

# **MÉTODOS ITERATIVOS PARA SISTEMAS LINEALES**

ALAN REYES-FIGUEROA  
MÉTODOS NUMÉRICOS II

(AULA 10) 08.AGOSTO.2023

# Refinamiento Iterativo

El **refinamiento iterativo** es una técnica para mejorar la precisión en la solución de un sistema lineal  $\mathbf{Ax} = \mathbf{b}$ , hallada por un método directo.

Suponga que el sistema lineal  $\mathbf{Ax} = \mathbf{b}$  ha sido resuelto mediante factoración  $LU$  (con pivoteo parcial o completo), y sea  $\mathbf{x}^{(0)} \in \mathbb{R}^n$  la solución calculada. Habiendo fijado una tolerancia de error,  $tol$ , el refinamiento iterativo se realiza de la siguiente manera:

**Algoritmo:** (Refinamiento iterativo, FPR):

While end condition doesn't hold.

    Compute the residual  $\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{Ax}^{(k)}$ ,

    Solve the system  $\mathbf{Az} = \mathbf{r}^{(k)}$ ,

    Update the solution  $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \mathbf{z}$ ,

Los términos  $\mathbf{r}^{(k)}$  se denominan residuos. En ausencia de errores de redondeo, el proceso se detendría en el primer paso, dando como resultado la solución exacta.

A este procedimiento lo llamamos refinamiento iterativo de precisión simple o fija (FRP), aunque existen mejoras como el refinamiento iterativo de precisión mixta (MPR).

# Métodos Iterativos

Una técnica iterativa para resolver el sistema lineal  $\mathbf{Ax} = \mathbf{b}$ , con  $A \in \mathbb{R}^{n \times n}$ ,  $\mathbf{x}, \mathbf{b} \in \mathbb{R}^n$ , comienza con una aproximación  $\mathbf{x}^{(0)}$  de  $\mathbf{x}$ , y genera una secuencia de aproximaciones  $\{\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots\} \subset \mathbb{R}^n$  tal que  $\mathbf{x}^{(k)} \rightarrow \mathbf{x}$ .

Estas técnicas transforman el sistema  $\mathbf{Ax} = \mathbf{b}$  en un sistema equivalente  $\mathbf{x} = T\mathbf{x} + \mathbf{c}$ ,  $T \in \mathbb{R}^{n \times n}$ ,  $\mathbf{c} \in \mathbb{R}^n$ . Usualmente se obtiene este sistema equivalente buscando alguna forma de “despejar” la  $\mathbf{x}$  en el sistema original. Luego, se aproxima la solución mediante la secuencia

$$\mathbf{x}^{(k+1)} = T\mathbf{x}^{(k)} + \mathbf{c}, \quad k = 0, 1, 2, \dots \quad (1)$$

Para estudiar la convergencia de estas técnicas de iteración, necesitamos analizar la fórmula (1), con  $\mathbf{x}^{(0)}$  arbitrario.

Recordemos que una matriz  $T \in \mathbb{R}^{n \times n}$  es **convergente** si  $T^k \rightarrow \mathbf{0}$ .

**Lema** Sea  $T \in \mathbb{R}^{n \times n}$ . Si el radio espectral  $\rho(T) < 1$ , entonces  $(I - T)^{-1}$  existe y

$$(I - T)^{-1} = I + T + T^2 + T^3 + \dots = \sum_{k \geq 0} T^k.$$

# Métodos Iterativos

Prueba: Observe que para cualquier autovalor  $\lambda$  de  $T$ ,  $1 - \lambda$  es autovalor de  $I - T$ , pues

$$T\mathbf{x} = \lambda\mathbf{x} \Rightarrow (I - T)\mathbf{x} = \mathbf{x} - T\mathbf{x} = \mathbf{x} - \lambda\mathbf{x} = (1 - \lambda)\mathbf{x}.$$

Como  $|\lambda| \leq \rho(T) < 1$ , entonces  $|1 - \lambda| > ||1| - |\lambda|| = 1 - |\lambda| > 0$ . Así, ningún autovalor de  $I - T$  es cero, y  $I - T$  es no singular, y la inversa  $(I - T)^{-1}$  existe.

Por otro lado,  $\rho(T) < 1$  implica que  $T$  es convergente y  $\lim T^k = \mathbf{0}$ .

Sea  $S_m = I + T + T^2 + \dots + T^m$ . Entonces

$$(I - T)S_m = (I - T)(I + T + T^2 + \dots + T^m) = I - T^{m+1},$$

y como  $T$  es convergente, entonces

$$(I - T) \lim_{m \rightarrow \infty} S_m = \lim_{m \rightarrow \infty} (I - T)S_m = \lim_{m \rightarrow \infty} (I - T^{m+1}) = \lim_{m \rightarrow \infty} I - \underbrace{\lim_{m \rightarrow \infty} T^{m+1}}_{=0} = I.$$

Portanto,  $(I - T)^{-1} = \lim_{m \rightarrow \infty} S_m = \sum_{k \geq 0} T^k$ .  $\square$

# Métodos Iterativos

**Teorema** Para cualquier  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ , la secuencia  $\{\mathbf{x}^{(k)}\}_{k \geq 0}$  definida por

$$\mathbf{x}^{(k+1)} = T\mathbf{x}^{(k)} + \mathbf{c}, \quad k = 0, 1, 2, \dots, \text{ y } \mathbf{c} \neq \mathbf{0}, \quad (2)$$

converge a la solución única de  $\mathbf{x} = T\mathbf{x} + \mathbf{c}$  si, y sólo si,  $\rho(T) < 1$ .

Prueba: De (2), para todo  $k \in \mathbb{N}$  obtenemos

$$\begin{aligned} \mathbf{x}^{(k)} &= T\mathbf{x}^{(k-1)} + \mathbf{c} = T(T\mathbf{x}^{(k-2)} + \mathbf{c}) + \mathbf{c} = T^2\mathbf{x}^{(k-2)} + (T + I)\mathbf{c} \\ &= T^2(T\mathbf{x}^{(k-3)} + \mathbf{c}) + \mathbf{c} = T^3\mathbf{x}^{(k-3)} + (T^2 + T + I)\mathbf{c} \\ &= \dots \\ &= T^k\mathbf{x}^{(0)} + (T^{k-1} + \dots + T^2 + T + I)\mathbf{c}. \end{aligned}$$

( $\Leftarrow$ ) Si  $\rho(T) < 1$ , entonces  $T$  es convergente y  $\lim_k T^k = \mathbf{0}$ . Luego,

$$\mathbf{x}^* = \lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \lim_{k \rightarrow \infty} T^k\mathbf{x}^{(0)} + \lim_{k \rightarrow \infty} \left( \sum_{j=0}^{k-1} T^j \right) \mathbf{c} = \left( \lim_{k \rightarrow \infty} T^k \right) \mathbf{x}^{(0)} + (I - T)^{-1} \mathbf{c} = (I - T)^{-1} \mathbf{c}.$$

Así,  $(I - T)\mathbf{x}^* = \mathbf{c} \Rightarrow \mathbf{x}^* = T\mathbf{x}^* + \mathbf{c}$ , y  $\mathbf{x}^{(k)}$  converge a la única solución de (2).

# Métodos Iterativos

( $\Rightarrow$ ) Sea  $\mathbf{x}^*$  la solución de  $\mathbf{x} = T\mathbf{x} + \mathbf{c}$ , y suponga que  $\mathbf{x}^{(k)} \rightarrow \mathbf{x}^*$ . Para todo  $k \geq 0$  vale

$$\mathbf{x}^* - \mathbf{x}^{(k)} = T(\mathbf{x}^* - \mathbf{x}^{(k-1)}) = T^2(\mathbf{x}^* - \mathbf{x}^{(k-2)}) = \dots = T^k(\mathbf{x}^* - \mathbf{x}^{(0)}). \quad (3)$$

Sea  $\mathbf{z} \in \mathbb{R}^n$  arbitrario. Haciendo  $\mathbf{x}^{(0)} = \mathbf{x}^* - \mathbf{z}$ , resulta

$$\lim_{k \rightarrow \infty} T^k \mathbf{z} = \lim_{k \rightarrow \infty} T^k(\mathbf{x}^* - \mathbf{x}^{(0)}) = \lim_{k \rightarrow \infty} (\mathbf{x}^* - \mathbf{x}^{(k)}) = \mathbf{x}^* - \lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \mathbf{0}.$$

Esto equivale a tener  $\rho(T) < 1$ .  $\square$

**Observaciones:** Si  $\|T\| < 1$  para alguna norma matricial, entonces la ecuación (3) nos produce fórmulas para medir el error del  $k$ -ésimo iterado  $\mathbf{x}^{(k)}$  con respecto a la solución exacta  $\mathbf{x}^*$ :

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq \|T\|^k \|\mathbf{x}^{(0)} - \mathbf{x}^*\|, \quad (4)$$

$$\|\mathbf{x}^{(k)} - \mathbf{x}^*\| \leq \frac{\|T\|^k}{1 - \|T\|} \|\mathbf{x}^{(1)} - \mathbf{x}^{(0)}\|. \quad (5)$$

# Métodos Iterativos

Una técnica general para diseñar métodos iterativos lineales se basa en una descomposición aditiva de  $A$ , en la forma  $A = P - N$ , con  $P$  no singular.  $P$  se llama **matriz de preconditionamiento** o **precondicionador**.

Dado  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ , se puede calcular la secuencia  $\{\mathbf{x}^{(k)}\}$  para  $k \geq 1$ , resolviendo

$$P\mathbf{x}^{(k+1)} = N\mathbf{x}^{(k)} + \mathbf{b}, \quad k \geq 0. \quad (6)$$

La matriz de iteración en (6) es  $T = P^{-1}N$ , mientras que  $\mathbf{c} = P^{-1}\mathbf{b}$ . Alternativamente, (6) puede escribirse en la forma

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + P^{-1}\mathbf{r}^{(k)}, \quad k \geq 0. \quad (7)$$

donde  $\mathbf{r}^{(k)} = \mathbf{b} - A\mathbf{x}^{(k)}$  es el vector residual en el paso  $k$ .

- $P$  debe ser no singular,
- Además,  $P$  debería ser fácilmente invertible, para mantener bajo el costo computacional general.
- Si  $P = A$  y  $N = \mathbf{0}$ , (6) convergería en una iteración, pero en el mismo costo de un método directo).

# Métodos Iterativos

Mencionamos dos resultados que aseguran la convergencia de la iteración (6).

## Propiedad

Sea  $A = P - N$ , con  $A$  y  $P$  simétricas y positivas definidas. Si la matriz  $2P - A = N + P$  es positiva definida, entonces el método iterativo definido en (6) converge para cualquier elección del dato inicial  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ , y

$$\rho(T) = \|T\|_A = \|T\|_P < 1.$$

Además, la convergencia de la iteración es monótona con respecto a las normas  $\|\cdot\|_P$  y  $\|\cdot\|_A$  (es decir,  $\|\mathbf{e}^{(k+1)}\|_P < \|\mathbf{e}^{(k)}\|_P$  y  $\|\mathbf{e}^{(k+1)}\|_A < \|\mathbf{e}^{(k)}\|_A$ , para  $k = 0, 1, 2, \dots$ ).

## Propiedad

Sea  $A = P - N$ , con  $A$  simétrica y positiva definida. Si la matriz  $P + P^T - A$  es positiva definida, entonces  $P$  es invertible, el método iterativo en (6) es monótonamente convergente con respecto a la norma  $\|\cdot\|_A$ , para cualquier  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ , y

$$\rho(T) \leq \|T\|_A < 1.$$

# Método de Jacobi

Considere el sistema lineal  $A\mathbf{x} = \mathbf{b}$ , con  $A \in \mathbb{R}^{n \times n}$ ,  $\mathbf{x}, \mathbf{b} \in \mathbb{R}^n$ . El **método de JACOBI** es un método iterativo que parte de descomponer la matriz  $A$  como una suma  $A = -L + D - U$ ,

$$A = - \underbrace{\begin{pmatrix} -a_{21} & & & \\ \vdots & \ddots & & \\ -a_{n1} & \cdots & -a_{n,n-1} \end{pmatrix}}_L + \underbrace{\begin{pmatrix} a_{11} & & & \\ & a_{22} & & \\ & & \ddots & \\ & & & a_{nn} \end{pmatrix}}_D - \underbrace{\begin{pmatrix} -a_{12} & \cdots & -a_{1n} \\ & \ddots & \vdots \\ & & -a_{n-1,n} \end{pmatrix}}_U.$$

Entonces, el sistema  $A\mathbf{x} = \mathbf{b}$  puede escribirse como

$$(-L + D - U)\mathbf{x} = -L\mathbf{x} + D\mathbf{x} - U\mathbf{x} = \mathbf{b} \quad \Rightarrow \quad D\mathbf{x} = (L + U)\mathbf{x} + \mathbf{b}.$$

Si  $D^{-1}$  existe, entonces

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

y hemos escrito el sistema en la forma  $\mathbf{x} = T_j\mathbf{x} + \mathbf{c}_j$ , donde  $T_j = D^{-1}(L + U)$  y  $\mathbf{c}_j = D^{-1}\mathbf{b}$ .

# Método de Jacobi

**Algoritmo:** (Método de JACOBI).

*Inputs:*  $A \in \mathbb{R}^{n \times n}$  no-singular y diagonal dominante,  $\mathbf{b} \in \mathbb{R}^n$ ,  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ .

*Outputs:*  $\mathbf{x} \in \mathbb{R}^n$ , solución del sistema  $A\mathbf{x} = \mathbf{b}$ .

Initialize  $\mathbf{x} = \mathbf{x}^{(0)}$ .

while end conditions doesn't hold:

  for  $i = 1$  to  $n$ :

$$x_i = (b_i - \sum_{j \neq i} a_{ij}x_j) / a_{ii},$$

  If  $(\|\mathbf{x} - \mathbf{x}^{(0)}\| \leq tol)$  or  $(iter \geq MaxIter)$ : end condition = True.

**Algoritmo:** (Método de JACOBI en forma vectorial).

*Inputs:*  $A \in \mathbb{R}^{n \times n}$  no-singular y diagonal dominante,  $\mathbf{b} \in \mathbb{R}^n$ ,  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ .

*Outputs:*  $\mathbf{x} \in \mathbb{R}^n$ , solución del sistema  $A\mathbf{x} = \mathbf{b}$ .

Initialize  $\mathbf{x} = \mathbf{x}^{(0)}$ ,  $T = D^{-1}(L + U)$ ,  $\mathbf{c} = D^{-1}\mathbf{b}$ .

while end conditions doesn't hold:

$$\mathbf{x} = T\mathbf{x} + \mathbf{c},$$

  If  $(\|\mathbf{x} - \mathbf{x}^{(0)}\| \leq tol)$  or  $(iter \geq MaxIter)$ : end condition = True.

# Método de Seidel

Consideramos de nuevo el sistema  $A\mathbf{x} = \mathbf{b}$ , con  $A \in \mathbb{R}^{nn}$ ,  $\mathbf{x}, \mathbf{b} \in \mathbb{R}^n$ . El **método de SEIDEL** es un método iterativo que también descompone la matriz  $A$  como la suma  $A = -L + D - U$ ,

$$A = - \underbrace{\begin{pmatrix} -a_{21} & & \\ \vdots & \ddots & \\ -a_{n1} & \cdots & -a_{n,n-1} \end{pmatrix}}_L + \underbrace{\begin{pmatrix} a_{11} & & \\ & a_{22} & \\ & & \ddots \\ & & & a_{nn} \end{pmatrix}}_D - \underbrace{\begin{pmatrix} -a_{12} & \cdots & -a_{1n} \\ & \ddots & \vdots \\ & & -a_{n-1,n} \end{pmatrix}}_U.$$

Sin embargo, ahora el sistema  $A\mathbf{x} = \mathbf{b}$  se reescribe como

$$(-L + D - U)\mathbf{x} = -L\mathbf{x} + D\mathbf{x} - U\mathbf{x} = \mathbf{b} \quad \Rightarrow \quad (D - L)\mathbf{x} = U\mathbf{x} + \mathbf{b}.$$

Si  $(D - L)^{-1}$  existe, entonces

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

y hemos escrito el sistema en la forma  $\mathbf{x} = T_S\mathbf{x} + \mathbf{c}_S$ , donde  $T_S = (D - L)^{-1}U$  y  $\mathbf{c}_S = (D - L)^{-1}\mathbf{b}$ .

# Método de Seidel

**Algoritmo:** (Método de SEIDEL).

*Inputs:*  $A \in \mathbb{R}^{n \times n}$  no-singular y diagonal dominante,  $\mathbf{b} \in \mathbb{R}^n$ ,  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ .

*Outputs:*  $\mathbf{x} \in \mathbb{R}^n$ , solución del sistema  $A\mathbf{x} = \mathbf{b}$ .

Initialize  $\mathbf{x} = \mathbf{x}^{(0)}$ .

while end conditions doesn't hold:

$\mathbf{z} = \mathbf{x}$ ,

    for  $i = 1$  to  $n$ :

$$x_i = (b_i - \sum_{j=1}^{i-1} a_{ij}x_j - \sum_{j=i+1}^n a_{ij}z_j) / a_{ii},$$

    If  $(\|\mathbf{x} - \mathbf{x}^{(0)}\| \leq tol)$  or  $(iter \geq MaxIter)$ : end condition = True.

**Algoritmo:** (Método de SEIDEL en forma vectorial).

*Inputs:*  $A \in \mathbb{R}^{n \times n}$  no-singular y diagonal dominante,  $\mathbf{b} \in \mathbb{R}^n$ ,  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ .

*Outputs:*  $\mathbf{x} \in \mathbb{R}^n$ , solución del sistema  $A\mathbf{x} = \mathbf{b}$ .

Initialize  $\mathbf{x} = \mathbf{x}^{(0)}$ ,  $T = (D - L)^{-1}U$ ,  $\mathbf{c} = (D - L)^{-1}\mathbf{b}$ .

while end conditions doesn't hold:

$$\mathbf{x} = T\mathbf{x} + \mathbf{c},$$

# Métodos Iterativos

Para que funcione el método de JACOBI es necesario:

1.  $a_{ii} > 0 \forall i$ , (para que  $D^{-1}$  exista).
2.  $\rho(D^{-1}(L + U)) < 1$ , (condición de convergencia).

## Definición

Sean  $A \in \mathbb{R}^{n \times n}$ . El **radio espectral** de  $A$  es el mayor módulo de sus autovalores. Esto es

$$\rho(A) = \max_{1 \leq i \leq n} |\lambda_i|, \quad \text{donde } \lambda_i \text{ es autovalor de } A.$$

## Lema

$\rho(A) \leq \|A\|$ , para cualquier norma inducida  $\|\cdot\|$ .

Prueba: Sea  $\lambda$  autovalor de  $A$ . Entonces existe  $\mathbf{x} \neq \mathbf{0}$ , con  $\|\mathbf{x}\| = 1$ , tal que  $A\mathbf{x} = \lambda\mathbf{x}$ . Luego

$$|\lambda| = \|\lambda\mathbf{x}\| = \|A\mathbf{x}\| \leq \|A\| \|\mathbf{x}\| = \|A\| \quad \Rightarrow \quad \rho(A) = \max |\lambda| \leq \|A\|. \quad \square$$

# Métodos Iterativos

**Teorema** Sea  $A \in \mathbb{R}^{n \times n}$ , una matriz estrictamente diagonal dominante. Para cualquier elección inicial  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ , el método iterativo de JACOBI,

$$\mathbf{x}^{(k+1)} = T_j \mathbf{x}^{(k)} + \mathbf{c}_j, \quad \text{con } T_j = D^{-1}(L + U), \quad \mathbf{c}_j = D^{-1}\mathbf{b},$$

converge a la solución del sistema  $A\mathbf{x} = \mathbf{b}$ .

Prueba: Basta mostrar las condiciones (1) y (2) anteriores. Como  $A$  es diagonal dominante, entonces  $|a_{ii}| > \sum_{j \neq i} |a_{ij}|$ . En particular  $|a_{ii}| > 0$   $a_{ii} \neq 0$ , para todo  $1 \leq i \leq n$ , de modo que  $D$  es invertible.

Por otro lado, las entradas  $t_{ij}$  de la matriz  $D^{-1}(L + U)$  son de la forma  $t_{ij} = \begin{cases} -\frac{a_{ij}}{a_{ii}}, & i \neq j; \\ 0, & i = j. \end{cases}$   
Tomando la norma  $\|\cdot\|_\infty$  para  $T_j = D^{-1}(L + U)$ , obtenemos

$$\rho(T_j) \leq \|T_j\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |t_{ij}| = \max_{1 \leq i \leq n} \sum_{j \neq i} \frac{|-a_{ij}|}{|a_{ii}|} = \max_{1 \leq i \leq n} \underbrace{\frac{1}{|a_{ii}|} \sum_{j \neq i} |a_{ij}|}_{< 1} < 1. \quad \square$$

# Métodos Iterativos

**Teorema** Sea  $A \in \mathbb{R}^{n \times n}$ , una matriz estrictamente diagonal dominante. Para cualquier elección inicial  $\mathbf{x}^{(0)} \in \mathbb{R}^n$ , el método iterativo de SEIDEL,

$$\mathbf{x}^{(k+1)} = T_S \mathbf{x}^{(k)} + \mathbf{c}_S, \quad \text{con } T_S = (D - L)^{-1}U, \quad \mathbf{c}_S = (D - L)^{-1}\mathbf{b},$$

converge a la solución del sistema  $A\mathbf{x} = \mathbf{b}$ .

Prueba: Basta mostrar las condiciones (1) y (2).  $\square$

**Referencias:** Para este teorema (y los subsiguientes sin demostración), consultar

- Axelsson O. (1994). *Iterative Solution Methods*. Cambridge University Press.
- Young D. (1971). *Iterative Solution of Large Linear Systems*. Academic Press.
- Varga R. (1962). *Matrix Iterative Analysis*. Prentice-Hall.

# Métodos de Relajación

Sea  $\mathbf{r}_i^{(k)} = (r_{i1}^{(k)}, r_{i2}^{(k)}, \dots, r_{in}^{(k)})$  el vector residual para el método de SEIDEL correspondiente a la solución aproximada  $\mathbf{x}^{(k)}$

$$\mathbf{x}^{(k)} = (x_1^{(k)}, \dots, x_{i-1}^{(k)}, x_i^{(k-1)}, \dots, x_n^{(k-1)}).$$

El  $m$ -ésimo componente de  $\mathbf{r}_i^{(k)}$  es

$$r_{mi}^{(k)} = b_m - \sum_{j=1}^{i-1} a_{mj} x_j^{(k)} - \sum_{j=i}^n a_{mj} x_j^{(k-1)}, \quad m = 1, 2, \dots, n.$$

En particular, el  $i$ -ésimo componente de  $\mathbf{r}_i^{(k)}$  es

$$r_{ii}^{(k)} = b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k)} - \sum_{j=i+1}^n a_{ij} x_j^{(k-1)} - a_{ii} x_i^{(k-1)}.$$

así que

$$a_{ii} x_i^{(k-1)} + r_{ii}^{(k)} = b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k)} - \sum_{j=i+1}^n a_{ij} x_j^{(k-1)} = a_{ii} x_i^{(k)}. \quad (8)$$

# Métodos Iterativos

o equivalentemente

$$x_i^{(k)} = x_i^{(k-1)} + \frac{r_{ii}^{(k)}}{a_{ii}}. \quad (9)$$

El método de SEIDEL está diseñado para que el residuo  $r_{i,i+1}^{(k)}$  sea 0. Sin embargo, reducir a cero una coordenada del vector residuo no siempre es el camino más eficiente para reducir la norma del vector  $\mathbf{r}_i^{(k)}$ . Es posible modificar la ecuación (9) de modo que

$$x_i^{(k)} = x_i^{(k-1)} + \omega \frac{r_{ii}^{(k)}}{a_{ii}}, \quad (10)$$

para ciertos valores de  $\omega$ .

Los métodos que usan (10) se llaman **métodos de relajación**. Para valores  $0 < \omega < 1$  se llaman *de subrelajación*, mientras que valores  $\omega > 1$  se llaman *de sobre-relajación*, y se utilizan para acelerar la convergencia de los métodos iterativos. Los métodos de **sobre relajación sucesiva** (*Successive Over Relaxation*), se abrevian como **SOR**, ó, **OR**.

# Métodos de Sobre-relajación

Llamaremos JOR a la implementación de sobre-relajación en el caso de la iteración de JACOBI. En este caso, tenemos

$$x_i^{(k+1)} = \frac{\omega}{a_{ii}} \left( b_i - \sum_{j \neq i} a_{ij} x_j^{(k)} \right) + (1 - \omega) x_i^{(k)}, \quad i = 1, 2, \dots, n.$$

La matriz de iteración en este caso es  $T_{j,\omega} = \omega D^{-1}(L + U) + (1 - \omega)I$ . Así, en forma matricial el método se escribe

$$\mathbf{x}^{(k+1)} = [\omega D^{-1}(L + U) + (1 - \omega)I] \mathbf{x}^{(k)} + \omega D^{-1} \mathbf{b}.$$

Equivalentemente,

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \omega D^{-1} \mathbf{r}^{(k)}.$$

En el caso del método de SEIDEL, la iteración para el método SOR resulta

$$x_i^{(k+1)} = \frac{\omega}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} + \sum_{j=1}^{i-1} a_{ij} x_j^{(k)} \right) + (1 - \omega) x_i^{(k)}, \quad i = 1, 2, \dots, n.$$

# Métodos Iterativos

La matriz de iteración en este caso es  $T_{s,\omega} = (I - \omega D^{-1}L)^{-1}[\omega D^{-1}U + (1 - \omega)I]$ . Así, en forma matricial el método se escribe

$$(I - \omega D^{-1}L)\mathbf{x}^{(k+1)} = [\omega D^{-1}U + (1 - \omega)I]\mathbf{x}^{(k)} + \omega D^{-1}\mathbf{b}.$$

Equivalentemente,

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \left(\frac{1}{\omega}D - L\right)^{-1}\mathbf{r}^{(k)}.$$

**Resultados sobre convergencia:** Resumimos algunos resultados de convergencia para los métodos de JACOBI , SEIDEL, JOR y SOR.

## Teorema

*Si  $A$  y  $2D - A$  son simétricas y positiva definidas, entonces el método de Jacobi es convergente y  $\rho(T_j) = \|T_j\|_A = \|T_j\|_D$ .*

En el caso del método JOR, la suposición en  $2D - A$  se puede eliminar, produciendo el siguiente resultado.

## Teorema

Si  $A$  es simétrica y positiva definida, entonces el método JOR es convergente si  $0 < \omega < \frac{2}{\rho(D^{-1}A)}$ .

Con respecto al método de Gauss-Seidel, se cumple el siguiente resultado.

## Teorema (Teorema de Kahan)

Para cualquier  $\omega \in \mathbb{R}$ , se tiene que  $\rho(T_{S,\omega}) \geq |\omega - 1|$ ; por lo tanto, el método SOR converge sólo si,  $0 < \omega < 2$ .

Prueba: Si  $\{\lambda_i\}$  son los autovalores de la matriz de iteración SOR, entonces

$$\left| \prod_{i=1}^n \lambda_i \right| = \left| \det [\omega D^{-1}L + (1 - \omega)I] \right| = |1 - \omega|^n.$$

Por lo tanto, debe existir al menos un autovalor  $\lambda_i$  tal que  $|\lambda_i| \geq |1 - \omega|$  y por lo tanto, para que se mantenga la convergencia, se debe tener  $|1 - \omega| < 1$ , es decir  $0 < \omega < 2$ .  $\square$

# Métodos Iterativos

Suponiendo que  $A$  es simétrica y definida positiva, la condición  $0 < \omega < 2$ , además de ser necesario, también se vuelve suficiente para la convergencia.

## Teorema (Teorema de Ostrowki-Reich)

*Si  $A$  es simétrica y positiva definida, entonces el método SOR es convergente si  $0 < \omega < 2$ . Además, su convergencia es monótona con respecto a  $\|\cdot\|_A$ .*

Finalmente, si  $A$  es estrictamente diagonale dominante, el método SOR converge si  $0 < \omega \leq 1$ . Los resultados anteriores muestran que el método SOR es más o menos rápidamente convergente, dependiendo de la elección del parámetro de relajación  $\omega$ .

La pregunta de cómo determinar el valor óptimo  $\omega_{opt}$  para el que la tasa de convergencia es la más alta posible se puede dar una respuesta satisfactoria sólo en casos especiales.

## Teorema

Si la matriz  $A$  es tridiagonal  $T_j$  tiene autovalores reales, entonces el método SOR converge para cualquier elección de  $\mathbf{x}^{(0)}$  si  $\rho(T_j) < 1$  y  $0 < \omega < 2$ . Además,

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \rho(T_j)^2}},$$

y el factor de convergencia asintótica correspondiente es

$$\rho(T_{S, \omega_{opt}}) = \frac{1 - \sqrt{1 - \rho(T_j)^2}}{1 + \sqrt{1 - \rho(T_j)^2}}.$$