

Análisis del Error en Solución de Sistemas de Ecuaciones Lineales

Dado el sistema de ecuaciones lineales de la forma

$$Ax = b, \text{ donde } A \in \mathbb{R}^{n \times n}; \quad b \in \mathbb{R}^n$$

En realidad tenemos:

$$(A + \delta A)(x + \delta x) = (b + \delta b)$$

$$Ax + A \delta x + \delta A x + \delta A \delta x = Ax + \delta b$$

Si despreciamos $\delta A \delta x$:

$$\delta x = A^{-1} (\delta b - \delta A x)$$

Norma

Medida escalar de la magnitud de un vector o una matriz.


Norma Vectorial: Dado un vector $X \in \mathbb{R}^n$, definimos **norma p**

$$\|X\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p}$$

$$p = 1: \|X\|_1 = \sum_{i=1}^n |x_i|$$

$$p = 2: \|X\|_2 = \|X\|_e = \sqrt{\sum_{i=1}^n x_i^2}$$

$$p = \infty: \|X\|_\infty = \max_{1 \leq i \leq n} |x_i|$$



Norma Matricial: Dada una matriz $A \in \mathbb{R}^{m \times n}$, definimos las normas matriciales, en función de las normas vectoriales definidas antes, se llama norma inducida

$$\|A\| = \max_{x \neq 0} \frac{\|Ax\|}{\|x\|}$$

Norma Columna $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$ 

Norma Fila $\|A\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$ 

Norma Raíz $\|A\|_2 = (\lambda_{\max})^{1/2}$,
 λ_{\max} : radio espectral de $[A]^T[A]$

Número de Condición

$$\text{Cond}(A) = \kappa(A) = \| |A| \| |A^{-1}| \|$$

- El producto de normas es una medida cuantitativa del grado de mal condicionamiento de la matriz de coeficientes. Mide cuán cerca está una matriz de ser singular
- Se usa para calcular cómo afectan los errores relativos en A y/o b el cálculo de x.
- Se puede demostrar que

$$\frac{\|\Delta X\|}{\|X\|} \leq \text{Cond}(A) \frac{\|\Delta b\|}{\|b\|} \quad \text{y} \quad \frac{\|\Delta X\|}{\|X + \Delta X\|} \leq \text{Cond}(A) \frac{\|\Delta A\|}{\|A\|}$$

- Si A y b tienen t cifras significativas y $\kappa(A)$ es de un orden 10^s entonces la precisión del resultado será 10^{s-t}

Sistema de ecuaciones mal condicionadas

- Una pequeño error en las entradas de la matriz A, causa una gran error en la solución.

$$\begin{bmatrix} 1 & 2 \\ 0.48 & 0.99 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 3 \\ 1.47 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 2 \\ 0.49 & 0.99 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 3 \\ 1.47 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 3 \\ 0 \end{bmatrix}$$

$$K(A) = ?$$

Definición de Residuo

Dado el sistema $Ax = b$, donde $A \in \mathbb{R}^{m \times n}$; $b \in \mathbb{R}^m$

Sea x_c valor calculado

$$e = x - x_c$$

$$r(x) = b - Ax_c$$

$$r(x) = Ax - Ax_c = Ae$$

$$e = A^{-1}r$$

$$\text{si } r(x) = 0 \Rightarrow e = 0$$

Teorema: Para toda matriz $A \in \mathbb{R}^{m \times n}$ vale que

$$\frac{1}{K(A)} \frac{\|r\|}{\|b\|} \leq \frac{\|e\|}{\|x\|} \leq K(A) \frac{\|r\|}{\|b\|}$$

Error en Eliminación de Gauss

- Wilkinson estudió el efecto del redondeo en el método de Eliminación de Gauss, considerando la triangulación con pivoteo y la solución de los dos sistemas triangulares, concluyendo que es un proceso muy estable, considerando que la matriz A no sea mal condicionada.
- Una forma de chequear esto es controlando los elementos de U, si crecen mucho es una señal de mala condición de la misma
- También multiplicar la inversa por la matriz de coeficientes original y estimar si el resultado es suficientemente cercano a la matriz identidad.

MÉTODOS ITERATIVOS

- Son recomendados para matrices *sparse*, caracterizadas por ordenes altos y muchos elementos nulos.
- Las ventajas respecto a los métodos directos se relacionan con:
 - número de operaciones
 - posiciones de memoria
 - errores de redondeo

El principio de estos métodos es dividir a la matriz A, de forma tal que el sistema sea fácil de resolver.

Generamos una ecuación de la forma:

$$x^{k+1} = B x^k + C$$

B se llama matriz de iteración

Método de Jacobi

Escribimos $A = L + D + U$

D: matriz diagonal, L y U: matrices triangulares

$$d_{ij} = \begin{cases} a_{ij} & i = j \\ 0 & \text{otherwise} \end{cases} \quad l_{ij} = \begin{cases} a_{ij} & i > j \\ 0 & \text{otherwise} \end{cases} \quad u_{ij} = \begin{cases} a_{ij} & i < j \\ 0 & \text{otherwise} \end{cases}$$

Suponiendo que los $a_{ii} \neq 0 \forall i$, D es invertible

$$\begin{aligned} Ax &= b \\ (D + L + U)x &= b \\ D x &= -(L+U)x + b \\ x &= -D^{-1}(L+U)x + D^{-1}b \end{aligned}$$

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

Método de Jacobi

Este método se puede ilustrar usando las siguientes ecuaciones:

$$\begin{aligned} a_{11} \cdot x_1 + a_{12} \cdot x_2 + a_{13} \cdot x_3 &= b_1 \\ a_{21} \cdot x_1 + a_{22} \cdot x_2 + a_{23} \cdot x_3 &= b_2 \\ a_{31} \cdot x_1 + a_{32} \cdot x_2 + a_{33} \cdot x_3 &= b_3 \end{aligned}$$

Despejo cada x_i de la ecuación i-esima, arrancamos de x^0

$$\begin{aligned} x_1^{(k+1)} &= \frac{b_1 - a_{12} \cdot x_2^{(k)} - a_{13} \cdot x_3^{(k)}}{a_{11}} \\ x_2^{(k+1)} &= \frac{b_2 - a_{21} \cdot x_1^{(k)} - a_{23} \cdot x_3^{(k)}}{a_{22}} \\ x_3^{(k+1)} &= \frac{b_3 - a_{31} \cdot x_1^{(k)} - a_{32} \cdot x_2^{(k)}}{a_{33}} \end{aligned}$$

Método de Jacobi

Forma Gral:

$$x_i^{k+1} = \frac{b_i - \sum_{j=1, j \neq i}^n a_{ij} \cdot x_j^k}{a_{ii}} \quad i = 1, \dots, n \quad k > 0$$

Criterios de Convergencia

$$\begin{aligned} \|x^{k+1} - x^k\| &< \varepsilon \\ \frac{\|x^{k+1} - x^k\|}{\|x^{k+1}\|} &< \varepsilon \\ k &> N \end{aligned}$$

Algoritmo Jacobi

Para $k = 0, 1, \dots$

Para $i = 1, 2, \dots, n$

$x_i = 0$

Para $j = 1, 2, \dots, i-1, i+1, \dots, n$

$x_i = x_i + a_{ij} x_j^k$

Fin

$x_i^{k+1} = (b_i - x_i) / a_{ii}$

Fin

Fin

Método de Gauss Seidel

Escribimos $A = L + D + U$

D: matriz diagonal, L y U: matrices triangulares

$$d_{ij} = \begin{cases} a_{ij} & i = j \\ 0 & \text{otherwise} \end{cases} \quad l_{ij} = \begin{cases} a_{ij} & i > j \\ 0 & \text{otherwise} \end{cases} \quad u_{ij} = \begin{cases} a_{ij} & i < j \\ 0 & \text{otherwise} \end{cases}$$

Suponiendo que los $a_{ii} \neq 0 \forall i$, D es invertible

$$\begin{aligned} Ax &= b \\ (D + L + U)x &= b \\ (D + L)x &= -Ux + b \\ D x^{k+1} &= -L x^k - U x^k + b \end{aligned}$$

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

Algoritmo Gauss-Seidel

Forma Gral:

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

Para $k=0,1,2,\dots$

Para $i=1,2,\dots,n$

sum=0

Para $j=1,2,\dots,i-1$,

$$sum = sum + a_{ij} x_j^{k+1}$$

Fin

Para $j=i+1,\dots,n$

$$sum = sum + a_{ij} x_j^k$$

Fin

$$\text{Fin } x_i^{k+1} = (b_i - sum) / a_{ii}$$

Fin

Método Sobrerrelajación (SOR)

Este método usa un factor de ponderación para mejorar el valor calculado

$$x_i^{k+1} = \omega \cdot x_i^{(k+1)} + (1-\omega) \cdot x_i^k \quad 0 \leq \omega \leq 2$$

$0 < \omega < 1$ hace convergente el método (subrelajación)

$\omega = 1$ Gauss Seidel

$1 < \omega < 2$ acelera convergencia del método (sobre relajación)

Convergencia

Método de Jacobi: Podemos afirmar su convergencia si A es diagonalmente dominante:

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

Método de Gauss Seidel: Podemos afirmar su convergencia si A es diagonalmente dominante y también si es simétrica y definida positiva

Teorema de Convergencia: Suponiendo tener la ecuación: $X^{k+1} = B X^k + C$, si en alguna norma matricial $\|B\| < 1$ y si x^0, x^1, \dots es la sucesión generada por esta ecuación, esta sucesión converge a la única solución x de la ecuación vectorial $x = B x + C$ independientemente del x^0 escogido