \mathbf{B} - \mathbf{M}^{-1} \cdot \mathbf{A} \cdot \mathbf{x} \Rightarrow \\ \mathbf{x} &= (\mathbf{I} - \mathbf{M}^{-1} \cdot \mathbf{A}) \cdot \mathbf{x} + \mathbf{M}^{-1} \cdot \mathbf{B}. \end{aligned} \quad (3)$$

Métodos Iterativos

- De esta forma tenemos un método con \mathbf{x} en ambos lados. Lo convertimos en un método iterativo:

$$\mathbf{x}^{\langle i+1 \rangle} = (\mathbf{I} - \mathbf{M}^{-1} \cdot \mathbf{A}) \cdot \mathbf{x}^{\langle i \rangle} + \mathbf{M}^{-1} \cdot \mathbf{B}. \quad (4)$$

donde $\langle i \rangle$ indica la iteración.

- Una forma simplificada de escribir lo anterior es:

$$\mathbf{x}^{\langle i+1 \rangle} = \mathbf{T} \cdot \mathbf{x}^{\langle i \rangle} + \mathbf{C}, \quad (5)$$

con $\mathbf{T} = \mathbf{I} - \mathbf{M}^{-1} \cdot \mathbf{A}$ y $\mathbf{C} = \mathbf{M}^{-1} \cdot \mathbf{B}$.

- Tenemos que definir la matriz \mathbf{M} y obtener \mathbf{T} y \mathbf{C} .

Métodos Iterativos Estacionarios

- Escribamos \mathbf{A} de la siguiente forma:

$$\mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U} \quad (6)$$

donde:

- \mathbf{D} : matriz diagonal, con $d_{ii} = a_{ii}$;
- \mathbf{L} : matriz estrictamente triangular inferior, que cumple con

$$l_{ij} = \begin{cases} a_{ij} & \text{cuando } i > j, \\ 0 & \text{cuando } i \leq j. \end{cases}$$

- \mathbf{U} : matriz estrictamente triangular superior, que cumple con

$$u_{ij} = \begin{cases} 0 & \text{cuando } i \geq j, \\ a_{ij} & \text{cuando } i < j. \end{cases}$$

- En todos los casos, $i \in (1, n)$ y $j \in (1, n)$.

Métodos Iterativos Estacionarios

Método de Jacobi

- El primer método surge de proponer que $\mathbf{M} = \mathbf{D}$, denominado *Método de Jacobi*.
- Si operamos en la matriz \mathbf{T} nos queda:

$$\begin{aligned}\mathbf{T} &= \mathbf{I} - \mathbf{M}^{-1} \cdot \mathbf{A} = \mathbf{I} - \mathbf{D}^{-1} \cdot (\mathbf{L} + \mathbf{D} + \mathbf{U}) \\ &= \mathbf{I} - \mathbf{D}^{-1} \cdot \mathbf{L} - \underbrace{\mathbf{D}^{-1} \cdot \mathbf{D}}_{\mathbf{I}} - \mathbf{D}^{-1} \cdot \mathbf{U} \Rightarrow\end{aligned}\tag{7}$$

$$\mathbf{T} = -\mathbf{D}^{-1} \cdot (\mathbf{L} + \mathbf{U}).$$

- Y si operamos en el vector \mathbf{C} nos queda:

$$\mathbf{C} = \mathbf{M}^{-1} \cdot \mathbf{B} = \mathbf{D}^{-1} \cdot \mathbf{B}.\tag{8}$$

- El *Método de Jacobi* lo podemos expresar así:

$$\mathbf{x}^{\langle i+1 \rangle} = \mathbf{D}^{-1} \cdot [\mathbf{B} - (\mathbf{L} + \mathbf{U}) \cdot \mathbf{x}^{\langle i \rangle}].\tag{9}$$

Métodos Iterativos Estacionarios

Método de Jacobi

- La formulación no matricial es:

$$x_j^{(i+1)} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} \cdot x_k^{(i)} - \sum_{k=j+1}^n a_{jk} \cdot x_k^{(i)} \right) \quad (10)$$

- Para poder aplicar el método debemos definir un $\mathbf{x}^{(0)}$.
- Suele usarse $\mathbf{x}^{(0)} = \mathbf{0}$.
- Este método es de convergencia lenta y requiere que la matriz \mathbf{A} sea **estrictamente diagonal dominante**, es decir que:

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|. \quad (11)$$

Métodos Iterativos Estacionarios

Método de Gauss–Seidel

- El segundo método surge de proponer que $\mathbf{M} = \mathbf{D} + \mathbf{L}$, denominado *Método de Gauss–Seidel*.
- En este caso partimos de $\mathbf{M} \cdot \mathbf{x}^{(i+1)} = \mathbf{M} \cdot \mathbf{x}^{(i)} - \mathbf{A} \cdot \mathbf{x}^{(i)} + \mathbf{B}$:

$$\begin{aligned}(\mathbf{D} + \mathbf{L}) \cdot \mathbf{x}^{(i+1)} &= (\mathbf{D} + \mathbf{L}) \cdot \mathbf{x}^{(i)} - (\mathbf{L} + \mathbf{D} + \mathbf{U}) \cdot \mathbf{x}^{(i)} + \mathbf{B}, \\ \mathbf{D} \cdot \mathbf{x}^{(i+1)} + \mathbf{L} \cdot \mathbf{x}^{(i+1)} &= (\mathbf{D} - \mathbf{D} + \mathbf{L} - \mathbf{L} - \mathbf{U}) \cdot \mathbf{x}^{(i)} + \mathbf{B}, \\ \mathbf{D} \cdot \mathbf{x}^{(i+1)} &= \mathbf{B} - \mathbf{L} \cdot \mathbf{x}^{(i+1)} - \mathbf{U} \cdot \mathbf{x}^{(i)} \Rightarrow \\ \mathbf{x}^{(i+1)} &= \mathbf{D}^{-1} \cdot (\mathbf{B} - \mathbf{L} \cdot \mathbf{x}^{(i+1)} - \mathbf{U} \cdot \mathbf{x}^{(i)}).\end{aligned}\tag{12}$$

- El método utiliza parte del nuevo vector $\mathbf{x}^{(i+1)}$ para calcular este vector en forma completa.

Métodos Iterativos Estacionarios

Método de Gauss–Seidel

- La formulación no matricial es:

$$x_j^{(i+1)} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} \cdot x_k^{(i+1)} - \sum_{k=j+1}^n a_{jk} \cdot x_k^{(i)} \right) \quad (13)$$

- Para poder aplicar el método debemos definir un $\mathbf{x}^{(0)}$.
- También suele usarse $\mathbf{x}^{(0)} = \mathbf{0}$.
- Converge más rápido que el *Método de Jacobi*, y también requiere que la matriz \mathbf{A} sea **estrictamente diagonal dominante**, aunque también converge si la matriz es definida positiva.

Métodos Iterativos Estacionarios

Método de las Sobrerrelajaciones Sucesivas

- Un tercer método surge de proponer que $\mathbf{M} = \frac{1}{\omega}\mathbf{D} + \mathbf{L}$, denominado *Método de las Sobrerrelajaciones Sucesivas (SOR)*.
- También partimos de $\mathbf{M} \cdot \mathbf{x}^{(i+1)} = \mathbf{M} \cdot \mathbf{x}^{(i)} - \mathbf{A} \cdot \mathbf{x}^{(i)} + \mathbf{B}$:

$$\begin{aligned} \left(\frac{1}{\omega}\mathbf{D} + \mathbf{L}\right) \cdot \mathbf{x}^{(i+1)} &= \left(\frac{1}{\omega}\mathbf{D} + \mathbf{L}\right) \cdot \mathbf{x}^{(i)} - (\mathbf{L} + \mathbf{D} + \mathbf{U}) \cdot \mathbf{x}^{(i)} + \mathbf{B}, \\ \frac{1}{\omega}\mathbf{D} \cdot \mathbf{x}^{(i+1)} + \mathbf{L} \cdot \mathbf{x}^{(i+1)} &= \left(\frac{1}{\omega}\mathbf{D} - \mathbf{D} + \mathbf{L} - \mathbf{L} - \mathbf{U}\right) \cdot \mathbf{x}^{(i)} + \mathbf{B}, \\ \frac{1}{\omega}\mathbf{D} \cdot \mathbf{x}^{(i+1)} &= \left(\frac{1}{\omega} - 1\right) \cdot \mathbf{D} \cdot \mathbf{x}^{(i)} + \mathbf{B} - \mathbf{L} \cdot \mathbf{x}^{(i+1)} - \mathbf{U} \cdot \mathbf{x}^{(i)} \Rightarrow \\ \mathbf{x}^{(i+1)} &= (1 - \omega) \cdot \mathbf{x}^{(i)} + \omega \cdot \mathbf{D}^{-1} \cdot (\mathbf{B} - \mathbf{L} \cdot \mathbf{x}^{(i+1)} - \mathbf{U} \cdot \mathbf{x}^{(i)}). \end{aligned} \tag{14}$$

- Este método también utiliza parte del nuevo vector $\mathbf{x}^{(i+1)}$ más un coeficiente ω para calcular este vector en forma completa.

Métodos Iterativos Estacionarios

Método de las Sobrerrelajaciones Sucesivas

- La formulación no matricial es:

$$x_j^{(i+1)} = (1 - \omega) \cdot x_j^{(i)} + \frac{\omega}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} \cdot x_k^{(i+1)} - \sum_{k=j+1}^n a_{jk} \cdot x_k^{(i)} \right) \quad (15)$$

- El valor de ω debe estar entre 0 y 2, es decir, $0 < \omega < 2$.
- En rigor, $1 < \omega < 2$. Cuando $0 < \omega < 1$, suele denominarse *Método de Jacobi Modificado*.
- El coeficiente ω logra que converja más rápido que los dos métodos vistos. Si la matriz es definida positiva también converge. Generalmente se toma $\omega = 1,25$.
- Si $\omega = 1$, se transforma en el *Método de Gauss–Seidel*.
- Puede extenderse la convergencia al caso de matrices \mathbf{A} simétricas definidas positivas.

Métodos Iterativos Estacionarios

Convergencia

- Para determinar la convergencia de los métodos estacionarios, analicemos la matriz \mathbf{T} .
- Supongamos que conocemos la solución «exacta» \mathbf{x} . Entonces tenemos que:

$$\begin{aligned}\mathbf{x} &= \mathbf{x}^{(i+1)} + \mathbf{e}^{(i+1)} = \mathbf{T} \cdot (\mathbf{x}^{(i)} + \mathbf{e}^{(i)}) + \mathbf{C}, \\ \mathbf{x}^{(i+1)} + \mathbf{e}^{(i+1)} &= \mathbf{T} \cdot \mathbf{x}^{(i)} + \mathbf{C} + \mathbf{T} \cdot \mathbf{e}^{(i)}, \\ \mathbf{e}^{(i+1)} &= \mathbf{T} \cdot \mathbf{e}^{(i)} = \mathbf{T} \cdot \mathbf{T} \cdot \mathbf{e}^{(i-1)} = \mathbf{T} \cdot \mathbf{T} \cdot \mathbf{T} \cdot \mathbf{e}^{(i-2)} = \dots = \mathbf{T}^{i+1} \cdot \mathbf{e}^{(0)}.\end{aligned}\tag{16}$$

- Si queremos que el error $\mathbf{e}^{(i+1)}$ sea menor que el error $\mathbf{e}^{(0)}$, entonces se debe cumplir que:

$$\|\mathbf{T}\|_{\infty} < 1.\tag{17}$$

Métodos Iterativos Estacionarios

Convergencia

- Para el *Método de Jacobi* se debe cumplir que:

$$\|\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\|_{\infty} < 1. \quad (18)$$

- Eso significa que:

$$\sum_{\substack{j=1 \\ j \neq i}}^n \frac{|a_{ij}|}{|a_{ii}|} < 1 \quad \text{para } i \in (1, n), \quad (19)$$

es decir,

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}| \quad \text{para } i \in (1, n), \quad (11)$$

expresión que define a una **matriz estrictamente diagonal dominante**.

Métodos Iterativos Estacionarios

Convergencia

- Hay varios teoremas que aseguran las condiciones de convergencia.
- Uno asegura la convergencia del *Método de las Sobrerrelaciones Sucesivas* cuando \mathbf{A} es *definida positiva*.
- Otros aseguran la convergencia para tipos especiales de matrices.
- Como todo método iterativo, requieren criterios de corte.
- Se usan dos:

- ① El error absoluto:

$$\|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\|_{\infty} \leq \text{Tol.}$$

- ② El error relativo:

$$\frac{\|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\|_{\infty}}{\|\mathbf{x}^{(n)}\|_{\infty}} \leq \text{Tol.}$$

Métodos Iterativos No Estacionarios

- Existe otro tipo de métodos iterativos.
- Son los *Métodos Iterativos No Estacionarios*.
- Los obtenemos con la ecuación ya vista:

$$\mathbf{x}^{(i+1)} = (\mathbf{I} - \mathbf{M}^{-1} \cdot \mathbf{A}) \cdot \mathbf{x}^{(i)} + \mathbf{M}^{-1} \cdot \mathbf{B}. \quad (4)$$

al proponer la siguiente matriz:

$$\mathbf{M} = \frac{1}{\alpha} \cdot \mathbf{I}.$$

- Al reemplazarla en (4), tenemos:

$$\begin{aligned} \mathbf{x}^{(i+1)} &= (\mathbf{I} - \alpha \cdot \mathbf{I} \cdot \mathbf{A}) \cdot \mathbf{x}^{(i)} + \alpha \cdot \mathbf{I} \cdot \mathbf{B}, \\ &= \mathbf{x}^{(i)} + \alpha \cdot \underbrace{(\mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(i)})}_{\mathbf{R}^{(i)}} \Rightarrow \boxed{\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \alpha \cdot \mathbf{R}^{(i)}}. \end{aligned} \quad (20)$$

- El modelo depende de α .

Método Iterativos No Estacionarios

Método de los Residuos Mínimos

- El primer método a partir de esta matriz \mathbf{M} se denomina *Método de los Residuos Mínimos* o *Método del Mínimo Residuo*.
- Para hallar este nuevo procedimiento, vamos a analizar el residuo en la iteración $\langle i + 1 \rangle$:

$$\begin{aligned}\mathbf{R}^{\langle i+1 \rangle} &= \mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{\langle i+1 \rangle} = \mathbf{B} - \mathbf{A} \cdot (\mathbf{x}^{\langle i \rangle} + \alpha \cdot \mathbf{R}^{\langle i \rangle}), \\ \mathbf{R}^{\langle i+1 \rangle} &= \mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{\langle i \rangle} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{\langle i \rangle}, \\ \mathbf{R}^{\langle i+1 \rangle} &= \mathbf{R}^{\langle i \rangle} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{\langle i \rangle}.\end{aligned}\tag{21}$$

- Hemos obtenido una relación entre dos residuos: $\mathbf{R}^{\langle i+1 \rangle}$ y $\mathbf{R}^{\langle i \rangle}$.
- Para lograr que $\mathbf{R}^{\langle i+1 \rangle}$ sea menor a $\mathbf{R}^{\langle i \rangle}$, vamos a analizar las normas euclídeas de ambos, de forma que

$$\|\mathbf{R}^{\langle i+1 \rangle}\|_2 < \|\mathbf{R}^{\langle i \rangle}\|_2.\tag{22}$$

Método Iterativos No Estacionarios

Método de los Residuos Mínimos

- Para ello vamos a buscar que:

$$\left\| \mathbf{R}^{(i)} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{(i)} \right\|_2 < \left\| \mathbf{R}^{(i)} \right\|_2. \quad (23)$$

- Existen muchas posibilidad para que se cumpla la expresión (23). Buscaremos aquella que haga que $\mathbf{R}^{(i+1)}$ sea mínima.
- Para ello vamos a proponer lo siguiente:

$$\frac{d \left\| \mathbf{R}^{(i+1)} \right\|_2}{d\alpha} = \frac{d \left\| \mathbf{R}^{(i)} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{(i)} \right\|_2}{d\alpha} = 0 \quad (24)$$

- En rigor, resolveremos:

$$\frac{d \left\| \mathbf{R}^{(i)} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{(i)} \right\|_2^2}{d\alpha} = 0 \quad (25)$$

Método Iterativos No Estacionarios

Método de los Residuos Mínimos

- Si derivamos vectorialmente, obtenemos:

$$\begin{aligned}2 \cdot [\mathbf{A} \cdot \mathbf{R}^{(i)}]^T \cdot [\mathbf{R}^{(i)} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}] &= 0, \\ [\mathbf{A} \cdot \mathbf{R}^{(i)}]^T \cdot \mathbf{R}^{(i)} &= \alpha \cdot [\mathbf{A} \cdot \mathbf{R}^{(i)}]^T \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}, \\ \alpha_i &= \frac{[\mathbf{A} \cdot \mathbf{R}^{(i)}]^T \cdot \mathbf{R}^{(i)}}{[\mathbf{A} \cdot \mathbf{R}^{(i)}]^T \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}}.\end{aligned}\tag{26}$$

- El coeficiente α se modifica en cada iteración $\langle i \rangle$, es decir, tenemos un α_i para cada iteración.
- Para que el *Método de los Residuos Mínimos* converja, la matriz \mathbf{A} debe ser *definida positiva*.
- Esto asegura obtener un mínimo.

Método Iterativos No Estacionarios

Método de los Residuos Mínimos

- El método completo es el siguiente:

$$\mathbf{R}^{(0)} = \mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(0)},$$

$$\alpha_i = \frac{\mathbf{R}^{(i)T} \cdot \mathbf{A}^T \cdot \mathbf{R}^{(i)}}{\mathbf{R}^{(i)T} \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}}, \quad (27)$$

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \alpha_i \cdot \mathbf{R}^{(i)},$$

$$\mathbf{R}^{(i+1)} = \mathbf{R}^{(i)} - \alpha_i \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}$$

- La convergencia, aún cuando la matriz sea s.d.p., es lenta.
- Analicemos un nuevo método.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Un método más eficiente es el conocido como *Método del Descenso Más Rápido* o *del Descenso Más Empinado*.
- Para obtenerlo, tomemos la siguiente función:

$$F(\mathbf{x}) = \frac{1}{2} \cdot \mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} - \mathbf{x}^T \cdot \mathbf{B} + C. \quad (28)$$

- Esta función se conoce como *forma cuadrática*, equivalente a una función cuadrática en una dimensión.
- Podemos calcular su mínimo si hacemos:

$$\frac{dF(\mathbf{x})}{d\mathbf{x}} = \frac{1}{2} \cdot \mathbf{A}^T \cdot \mathbf{x} + \frac{1}{2} \cdot \mathbf{A} \cdot \mathbf{x} - \mathbf{B} = 0 \quad (29)$$

- Para este método es necesario que la matriz \mathbf{A} sea simétrica, además de definida positiva.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Con esta condición nos queda:

$$\frac{dF(\mathbf{x})}{d\mathbf{x}} = \mathbf{A} \cdot \mathbf{x} - \mathbf{B} = 0, \quad (30)$$

que resulta ser nuestro *Sistema de Ecuaciones Lineales* escrito de otra forma.

- Pero la ecuación (30) también representa otra cosa:

$$\frac{dF(\mathbf{x})}{d\mathbf{x}} = F'(\mathbf{x}) = \text{grad } F(\mathbf{x}) = \begin{bmatrix} \frac{\partial F(\mathbf{x})}{\partial x_1} \\ \vdots \\ \frac{\partial F(\mathbf{x})}{\partial x_n} \end{bmatrix}. \quad (31)$$

- Podemos escribir lo siguiente:

$$-F'(\mathbf{x}) = \mathbf{B} - \mathbf{A} \cdot \mathbf{x}. \quad (32)$$

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Finalmente, también tenemos que:

$$-F'(\mathbf{x}^{(i)}) = \mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(i)} = \mathbf{R}^{(i)}. \quad (33)$$

- Este nuevo método también parte de:

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \alpha \cdot \mathbf{R}^{(i)}. \quad (20)$$

- Nuevamente, buscaremos que $\mathbf{R}^{(i+1)}$ sea el menor posible, el mínimo.
- Entonces:

$$\frac{dF(\mathbf{x}^{(i+1)})}{d\alpha} = F'(\mathbf{x}^{(i+1)})^T \frac{d\mathbf{x}^{(i+1)}}{d\alpha} = F'(\mathbf{x}^{(i+1)})^T \cdot \mathbf{R}^{(i)} = -\mathbf{R}^{(i+1)T} \cdot \mathbf{R}^{(i)} = 0. \quad (34)$$

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Si reemplazamos $\mathbf{R}^{(i+1)}$ por $\mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(i+1)}$ en (34), nos queda:

$$[\mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(i+1)}]^T \cdot \mathbf{R}^{(i)} = 0. \quad (35)$$

- Pero por (20) tenemos:

$$[\mathbf{B} - \mathbf{A} \cdot (\mathbf{x}^{(i)} + \alpha \cdot \mathbf{R}^{(i)})]^T \cdot \mathbf{R}^{(i)} = 0. \quad (36)$$

que podemos escribir así:

$$(\mathbf{R}^{(i)} - \alpha \cdot \mathbf{A} \cdot \mathbf{R}^{(i)})^T \cdot \mathbf{R}^{(i)} = \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)} - \alpha \cdot (\mathbf{A} \cdot \mathbf{R}^{(i)})^T \cdot \mathbf{R}^{(i)} = 0. \quad (37)$$

- Si despejamos α , nos queda:

$$\alpha_i = \frac{\mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)}}{(\mathbf{A} \cdot \mathbf{R}^{(i)})^T \cdot \mathbf{R}^{(i)}} = \frac{\mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)}}{\mathbf{R}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}}. \quad (38)$$

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- El nuevo método completo es:

$$\begin{aligned}\mathbf{R}^{(0)} &= \mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(0)}, \\ \alpha_i &= \frac{\mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)}}{\mathbf{R}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}}, \\ \mathbf{x}^{(i+1)} &= \mathbf{x}^{(i)} + \alpha_i \cdot \mathbf{R}^{(i)}, \\ \mathbf{R}^{(i+1)} &= \mathbf{R}^{(i)} - \alpha_i \cdot \mathbf{A} \cdot \mathbf{R}^{(i)}\end{aligned}\tag{39}$$

- Este método converge algo más rápido que el *Método de los Residuos Mínimos* pero sigue siendo relativamente lento.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Veamos una muestra mediante representaciones gráficas.
- Primero representemos una *forma cuadrática* para un $\mathbf{x} = (x_1, x_2)$.




Figura: Forma cuadrática.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- En un punto determinado, podemos obtener el gradiente y su plano tangente.




Figura: Forma cuadrática y plano tangente en un punto.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Para acercarnos al mínimo de $F(x)$, podemos elegir cualquier dirección contenida en el plano tangente.





Figura: Forma cuadrática y plano tangente en un punto (2).


Método Iterativos No Estacionarios

Método del Descenso Más Rápido


- Con varias iteraciones, obtenemos lo siguiente:




(a)



(b)



(c)



(d)

Figura: Método del Descenso Más Rápido.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- En el punto mínimo el plano tangente debe ser horizontal:




Figura: Método del Descenso Más Rápido. Mínimo y plano tangente.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- El método solamente determina las direcciones de aproximación considerando que estén contenidas en los planos tangentes (gradientes).
- Tengamos en cuenta que $\mathbf{x}^{(i)}$ y $\mathbf{R}^{(i)}$ son vectores.

- Al hacer

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \alpha_i \cdot \mathbf{R}^{(i)},$$

estamos sumando vectores.

- La lentitud se debe a que el método repite las direcciones en el proceso iterativo, es decir, usa varias veces algunas direcciones de aproximación.
- Debemos buscar una forma de no repetir direcciones.

Método Iterativos No Estacionarios

Método del Descenso Más Rápido

- Primera idea: optimizar los gradientes obtenidos en las sucesivas aproximaciones y no repetir direcciones.
- Segunda idea: buscar direcciones ortogonales y evitar repeticiones.
- Problema: buscar direcciones ortogonales limitaría la aplicación de dicho método.



Figura: Direcciones ortogonales.

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Pronodremos un nuevo método denominado *Método de los Gradiente Conjugados*.
- Vamos a definir una nueva aproximación:

$$\mathbf{x}^{(i+1)} = \mathbf{x}^{(i)} + \alpha_i \cdot \mathbf{d}^{(i)} \quad (40)$$

- En vez de que los vectores $\mathbf{d}^{(i)}$ sean ortogonales, es decir, que

$$\mathbf{d}^{(i)T} \cdot \mathbf{d}^{(i)} = 0, \quad (41)$$

propondremos lo siguiente:

$$\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} = 0, \quad (42)$$

- Esta condición se denomina *direcciones conjugadas*.

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Con la misma expresión usada para el *Método del Descenso Más Rápido* pero con la dirección $\mathbf{d}^{(i)}$, tenemos:

$$F'(\mathbf{x}^{(i+1)})^T \cdot \mathbf{d}^{(i)} = -\mathbf{R}^{(i+1)T} \cdot \mathbf{d}^{(i)} = [\mathbf{B} - \mathbf{A} \cdot (\mathbf{x}^{(i)} + \alpha \cdot \mathbf{d}^{(i)})]^T \cdot \mathbf{d}^{(i)} = 0 \quad (43)$$

- Al desarrollar nos queda:

$$(\mathbf{R}^{(i)} - \alpha \cdot \mathbf{A} \cdot \mathbf{d}^{(i)})^T \cdot \mathbf{d}^{(i)} = \mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)} - \alpha \cdot (\mathbf{A} \cdot \mathbf{d}^{(i)})^T \cdot \mathbf{d}^{(i)} = 0 \quad (44)$$

- Al despejar α obtenemos:

$$\alpha_i = \frac{\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)}}{(\mathbf{A} \cdot \mathbf{d}^{(i)})^T \cdot \mathbf{d}^{(i)}} = \frac{\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}} \quad (45)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Todavía nos falta encontrar las direcciones $\mathbf{d}^{(i)}$.
- Debemos obtener un conjunto de direcciones $\mathbf{d}^{(0)}, \mathbf{d}^{(1)}, \dots, \mathbf{d}^{(n)}$, que sean conjugadas y obtenidas a partir de los $\mathbf{R}^{(i)}$.
- A tener en cuenta: proceso de *Gram-Schmidt* para obtener una base ortogonal con los vectores $\mathbf{d}^{(i)}$:

$$\mathbf{d}^{(i)} = \mathbf{u}^{(i)} + \sum_{j=0}^{i-1} \beta_{ij} \cdot \mathbf{d}^{(j)}.$$

- El planteo es mediante *direcciones conjugadas*:

$$\mathbf{d}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} = \mathbf{u}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} + \sum_{j=0}^i \beta_{i+1j} \cdot \mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} = 0 \quad (46)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Para obtener el coeficiente β_{i+1j} planteamos:

$$\mathbf{d}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} = \mathbf{u}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} + \sum_{j=0}^i \beta_{i+1j} \cdot \mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(j)} = 0 \quad (47)$$

de la que obtenemos:

$$\mathbf{u}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} + \beta_{i+1i} \cdot \mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} = 0. \quad (48)$$

- Si despejamos β_{i+1i} :

$$\beta_{i+1i} = -\frac{\mathbf{u}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}} = -\frac{\mathbf{R}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}. \quad (49)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Vimos previamente que

$$\mathbf{R}^{(i+1)T} \cdot \mathbf{d}^{(i)} = 0,$$

que podemos escribir en forma genérica como

$$\mathbf{d}^{(i)T} \cdot \mathbf{R}^{(j)} = 0,$$

- Entonces podemos proponer lo siguiente:

$$\mathbf{d}^{(i)T} \cdot \mathbf{R}^{(j)} = \mathbf{u}^{(i)T} \cdot \mathbf{R}^{(j)} + \sum_{k=0}^i \beta_{ik} \cdot \mathbf{d}^{(k)T} \cdot \mathbf{R}^{(j)} = 0. \quad (50)$$

- Como $\mathbf{d}^{(k)T} \cdot \mathbf{R}^{(j)} = 0$, nos queda:

$$\mathbf{u}^{(i)T} \cdot \mathbf{R}^{(j)} = 0 \quad \text{para todo } i < j \quad (51)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- En función de lo anterior, se cumple:

$$\mathbf{d}^{(i)T} \cdot \mathbf{R}^{(i)} = \mathbf{u}^{(i)T} \cdot \mathbf{R}^{(i)}. \quad (52)$$

- Podemos tomar $\mathbf{u}^{(j)} = \mathbf{R}^{(j)}$.
- Con esto, para un $\mathbf{R}^{(j+1)}$ tenemos:

$$\begin{aligned} \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(j+1)} &= \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(j)} - \alpha_j \cdot \mathbf{R}^{(i)T} \cdot A \cdot \mathbf{d}^{(j)}, \\ \alpha_j \cdot \mathbf{R}^{(i)T} \cdot A \cdot \mathbf{d}^{(j)} &= \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(j)} - \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(j+1)}, \\ \mathbf{R}^{(i)T} \cdot A \cdot \mathbf{d}^{(j)} &= \frac{1}{\alpha_j} \cdot (\mathbf{R}^{(i)T} \cdot \mathbf{R}^{(j)} - \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(j+1)}). \end{aligned} \quad (53)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- De la expresión anterior podemos establecer que:

$$\mathbf{R}^{\langle i \rangle T} \cdot A \cdot \mathbf{d}^{\langle j \rangle} = \begin{cases} \frac{1}{\alpha_j} \cdot \mathbf{R}^{\langle i \rangle T} \cdot \mathbf{R}^{\langle i \rangle} & \text{para } i = j \\ -\frac{1}{\alpha_j} \cdot \mathbf{R}^{\langle j+1 \rangle T} \cdot \mathbf{R}^{\langle j+1 \rangle} & \text{para } i = j + 1 (\leftarrow) \\ 0 & \text{para el resto de los casos.} \end{cases} \quad (54)$$

- Si el caso $\langle j + 1 \rangle$ lo convertimos en $\langle i + 1 \rangle$, nos queda:

$$\mathbf{R}^{\langle i+1 \rangle T} \cdot A \cdot \mathbf{d}^{\langle i \rangle} = -\frac{1}{\alpha_i} \cdot \mathbf{R}^{\langle i+1 \rangle T} \cdot \mathbf{R}^{\langle i+1 \rangle} \quad (55)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- De lo desarrollado anteriormente, tenemos:

$$\alpha_i = \frac{\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}. \quad (45)$$

$$\beta_{i+1 i} = -\frac{\mathbf{R}^{(i+1)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}. \quad (49)$$

- Si reemplazamos (55) en (49) nos queda:

$$\beta_{i+1 i} = \frac{1}{\alpha_i} \frac{\mathbf{R}^{(i+1)T} \cdot \mathbf{R}^{(i+1)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}. \quad (56)$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Y si reemplazamos (45) en (56) queda:

$$\beta_{i+1} = \frac{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)} \mathbf{R}^{(i+1)T} \cdot \mathbf{R}^{(i+1)}}{\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)} \mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}. \quad (57)$$

- Al simplificar considerar que en realidad solo necesitamos el caso β_{i+1} , nos queda:

$$\beta_{i+1} = \frac{\mathbf{R}^{(i+1)T} \cdot \mathbf{R}^{(i+1)}}{\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)}} = \frac{\mathbf{R}^{(i+1)T} \cdot \mathbf{R}^{(i+1)}}{\mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)}} \quad (58)$$

pues

$$\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)} = \mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)}.$$

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- El *Método de los Gradientes Conjugados* queda así:


$$\begin{aligned} \mathbf{d}^{(0)} &= \mathbf{R}^{(0)} = \mathbf{B} - \mathbf{A} \cdot \mathbf{x}^{(0)}, \\ \alpha_i &= \frac{\mathbf{R}^{(i)T} \cdot \mathbf{d}^{(i)}}{\mathbf{d}^{(i)T} \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}}, \\ \mathbf{x}^{(i+1)} &= \mathbf{x}^{(i)} + \alpha_i \cdot \mathbf{d}^{(i)}, \\ \mathbf{R}^{(i+1)} &= \mathbf{R}^{(i)} - \alpha_i \cdot \mathbf{A} \cdot \mathbf{d}^{(i)}, \\ \beta_{i+1} &= \frac{\mathbf{R}^{(i+1)T} \cdot \mathbf{R}^{(i+1)}}{\mathbf{R}^{(i)T} \cdot \mathbf{R}^{(i)}}, \\ \mathbf{d}^{(i+1)} &= \mathbf{R}^{(i+1)} + \beta_{i+1} \cdot \mathbf{d}^{(i)}. \end{aligned} \tag{59}$$

- Es un poderoso método para resolver sistemas de ecuaciones lineales con matrices ralas simétricas definidas positivas.


Método Iterativos No Estacionarios

Método de los Gradientes Conjugados


- Si partimos del mismo punto que usamos con el *Método del Descenso Más Rápido*, obtenemos nuestros resultados en dos iteraciones:



(a)



(b)



(c)

Figura: Método de los Gradientes Conjugados.

Método Iterativos No Estacionarios

Método de los Gradientes Conjugados

- Vemos que la convergencia fue casi «instantánea».
- Se demuestra que si no hubieran errores de redondeo, la convergencia se da en « n » iteraciones, siendo « n » el rango de la matriz.
- Más aún, la velocidad de convergencia depende casi exclusivamente de la cantidad de autovalores distintos que tenga la matriz \mathbf{A} .
- Si la matriz tiene, por ejemplo, « k » autovalores repetidos, entonces la convergencia será en « $n - k$ » iteraciones.
- En las últimas décadas, se han desarrollado numerosos métodos a partir del *Método de los Gradientes Conjugados* para resolver *Sistemas de Ecuaciones Lineales Ralos* de cualquier tipo.

Resumen

- **Método de Jacobi:** converge cuando la matriz es estrictamente diagonal dominante.
- **Método de Gauss-Seidel:** similar al *Método de Jacobi*. Además converge cuando la matriz \mathbf{A} es simétrica definida positiva (SPD).
- **Método de las Sobrerrelajaciones Sucesivas:** converge cuando la matriz \mathbf{A} es SPD pero no es fácil obtener el ω que optimiza la convergencia.
- **Método de los Residuos Mínimos:** converge cuando la matriz \mathbf{A} es definida positiva. Rapidez similar a Jacobi.
- **Método del Descenso Más Rápido:** sólo para sistemas s.p.d. Suele ser equivalente en rapidez a Gauss-Seidel.
- **Método de los Gradientes Conjugados:** solo para sistemas s.d.p.; gran rapidez de convergencia; si la matriz \mathbf{A} tiene « k » autovalores repetidos, converge en « $n - k$ » iteraciones. Muy usado para resolver grandes sistemas de ecuaciones lineales.

Bibliografía

-  Burden, R. L., Faires, J. D. & Burden, A. M.
Análisis Numérico.
Décima Edición. CENGAGE Learning, 2016.
-  Samarski, A. A.
Introducción a los métodos numéricos.
Editorial Mir. 1986.
-  Saad, Y.
Iterative Methods for Sparse Linear Systems.
Society for Industrial and Applied Mathematics. Second Edition, 2003.
-  Schwarz, R.
Resumen de clases.