



ALN – Sistemas Lineales

In. Co.

Facultad de Ingeniería

Universidad de la República

Introducción

$$Ax = b$$

Donde A es una matriz dada de $n \times n$, b es un vector dado de largo n y x es un vector de incógnita (también de largo n).

La matriz A es invertible.

Introducción

■ Aplicaciones

- Resolución de ecuaciones diferenciales
- Problemas de optimización.
- Resolución de problemas no lineales (Newton-Raphson)
- Muchos otros problemas



Introducción

- Distintas estrategias:
 - Métodos directos.
 - Métodos iterativos.

Introducción

Métodos directos:

- 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.
- Disponen de estrategias para reducir los efectos de los problemas ocasionados por el mal condicionamiento de las matrices, como son las técnicas de pivoteo.
- Para la resolución de matrices dispersas utilizando métodos directos es necesario controlar la aparición de nuevos coeficientes no nulos (*fill in*).

Introducción

Métodos iterativos:

- Intentan aproximar la solución mediante una sucesión generada iterativamente.
- Si el método converge se obtiene una solución aproximada del problema, cuyo error satisface algún criterio prefijado.



Métodos directos

Resolución de sistemas particulares

- Sistemas de una diagonal

- Sistema $Ax=b$, donde la matriz A es diagonal.

$$\begin{pmatrix} 4 & 0 & 0 & 0 & 0 \\ 0 & 5 & 0 & 0 & 0 \\ 0 & 0 & 5 & 0 & 0 \\ 0 & 0 & 0 & 4 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$$

Resolución de sistemas particulares

■ Sistemas triangulares

- Sistema $Ax=b$, donde la matriz A es triangular (superior o inferior)

$$\begin{pmatrix} 4 & 0 & 0 & 0 & 0 \\ 2 & 5 & 0 & 0 & 0 \\ 3 & 3 & 5 & 0 & 0 \\ 2 & 1 & 9 & 4 & 0 \\ 3 & 4 & 7 & 8 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$$

$$\begin{pmatrix} 4 & 4 & 6 & 7 & 8 \\ 0 & 5 & 1 & 0 & 3 \\ 0 & 0 & 5 & 6 & 4 \\ 0 & 0 & 0 & 4 & 2 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$$

Resolución de sistemas particulares

- Sistemas triangular superior (sustitución hacia atrás)

$$\begin{pmatrix} u_{11} & \cdot & \cdot & \cdot & u_n \\ 0 & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & \cdot \\ 0 & 0 & 0 & \cdot & \cdot \\ 0 & 0 & 0 & 0 & u_{nn} \end{pmatrix} \begin{pmatrix} x_1 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{pmatrix} = \begin{pmatrix} b_1 \\ \cdot \\ \cdot \\ \cdot \\ b_n \end{pmatrix}$$

$$x_n = \frac{b_n}{u_{nn}}$$

$$x_i = \frac{b_i - \sum_{k=i+1}^n x_k u_{ik}}{u_{ii}}$$

Resolución de sistemas particulares

- Contando operaciones

$$op \approx \sum_{k=1}^n (k-1) = \frac{1}{2} (n)(n-1) \approx \frac{1}{2} n^2$$

Lo que implica que el algoritmo sea de $O(n^2)$

Resolución de sistemas particulares

- Sistemas triangular inferior
 - sustitución hacia delante
 - análogo a la sustitución hacia atrás

Eliminación Gaussiana

- Uno de los métodos más difundidos.
- También denominada escalerización y eliminación de Gauss (por Karl Gauss [1777-1855]).
- Asume que la matriz A es invertible, por lo que el sistema posee una única solución.



Eliminación Gaussiana

- Consiste en transformar la matriz A y el vector b , mediante una serie de transformaciones elementales (intercambiar dos filas, multiplicar una fila por un escalar distinto de 0 o sumar dos filas) para convertir el sistema en uno triangular.

Eliminación Gaussiana

- Para cada columna j desde la 1 a la n (en orden), “eliminar” los coeficientes distintos de 0 a partir de la fila j .
 - Para eliminar el coeficiente a_{ij} de la columna j resto la fila i menos la fila j multiplicada por $m_{ij} = \frac{a_{ij}}{a_{jj}}$
- Hay que realizar los mismos cambios en el vector b para que el sistema sea equivalente

Eliminación Gaussiana

- La segunda etapa del método consiste en resolver el sistema lineal triangular.
- Para esta etapa se utiliza la estrategia vista anteriormente.

Eliminación Gaussiana

■ Ejemplo:

$$Ax = b \rightarrow \begin{pmatrix} 1 & 1 & 1 & 1 \\ 2 & 3 & 5 & 4 \\ 1 & 3 & 9 & 6 \\ 2 & 3 & 7 & 9 \end{pmatrix} x = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} \rightarrow \begin{pmatrix} 1 & 1 & 1 & 1 \\ 0 & 1 & 3 & 2 \\ 0 & 2 & 8 & 5 \\ 0 & 1 & 5 & 7 \end{pmatrix} x = \begin{pmatrix} 1 \\ -1 \\ 0 \\ -1 \end{pmatrix} \quad \dots \quad \begin{pmatrix} 1 & 1 & 1 & 1 \\ 0 & 1 & 3 & 2 \\ 0 & 0 & 2 & 1 \\ 0 & 0 & 0 & 4 \end{pmatrix} x = \begin{pmatrix} 1 \\ -1 \\ 2 \\ -2 \end{pmatrix}$$

$$Ax = b \rightarrow Lx = \tilde{b}, \tilde{b} = \begin{pmatrix} 1 \\ -1 \\ 2 \\ -2 \end{pmatrix} \rightarrow x = \begin{pmatrix} 4.0 \\ -3.75 \\ 1.25 \\ -0.5 \end{pmatrix}$$

Eliminación Gaussiana

- Escalerizando ...

$$Ax = b \rightarrow M_1 Ax = M_1 b$$

$$M_1 = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ -m_{21} & 1 & \ddots & \vdots \\ -m_{31} & 0 & \ddots & \\ \vdots & \vdots & \ddots & 0 \\ -m_{n1} & 0 & \cdots & 0 & 1 \end{pmatrix}$$

$$M_1 Ax = M_1 b \rightarrow M_{n-1} \cdots M_1 Ax = M_{n-1} \cdots M_1 b$$

Eliminación Gaussiana

- Contando operaciones
 - Para cada columna k (todas las columnas excepto la última):
 - Calculo $(n-k)$ multiplicadores: $(n-k)$ divisiones.
 - Actualizo $(n-k)^2$ elementos: una mult. y una suma por cada uno.

$$\sum_{k=1}^{n-1} (n-k) + 2 \sum_{k=1}^{n-1} (n-k)^2 = \frac{2n(n-1)(2n-1)}{6} + \frac{n(n-1)}{2} = \frac{4n^3 - 3n^2 - n}{6} = \frac{2(n^3)}{3}$$

- Por lo tanto el orden del algoritmo es $O(n^3)$

Eliminación Gaussiana

- Los elementos a_{ii} (en el paso i de la escalerización) se denominan pivotes.
- ¿Que pasa si uno de los pivotes es (cercano a) cero?
 - Pivoteo!!!!!!: Intercambiar filas/columnas para que los pivotes sean distintos de cero.
 - Dos estrategias:
 - Pivoteo parcial
 - Pivoteo completo

Eliminación Gaussiana

- Estrategias de pivoteo:

- Pivoteo parcial: intercambiar las filas k y r siendo k la columna actual y r el mínimo entero para el cual

$$\left| a_{rk}^{(k)} \right| = \max_{k \leq i \leq n} \left| a_{ik}^{(k)} \right|$$

- Pivoteo completo: intercambiar las filas k con r y columnas k con s tal que r y s son los mínimos enteros para los cuales

$$\left| a_{rs}^{(k)} \right| = \max_{k \leq i, j \leq n} \left| a_{ij}^{(k)} \right|$$

Eliminación Gaussiana

- Se pueden resolver varios vectores independientes (varios b).
- Se escalerizan todos juntos, luego se resuelve cada uno de los sistemas triangulares.

Factorización LU

- $Ax = b \rightarrow LU=A \rightarrow Ly = b, Ux=y$
 - L es triangular inferior
 - U es triangular superior
 - Si utilizamos factorización LU, con la matriz L con unos en la diagonal la descomposición es única.
- Es útil cuando quiero resolver varios vectores derechos sin conocerlos

Factorización LU

- Relación con la escalerización

$$M_1 Ax = M_1 b \rightarrow M_{n-1} \dots M_1 Ax = M_{n-1} \dots M_1 b$$

$$MA = U \rightarrow A = M^{-1}U \rightarrow M^{-1} = L$$

Recordar que la matriz M es la multiplicación de matrices triangulares inferiores

Factorización LU

- Un algoritmo

```
U=A;  
L=I;  
For k=1:n-1  
    For j=k+1:n  
        L(j,k)=U(j,k)/U(k,k)  
        U(j,k:n)=U(j,k:n)-L(j,k)U(k,k:n)
```

Factorización LU

- Un algoritmo “in place”

```
For i=1:n-1
  For j=i+1:n
    A(j,i)=A(j,i)/A(i,i)
  For k=i+1:n
    A(j, k)=A(j, k)-A(j, i)A(i, k)
```

Factorización LU

- Acceso a la matriz
 - Por bloques
 - Con distinto patrón de acceso
- Se realizan operaciones matriz-matriz que son más eficientes que vector-vector

■ LU a bloques

- Descomponer la matriz A en sub-bloques

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} L_{11} & 0 \\ L_{21} & L_{22} \end{pmatrix} \begin{pmatrix} U_{11} & U_{12} \\ 0 & U_{22} \end{pmatrix}$$

Factorización LU

- Un algoritmo por bloques

$$A_{11} = L_{11}U_{11}$$

$$A_{21} = L_{21}U_{11}$$

$$A_{12} = L_{11}U_{12}$$

$$A_{22} = L_{21}U_{12} + L_{22}U_{22}$$

$$A_{11} = L_{11}U_{11}$$

$$A_{21} = XU_{11}$$

$$A_{12} = L_{11}Y$$

Se resuelve $L_{11}yU_{11}$

Se resuelve L_{21}

Se resuelve U_{12}

Luego se actualiza $\tilde{A}_{22} = A_{22} - L_{21}U_{12}$

Por último se factoriza \tilde{A}_{22}




Factorización LU

Diferentes tipo de patrón de acceso a la matriz (por bloques) según que datos utiliza/calcula.

Factorización LU

- Diferentes estrategias de acceso



Left-looking

Right-looking

Crout-LU

- Acceso a la matriz “Right-looking”, el que vimos anteriormente

$$A = \begin{pmatrix} L_{11} & & & \\ L_{21} & I & & \\ L_{31} & 0 & I & \end{pmatrix} \begin{pmatrix} U_{11} & U_{12} & U_{13} \\ & \tilde{A}_{22} & \tilde{A}_{23} \\ & \tilde{A}_{32} & \tilde{A}_{33} \end{pmatrix}$$

Factorización LU

■ Acceso "Left"

$$A = \begin{pmatrix} L_{11} & & & \\ L_{21} & I & & \\ L_{31} & 0 & I & \end{pmatrix} \begin{pmatrix} U_{11} & A_{12} & A_{13} \\ & A_{22} & A_{23} \\ & A_{32} & A_{33} \end{pmatrix}$$

$$U_{12} = L_{11}^{-1} A_{12}$$

$$\tilde{U}_{22} = A_{22} - L_{21} U_{12}$$

$$\tilde{U}_{32} = A_{32} - L_{31} U_{12}$$

$$\begin{pmatrix} \tilde{U}_{22} \\ \tilde{U}_{32} \end{pmatrix} = \begin{pmatrix} A_{22} \\ A_{32} \end{pmatrix} - \begin{pmatrix} L_{21} \\ L_{31} \end{pmatrix} U_{12}$$

$$A = \begin{pmatrix} L_{11} & & & \\ L_{21} & I & & \\ L_{31} & 0 & I & \end{pmatrix} \begin{pmatrix} U_{11} & U_{12} & A_{13} \\ & \tilde{U}_{22} & A_{23} \\ & \tilde{U}_{32} & A_{33} \end{pmatrix}$$

Factorizando

$$\begin{pmatrix} \tilde{U}_{22} \\ \tilde{U}_{32} \end{pmatrix} \rightarrow \begin{pmatrix} L_{22} \\ L_{32} \end{pmatrix} U_{22}$$

$$A = \begin{pmatrix} L_{11} & & & \\ L_{21} & L_{22} & & \\ L_{31} & L_{32} & I & \end{pmatrix} \begin{pmatrix} U_{11} & U_{12} & A_{13} \\ & U_{22} & A_{23} \\ & 0 & A_{33} \end{pmatrix}$$

Factorización LU

■ Acceso Crout

$$A = \begin{pmatrix} L_{11} & & \\ 0 & I & \\ 0 & 0 & I \end{pmatrix} \begin{pmatrix} I & U_{12} & U_{13} \\ L_{21} & A_{22} & A_{23} \\ L_{31} & A_{32} & A_{33} \end{pmatrix} \begin{pmatrix} U_{11} & 0 & 0 \\ & I & 0 \\ & & I \end{pmatrix} \quad \begin{aligned} (A_{22} \quad A_{23}) &\leftarrow (A_{22} \quad A_{23}) - L_{21}(U_{12} \quad U_{13}) \\ A_{32} &\leftarrow A_{32} - L_{31}U_{12} \end{aligned}$$

Factorizando

$$\begin{pmatrix} A_{22} \\ A_{32} \end{pmatrix} \leftarrow \begin{pmatrix} L_{22} \\ L_{32} \end{pmatrix} U_{22}$$

$$\text{con } U_{23} = L_{21}^{-1} A_{23}$$

$$A = \begin{pmatrix} L_{11} & & \\ L_{21} & L_{22} & \\ 0 & 0 & I \end{pmatrix} \begin{pmatrix} I & 0 & U_{13} \\ 0 & I & A_{23} \\ L_{31} & A_{32} & A_{33} \end{pmatrix} \begin{pmatrix} U_{11} & U_{12} & 0 \\ & U_{22} & 0 \\ & & I \end{pmatrix}$$

Factorización LU

- Estrategias de acceso, conclusiones:
 - mejoran la localidad de datos en el acceso, tanto de lectura como de escritura.
 - el acceso por columna se puede hacer por fila.
 - mejoran el trabajo en computadores vectoriales.
 - mejoran el desempeño al utilizar bibliotecas blas.

Factorización LU

- Pivoteo en LU

- $LU=PA, PAx=Pb$

- En la factorización LU, el pivoteo parcial se aplica de la siguiente forma:

- $Ly=Pb, Ux = y$

Factorización LU

- Pivoteo en bloques ...
 - completo muy difícil ..
 - solo “pivotear” en el bloque !!
 - otras soluciones
 - Pivoteo 2*2
 - Matrices aleatorias

Factorización LU

Matrices especiales

- Simétricas (indefinidas)
 - Descomposición LDL^t

- Simétricas y definidas positivas (Cholesky)
 - Descomposición LL^t

Errores

Ejemplo: $A = \begin{bmatrix} 1 & 1 \\ 10.05 & 10 \end{bmatrix}$ $b = \begin{bmatrix} 2 \\ 21 \end{bmatrix}$ solución: $x = \begin{bmatrix} 20 \\ -18 \end{bmatrix}$

Si modificamos “un poco” el sistema esperaríamos una pequeña variación en la solución, pero esto no siempre sucede:


$$A = \begin{bmatrix} 1 & 1 \\ 10.1 & 10 \end{bmatrix} \quad b = \begin{bmatrix} 2 \\ 21 \end{bmatrix} \quad \text{solución: } x = \begin{bmatrix} 10 \\ -8 \end{bmatrix}$$



Errores

- Otra forma de verlo: como rectas...


Errores



$$A = \begin{bmatrix} 1 & 1 \\ 10.05 & 10 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 21 \end{bmatrix}$$

Errores



$$A = \begin{bmatrix} 1 & 1 \\ 10.1 & 10 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 21 \end{bmatrix}$$

Errores...

- Perturbando las matrices conocidas y acotando errores
- Analizando la estabilidad

Estudio del error

- Si perturbamos b ,

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

$$\delta x = A^{-1}\delta b \rightarrow \|\delta x\| \leq \|A^{-1}\|\|\delta b\|$$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\|\|A^{-1}\|\frac{\|\delta b\|}{\|b\|}$$

Estudio del error

- Si perturbamos A

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

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

$$\|\delta x\| \leq \frac{\|A\| \|A^{-1}\| \|\delta A\|}{\|A\|} \|x + \delta x\|$$

$$\frac{\|\delta x\|}{\|x + \delta x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta A\|}{\|A\|}$$

Estudio del error

- Si además $\|A^{-1}\| \|\delta A\| < 1$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta A\| \|x + \delta x\|$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta A\| \|x + \delta x\| \leq \|A^{-1}\| \|\delta A\| \|x\| + \|A^{-1}\| \|\delta A\| \|\delta x\|$$

$$1 - \frac{\|A\| \|A^{-1}\| \|\delta A\|}{\|A\|} \leq \frac{\|A\| \|A^{-1}\| \|\delta A\|}{\|A\|} \frac{\|x\|}{\|\delta x\|}$$

$$\frac{\|\delta x\|}{\|x\|} \leq \left(\frac{\|A\| \|A^{-1}\| \|\delta A\|}{\|A\|} \right) / \left(1 - \frac{\|A\| \|A^{-1}\| \|\delta A\|}{\|A\|} \right)$$

Estudio del error

Número de condición:

El factor que controla la amplificación de los errores relativos de los datos

$$\mathit{cond}(A) = \|A\| \|A^{-1}\|$$

Estudio del error

- Con esta definición podemos reescribir las fórmulas anteriores para la perturbación relativa de x :

- Perturbando b

$$\frac{\|\delta x\|}{\|x\|} \leq \text{cond}(A) \frac{\|\delta b\|}{\|b\|}$$

- Perturbando A

$$\frac{\|\delta x\|}{\|x\|} \leq \left(\text{cond}(A) \frac{\|\delta A\|}{\|A\|} \right) / \left(1 - \text{cond}(A) \frac{\|\delta A\|}{\|A\|} \right)$$

Estudio del error

- Si perturbamos A y b ,

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

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\text{cond}(A)}{1 - \text{cond}(A) \frac{\|\delta A\|}{\|A\|}} \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right)$$

Algunos conceptos matemáticos

- Teorema 1: Cualquier norma matricial es una función continua de los elementos de la matriz.
- Teorema 2: Para cada par de normas matriciales existen constantes positivas m y M tales que :

$$m \|A\|_i \leq \|A\|_j \leq M \|A\|_i$$

Algunos conceptos matemáticos

- Teorema 3: Para cualquier norma natural y cualquier matriz cuadrada se verifica:

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

- Teorema 4: Para cualquier matriz cuadrada y cualquier valor existe alguna norma natural tal que:

$$\rho(A) \leq \|A\| \leq \rho(A) + \varepsilon$$

- Corolario: Para cualquier matriz cuadrada:

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

Estudio del error

- Para la norma euclidiana y para una matriz normal ($AA^* = A^*A$)

$$\text{cond}(A) = \frac{\lambda_1}{\lambda_n}$$

Estudio del error

- Otra forma de obtener en forma exacta el número de condición de una matriz es mediante la formula:

$$\text{cond}(A) = \frac{\sigma_1}{\sigma_n}$$

donde, σ_1 es el mayor valor singular y σ_n el menor

Estudio del error

- Estabilidad de la factorización LU , ante los errores de redondeo.
- Como afectan la estrategias de pivoteo

Estudio del error

- El condicionamiento numérico indica como se amplifican los errores.
- Entonces, si introducimos errores de redondeo en las cuentas los resultados se verán afectados
- Se puede hacer:
 - Análisis directo: se estudia cómo se propagan los errores (resultados muy pesimistas).
 - Análisis inverso: se estiman los errores como perturbaciones de los datos y se intenta acotar los errores.

Estudio del error

- Si realizamos una factorización (sin pivoteo) de una matriz A (no singular) obtenemos $LU = A + \delta A$ debido a los errores de redondeo
- Se cumple el siguiente resultado: $\|\delta A\| \leq n\varepsilon\|L\|\|U\|$
- Definimos el factor de crecimiento respecto a la norma $\|\cdot\|$ como $\rho = \frac{\|L\|\|U\|}{\|A\|}$

Estudio del error

- Con la def. anterior tenemos que: $\frac{\|\delta A\|}{\|A\|} \leq n\varepsilon\rho$
- ρ refleja el crecimiento en magnitud de las entradas de LU respecto de las de A.
- Si se utiliza pivoteo, los valores de la matriz L se obtienen mediante divisiones en las cuales el divisor siempre es mayor al dividendo. Podemos asumir que la norma de la matriz L no crecerá sustancialmente y que ρ está determinado por el crecimiento de U.

Estudio del error

- El factor de crecimiento que utiliza normas matriciales se sustituye por:

$$\rho = \frac{\max_{i,j} |u_{ij}|}{\max_{i,j} |a_{ij}|}$$

- Podemos reescribir la formula:

$$\frac{\|\delta A\|}{\|A\|} = O(\rho n \varepsilon_{mach})$$

Estudio del error

- Estudiando un caso particular
- Con pivoteo parcial, todo solucionado ??

$$A = \begin{pmatrix} 1 & 0 & 1 \\ -1 & 1 & 1 \\ -1 & -1 & 1 \end{pmatrix}$$

Estudio del error

$$A = LU = \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ -1 & -1 & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 2 \\ 0 & 0 & 4 \end{pmatrix} \quad \rho = \frac{\max_{i,j} |u_{ij}|}{\max_{i,j} |a_{ij}|} = 4$$

Para una matriz con esta forma pero de dimensión n el ρ es 2^{n-1}

Y que paso con nuestra teoría ?

Estudio del error

- Para la gran mayoría de las matrices se puede afirmar que la factorización LU con pivoteo parcial es estable.
- Que tan grande es la mayoría ?!?!
 - Wilkinson en 1965 escribió: “Ningún ejemplo que haya surgido naturalmente en mi experiencia dio un factor de crecimiento mayor a 16”
 - Existen cotas más duras para matrices especiales:
 - Hessenberg: $\rho \leq n$
 - Tridiagonales: $\rho \leq 2$

Estudio del error

- En general es necesario algún tipo de pivoteo para garantizar la estabilidad de la factorización LU.
- Sin embargo existen familias de matrices para las cuales no es necesario pivoteo:
 - Matrices diagonal-dominantes
 - Matrices definidas positivas
 - Matrices totalmente positivas

Refinamiento iterativo

$$Ax = b \rightarrow A\tilde{x} = b$$

$$r = b - A\tilde{x}$$

$$A\delta x = r$$

$$x = \tilde{x} + \delta x$$

- Solo es útil si se trabaja con distintas precisiones
- Existen otros refinamientos sin esta exigencia pero son menos intuitivos

Escalado I

- Dividir cada fila de la matriz por el mayor valor de la fila.
- No garantiza mejorar el condicionamiento.

Escalado

$$\frac{\|\tilde{x} - x\|}{\|x\|} \approx \mu K(A) \quad (D_1^{-1}AD_2)y = D_1^{-1}b \rightarrow \mu K(D_1^{-1}AD_2)$$

$$\text{Si } K(D_1^{-1}AD_2) < K(A)$$

- Elegir D_1 para que todas las filas de A tengan la misma norma
- Elegir D_1 y D_2 para que las columnas y filas tengan norma similar

Es difícil determinar estrategias generales de escalado es necesario estudiar cada problema

Estimación del número de condición I

$$\text{cond}(A) = \|A\| \|A^{-1}\| \quad \|A\| \text{ se puede calcular}$$

$$\text{Si } A \text{ es no singular y } B \text{ es singular} \rightarrow \|A^{-1}\| \geq \frac{1}{\|A - B\|}$$

$$\text{cond}(A) \geq \frac{\|A\|}{\|A - B\|}$$

Estimación del número de condición

Como B es singular $\exists x \neq 0 / Bx = 0$

$$Ax = (A - B)x \rightarrow A^{-1}Ax = A^{-1}(A - B)x$$

$$x = A^{-1}(A - B)x$$

$$1 \leq \|A^{-1}\| \|A - B\|$$

Si se toma la matriz B “parecida” a la matriz A, se obtiene una buena cota para el número de condición.

Estimación del número de condición II

$$\text{cond}(A) = \|A\| \|A^{-1}\| \quad \|A\| \text{ se puede calcular}$$

$$\text{Un estimador } Ay = d \rightarrow \|A^{-1}\| \geq \frac{\|y\|}{\|d\|}$$

$$\text{cond}(A) \approx \frac{\|A\| \|y\|}{\|d\|}$$

Otra aplicación de LU

Cálculo del determinante

$$\det(A) = \det(LU) = \det(L)\det(U)$$

Pero el determinante de matrices triangulares es igual a la multiplicatoria de la diagonal

$$\det(L)\det(U) = \det(U) = u_{11} * u_{22} * \dots * u_{nn}$$

Tri-diagonales

Queremos resolver un sistema tri-diagonal (caso particular de un sistema de banda) donde la matriz es de la siguiente forma:

$$A = \begin{bmatrix} d_1 & s_1 & 0 & \dots & 0 \\ i_2 & d_2 & s_2 & & \cdot \\ 0 & & \cdot & & 0 \\ \cdot & & & \cdot & s_{n-1} \\ 0 & \cdot & 0 & i_n & d_n \end{bmatrix}$$

Tri-diagonales

Al hacer una factorización LU

$$L = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ \alpha_2 & 1 & 0 & & \\ 0 & \cdot & & & 0 \\ \cdot & & & \cdot & 0 \\ 0 & \cdot & 0 & \alpha_n & 1 \end{bmatrix} \quad U = \begin{bmatrix} \beta_1 & s_1 & 0 & \dots & 0 \\ 0 & \beta_2 & s_2 & & \cdot \\ 0 & & \cdot & & 0 \\ \cdot & & & \cdot & s_{n-1} \\ 0 & \cdot & 0 & 0 & \beta_n \end{bmatrix}$$

Si multiplicamos $L \cdot U$ e igualamos a la matriz A podemos deducir el algoritmo

Tri-diagonales

$$LU = \begin{bmatrix} \beta_1 & s_1 & 0 & \dots & 0 \\ \alpha_2 \beta_1 & \alpha_2 s_1 + \beta_2 & s_2 & & \cdot \\ 0 & & \cdot & & 0 \\ \cdot & & & \cdot & s_{n-1} \\ 0 & \cdot & 0 & \alpha_n \beta_{n-1} & \alpha_n s_{n-1} + \beta_n \end{bmatrix} \quad A = \begin{bmatrix} d_1 & s_1 & 0 & \dots & 0 \\ i_2 & d_2 & s_2 & & \cdot \\ 0 & & \cdot & & 0 \\ \cdot & & & \cdot & s_{n-1} \\ 0 & \cdot & 0 & i_n & d_n \end{bmatrix}$$

Tri-diagonales

$$\beta_1 = d_1$$

$$\left. \begin{aligned} \alpha_j &= \frac{i_j}{\beta_{j-1}} \\ \beta_j &= d_j - \alpha_j s_{j-1} \end{aligned} \right\} \text{para } j = 2, 3..n$$