

# **Normas de Vectores y de Matrices**

## **Números de Condición**

Profesor: Dr. Alejandro S. M. Santa Cruz  
JTP: Dr. Juan Ignacio Manassaldi  
Auxiliar: Srta. Amalia Rueda

- Normas de matrices y números de condición:
  - Sistemas de ecuaciones mal condicionados.
  - Normas de matrices: norma de Frobenius y normas asociadas a una norma vectorial.
  - Números de condición de una matriz.
  - Cálculo del número de condición para la norma Euclídea.
  - Inversas de matrices perturbadas.
- Observaciones:
  - Se va a abordar el problema de la *estimación de los errores* introducidos en la resolución numérica de los sistemas de ecuaciones lineales mediante los métodos vistos en el curso.
  - Para poder hacer este estudio son necesarios varios conceptos introducidos en Álgebra, principalmente el concepto de norma de un vector y de valores y vectores propios.
  - Además es necesario introducir el concepto de *norma de una matriz*, que se basará en la norma de un vector.

## Sistemas de Ecuaciones Mal Condicionados (1/2)

- Posibles orígenes de los errores en el resultado de unos cálculos:
  - Errores en el *modelo* (por ejemplo, prescindir del rozamiento)
  - Errores en los *datos* (por ejemplo, los originados por medidas poco precisas)
  - Errores en el *algoritmo* (hay algoritmos estables e inestables)
  - Errores en las *operaciones aritméticas*: imposibles de evitar en la práctica.
- Errores en las operaciones aritméticas
  - Debidos al *nº limitado de cifras* que almacena el ordenador (53 bits ó 15~16 cifras decimales equivalentes en los PCs).
  - Unos problemas son mucho más sensibles que otros (matriz aleatoria o matriz de Hilbert). Se dice que son *problemas mal condicionados*.
- Problemas mal condicionados:
  - Son aquellos problemas en los que los errores tienden a crecer en una forma incontrolada, potencial o exponencial, superior por tanto a un crecimiento lineal con el número de operaciones aritméticas.
  - La *condición* de un problema es la sensibilidad de los resultados a pequeñas variaciones en los datos.
  - Si esta sensibilidad es muy grande, pueden esperarse *importantes dificultades* aunque los datos iniciales sean exactos, pues los errores numéricos tenderán a amplificarse.
- En este tema se estudiarán los errores en los *sistemas de ecuaciones lineales*.

## Sistemas de Ecuaciones Mal Condicionados (2/2)

□ Ejemplos de pequeño tamaño:

- Supóngase los siguientes sistemas de ecuaciones lineales:

$$\begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 0 \end{bmatrix}; \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 2.0001 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

- Éste es un problema *mal condicionado*, porque un pequeño cambio en el término independiente da lugar a un cambio muy grande en la solución. En realidad, la segunda ecuación es muy parecida a la primera,
- Considérese ahora otro sistema de ecuaciones, que se va a resolver mediante el Método de Gauss de modo exacto y con tres cifras decimales de precisión :

$$\text{Exacto: } \begin{bmatrix} 0.0001 & 1 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 2 \end{bmatrix} \Rightarrow \begin{bmatrix} 0.0001 & 1 \\ 0 & -9999 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ -9998 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 0.9999 \end{bmatrix}$$

$$3 \text{ cifras: } \begin{bmatrix} 0.0001 & 1 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 2 \end{bmatrix} \Rightarrow \begin{bmatrix} 0.0001 & 1 \\ 0 & -10000 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ -10000 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

- Si se intercambian las ecuaciones:

$$3 \text{ cifras: } \begin{bmatrix} 1 & 1 \\ 0.0001 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 1 \end{bmatrix} \Rightarrow \begin{bmatrix} 1 & 1 \\ 0 & 0.9999 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 0.9998 \end{bmatrix} \Rightarrow \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

- En este caso el problema está bien condicionado, pero se estaba aplicando un algoritmo incorrecto (inestable).

## Normas Vectoriales en $\mathbf{R}^n$ (1/3)

### □ Objetivo:

- Disponer de una medida del tamaño de los vectores, con objeto de estudiar convergencias, relaciones de mayor o menor, proximidad a cero, etc.

### □ Normas de vectores

- Estudiadas al hablar de los espacios vectoriales Euclídeos.
- La norma de un vector  $\|\mathbf{x}\|$  debe satisfacer las tres propiedades siguientes:
  1.  $\|\mathbf{x}\| \geq 0$ , y  $\|\mathbf{x}\| = 0$  si y sólo si  $\mathbf{x} = 0$
  2.  $\|\alpha\mathbf{x}\| = |\alpha| \|\mathbf{x}\|$ , para cualquier  $\alpha \in \mathbf{R}$
  3.  $\|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|$  (desigualdad triangular)
- El **producto escalar** permite definir de modo natural una norma en  $\mathbf{R}^n$ , que coincide con la longitud de un vector en  $\mathbf{R}^2$  y  $\mathbf{R}^3$ :

$$\|\mathbf{x}\| = \sqrt{\langle \mathbf{x}, \mathbf{x} \rangle} = \sqrt{\sum_{j=1}^n x_j^2}$$

- Esta norma, llamada **norma Euclídea**, no es la única posibilidad. Puede considerarse caso particular de una norma más general llamada **norma p**:

$$\|\mathbf{x}\|_p = \left( \sum_{j=1}^n |x_j|^p \right)^{1/p} ; p \geq 1$$

## Normas Vectoriales en $\mathbf{R}^n$ (2/3)

□ Casos particulares más utilizados de la *norma-p*:

➤ *Norma-1*: Se toma  $p=1$ ,

$$\|\mathbf{x}\|_1 = \sum_{j=1}^n |\mathbf{x}_j| = |\mathbf{x}_1| + |\mathbf{x}_2| + \dots + |\mathbf{x}_n|$$

➤ *Norma-2* ó *norma Euclídea*: Se toma  $p=2$ ,

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{j=1}^n |\mathbf{x}_j|^2} = \sqrt{\mathbf{x}_1^2 + \mathbf{x}_2^2 + \dots + \mathbf{x}_n^2}$$

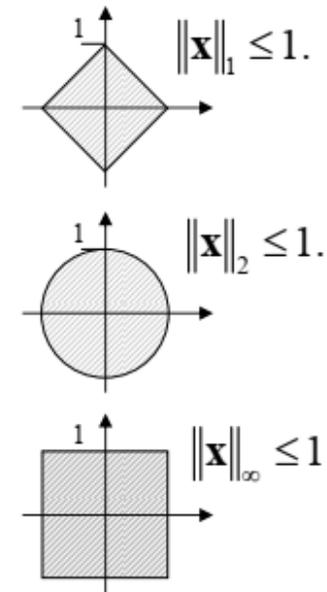
➤ *Norma- $\infty$*  ó *norma máxima*: Se toma  $p=\infty$ ,

$$\|\mathbf{x}\|_\infty = \lim_{p \rightarrow \infty} \|\mathbf{x}\|_p = \lim_{p \rightarrow \infty} \left( \sum_{j=1}^n |\mathbf{x}_j|^p \right)^{1/p} = \max_{1 \leq j \leq n} |\mathbf{x}_j|$$

➤ En la parte derecha de cada norma se muestra el lugar geométrico de los puntos de  $\mathbf{R}^2$  que cumplen la condición  $\|\mathbf{x}\| \leq 1$

➤ Es inmediato ver que se cumplen las condiciones 1 y 2 de la definición de norma. También se demuestra fácilmente que se cumple la condición 3;

$$\|\mathbf{x} + \mathbf{y}\|_1 = \sum_{j=1}^n |\mathbf{x}_j + \mathbf{y}_j| \leq \sum_{j=1}^n |\mathbf{x}_j| + \sum_{j=1}^n |\mathbf{y}_j| = \|\mathbf{x}\|_1 + \|\mathbf{y}\|_1$$



## Normas Vectoriales en $\mathbf{R}^n$ (3/3)

- Se enuncian dos Teoremas (sin demostración):
- Teorema 1:
  - Cada norma vectorial  $\|\mathbf{x}\|_p$  es una función continua de las componentes del vector  $\mathbf{x}$ , es decir, de  $x_1, x_2, \dots, x_n$ .
- Teorema 2:
  - Para cada dos normas vectoriales  $\|\mathbf{x}\|_i$  y  $\|\mathbf{x}\|_j$  existen dos constantes positivas  $m$  y  $M$  tales que:
 
$$m \|\mathbf{x}\|_i \leq \|\mathbf{x}\|_j \leq M \|\mathbf{x}\|_i, \forall \mathbf{x} \in \mathbf{R}^n$$
  - Este Teorema establece una *equivalencia* de las normas. Si con una determinada norma una secuencia de vectores tiende por ejemplo a cero, también tenderá a cero con cualquier otra norma

## Normas Matriciales (1/6)

### □ Norma de una matriz

- Una *norma de una matriz* es un número real positivo que "mide" el tamaño de una matriz, y permite por ejemplo estudiar cuando una matriz tiende a otra matriz o a la matriz nula.
- A la norma de una matriz se le exigen las *tres condiciones* que debía satisfacer la norma de un vector, y *una condición adicional* relacionada con el producto de matrices:

1.  $\|A\| \geq 0$ , y  $\|A\| = 0$  si y sólo si  $A=0$

2.  $\|\alpha A\| = |\alpha| \|A\|$ , para cualquier  $\alpha \in K$  ( $R$  o  $C$ )

3.  $\|A+B\| \leq \|A\| + \|B\|$  (desigualdad triangular)

4.  $\|A \cdot B\| \leq \|A\| \cdot \|B\|$

- Es posible definir normas de matrices directamente. Por otra parte, las matrices  $A \in R^{(m \times n)}$  forman un espacio vectorial Euclídeo con un producto escalar definido como  $\langle A, B \rangle = \text{traza}(A^T \cdot B)$ . Este producto escalar induce una norma, llamada *norma de Frobenius*, que responde a la expresión:

$$\|A\|_F = \sqrt{\langle A, A \rangle} = \left( \sum_{i=1}^m \sum_{j=1}^n a_{ij}^2 \right)^{1/2}$$

## Normas Matriciales (2/6)

- Norma matricial inducida por una norma vectorial (*norma natural*):

- En este caso la norma matricial se define a partir de una norma vectorial:

$$\|A\| = \max_{x \neq 0} \frac{\|A \cdot x\|}{\|x\|} \quad \text{o} \quad \|A\| = \max_{u \neq 0} \|A \cdot u\| = \|A \cdot y\| ; (\|y\| = 1)$$

donde  $y$  es el vector concreto de  $\mathbf{R}^n$  que produce el máximo (y la igualdad). El máximo se alcanza porque el conjunto de vectores  $u$  es cerrado y acotado.

- De esta definición de norma matricial se concluye que:

$$\|A \cdot x\| \leq \|A\| \|x\|$$

- Se cumplen las cuatro condiciones de la definición de norma matricial:

1. Si  $\|x\| \neq 0$ ,  $\|A\| \neq 0$  y  $\|A\| = 0$  sí y sólo si  $A = 0$

2.  $\|\alpha A\| = \max_{x \neq 0} \frac{\|\alpha Ax\|}{\|x\|} = \max_{x \neq 0} |\alpha| \frac{\|Ax\|}{\|x\|} = |\alpha| \|A\| \quad \forall \alpha \in K (R \text{ o } C)$

3.  $\|A + B\| = \|(A + B)y\| = \|Ay + By\| \leq \|Ay\| + \|By\| \leq \|A\| + \|B\|$

4.  $\|AB\| = \|(AB)y\| = \|A(By)\| \leq \|A\| \|By\| \leq \|A\| \cdot \|B\|$

- Se pueden estudiar las normas matriciales inducidas por las normas vectoriales:  $\|x\|_1$ ,  $\|x\|_2$  y  $\|x\|_\infty$  que se denotarán con la notación correspondiente

## Normas Matriciales (3/6)

- La expresión de la **norma-1** de una matriz es la siguiente:

$$\|A\|_1 = \max_k \sum_{j=1}^n |a_{jk}|$$

- Es decir, la norma-1 es el máximo de la suma de los valores absolutos de los elementos de cada **columna**.

- Demostración:

- Supóngase que la igualdad en la definición de la norma se alcanza para un vector  $y$  tal que

$$\|A\|_1 = \|A y\|_1, \text{ siendo } \|y\|_1 = 1$$

$$\|A\|_1 = \|A y\|_1 = \sum_{j=1}^n \left| \sum_{k=1}^n a_{jk} y_k \right| \leq \sum_{j=1}^n \sum_{k=1}^n |a_{jk}| |y_k| = \sum_{k=1}^n |y_k| \sum_{j=1}^n |a_{jk}| \leq$$

$$\leq \sum_{k=1}^n |y_k| \max_m \sum_{j=1}^n |a_{jm}| = \left( \max_m \sum_{j=1}^n |a_{jm}| \right) \sum_{k=1}^n |y_k| = \left( \max_m \sum_{j=1}^n |a_{jm}| \right) \|y\|_1 = \left( \max_m \sum_{j=1}^n |a_{jm}| \right)$$

- El desarrollo anterior demuestra que el máximo de las sumas de los valores absolutos de cada columna es un límite superior de la norma-1, pero para que sea verdaderamente la expresión de la norma este límite debe ser alcanzado.
- Supóngase que la columna que da el máximo es la columna  $K$ . Tomando como vector  $x$  al vector  $e_k$  de la base natural ( $\|e_k\|_1 = 1$ ):

$$\|A e_K\|_1 = \sum_{j=1}^n \left| \sum_{k=1}^n a_{jk} \delta_{kK} \right| = \sum_{j=1}^n |a_{jK}| = \|A\|_1$$

## Normas Matriciales (4/6)

- La expresión de la *norma-∞* de una matriz es la siguiente:

$$\|A\|_{\infty} = \max_k \sum_{j=1}^n |a_{kj}|$$

- Es decir, la norma-∞ es el máximo de la suma de los valores absolutos de los elementos de cada *fila*.

- Demostración:

- Supóngase que la igualdad en la definición de la norma se alcanza para un vector  $\mathbf{y}$  tal que:

$$\|A\|_{\infty} = \|A\mathbf{y}\|_{\infty}, \text{ siendo } \|\mathbf{y}\|_{\infty} = 1$$

$$\begin{aligned} \|A\|_{\infty} = \|A\mathbf{y}\|_{\infty} &= \max_j \left| \sum_{k=1}^n a_{jk} y_k \right| \leq \max_j \sum_{k=1}^n |a_{jk}| |y_k| \leq \\ &\leq \left( \max_k |y_k| \right) \left( \max_j \sum_{k=1}^n |a_{jk}| \right) = \max_j \sum_{k=1}^n |a_{jk}| \end{aligned}$$

- Al igual que el caso anterior, el máximo de las sumas de los valores absolutos de cada fila es un límite superior de la norma-∞, pero para que sea verdaderamente la expresión de la norma este límite debe ser alcanzado.
- Supóngase que la fila que da el máximo es la fila  $J$ . Se toma un vector  $\mathbf{x}$  tal que  $x_k = a_{Jk}/|a_{Jk}|$  si  $a_{Jk} \neq 0$  y  $x_k = 0$  si  $a_{Jk} = 0$

$$\|A\mathbf{x}\|_{\infty} = \max_j \left| \sum_{k=1}^n a_{jk} x_k \right| = \left| \sum_{k=1}^n a_{Jk} x_k \right| = \sum_{k=1}^n \left| \frac{a_{Jk}^2}{|a_{Jk}|} \right| = \sum_{k=1}^n |a_{Jk}| ; \|\mathbf{x}\|_{\infty} = 1$$

## Normas Matriciales (5/6)

- La expresión de la *norma espectral* o *norma-2* de una matriz es:

$$\|A\|_2 = \sqrt{\rho(A^H A)}$$

- Es decir, la norma-2 es la raíz cuadrada del máximo valor propio de la matriz  $A^H A$ , que es una *matriz hermítica* y –al menos– *semidefinida positiva*, cuyos valores propios son por tanto *reales* y *no negativos*.

$$A^H A u_j = \lambda_j u_j \Rightarrow \lambda_j = u_j^H A^H A u_j$$

- Demostración:

- La matriz  $A^H A$  tendrá una base ortonormal de vectores propios  $u_1, u_2, \dots, u_n$
- El vector  $y$  que produce la igualdad en la definición de la norma inducida se puede expresar como combinación lineal de los vectores propios  $u_j$ :

$$y = \sum_{k=1}^n \alpha_k u_k ; \|y\|_2^2 = \sum_{k=1}^n |\alpha_k|^2$$

- Aplicando ahora la definición de la norma-2 de un vector:

$$\begin{aligned} \|A\|_2^2 &= \|Ay\|_2^2 = y^H A^H A y = \left( \sum_{j=1}^n \bar{\alpha}_j u_j^H \right) A^H A \left( \sum_{k=1}^n \alpha_k u_k \right) = \\ &= \left( \sum_{j=1}^n \bar{\alpha}_j u_j^H \right) \left( \sum_{k=1}^n \alpha_k \lambda_k u_k \right) = \left( \sum_{k=1}^n \lambda_k |\alpha_k|^2 \right) \leq \left( \max_i \lambda_i \right) \left( \sum_{k=1}^n |\alpha_k|^2 \right) = \max_i \lambda_i = \rho(A^H A) \end{aligned}$$

- De nuevo éste es un límite superior, pero dicho límite se alcanza para  $x = u_n$ .

$$\|A u_n\|_2^2 = u_n^H A^H A u_n = u_n^H u_n \lambda_n = \lambda_n = \rho(A^H A)$$

## Normas Matriciales (6/6)

□ Teoremas relacionados con las normas matriciales (sin demostración)

- **Teorema 1:** Cualquier norma matricial es una función continua de los  $m \times n$  elementos de la matriz  $A \in C^{(m \times n)}$ .
- **Teorema 2:** Para cada par de normas matriciales existen unas constantes positivas  $m$  y  $M$  tales que:

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

Este Teorema permite hablar de "equivalencia de normas".

- **Teorema 3:** Para cualquier norma natural y cualquier matriz cuadrada  $A \in C^{(n \times n)}$  se verifica:  $\rho(A) \leq \|A\|$  pues

$$\|A\| = \max_{\|x\|=1} \|Ax\| \geq \|Au_n\| = \|\lambda_n u_n\| = |\lambda_n| \|u_n\| = |\lambda_n| = \rho(A)$$

- **Teorema 4:** Para cualquier matriz cuadrada  $A \in C^{(n \times n)}$  y cualquier valor  $\varepsilon$  arbitrariamente pequeño existe alguna norma natural tal que:

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

El radio espectral de una matriz cuadrada no es una norma (salvo que la matriz  $A$  sea normal, en cuyo caso  $\|A\|_2 = \rho(A)$ ), pero puede ser utilizado como tal dada su "cercanía".

- **Corolario:** Para cualquier matriz cuadrada  $A$ :  $\rho(A) = \inf_{\|\cdot\|} \|A\|$

## Números de Condición de una Matriz (1/4)

□ Recordatorio de conceptos ya estudiados en Álgebra:

- Matriz convergente  $\lim_{m \rightarrow \infty} \|\mathbf{A}^m\| = 0 \Leftrightarrow \rho(\mathbf{A}) < 1 \Leftrightarrow \lim_{m \rightarrow \infty} \mathbf{A}^m = \mathbf{0}$
- La serie  $\mathbf{I} + \mathbf{A} + \mathbf{A}^2 + \mathbf{A}^3 + \dots$  converge si  $\mathbf{A}$  es convergente.
- Si  $\mathbf{A}$  es convergente la matriz  $(\mathbf{I} - \mathbf{A})$  es no singular y se puede expresar como:  

$$(\mathbf{I} - \mathbf{A})^{-1} = \mathbf{I} + \mathbf{A} + \mathbf{A}^2 + \mathbf{A}^3 + \dots$$

□ Proposición:

- Si  $\|\mathbf{A}\| < 1$ , la matriz  $(\mathbf{I} - \mathbf{A})$  es no singular y se verifican las desigualdades:

$$\frac{1}{1 + \|\mathbf{A}\|} \stackrel{a)}{\leq} \left\| (\mathbf{I} - \mathbf{A})^{-1} \right\| \stackrel{b)}{\leq} \frac{1}{1 - \|\mathbf{A}\|}$$

Desigualdad a)

$$\mathbf{I} = (\mathbf{I} - \mathbf{A})(\mathbf{I} - \mathbf{A})^{-1}$$

$$1 \leq \|\mathbf{I} - \mathbf{A}\| \cdot \left\| (\mathbf{I} - \mathbf{A})^{-1} \right\| \leq (1 + \|\mathbf{A}\|) \cdot \left\| (\mathbf{I} - \mathbf{A})^{-1} \right\| \Rightarrow \frac{1}{1 + \|\mathbf{A}\|} \leq \left\| (\mathbf{I} - \mathbf{A})^{-1} \right\|$$

Desigualdad b)

$$(\mathbf{I} - \mathbf{A})^{-1}(\mathbf{I} - \mathbf{A}) = \mathbf{I} \Rightarrow (\mathbf{I} - \mathbf{A})^{-1} - (\mathbf{I} - \mathbf{A})^{-1}\mathbf{A} = \mathbf{I} \Rightarrow (\mathbf{I} - \mathbf{A})^{-1} = \mathbf{I} + (\mathbf{I} - \mathbf{A})^{-1}\mathbf{A}$$

$$\left\| (\mathbf{I} - \mathbf{A})^{-1} \right\| \leq 1 + \|\mathbf{A}\| \cdot \left\| (\mathbf{I} - \mathbf{A})^{-1} \right\| \Rightarrow \left\| (\mathbf{I} - \mathbf{A})^{-1} \right\| \leq \frac{1}{1 - \|\mathbf{A}\|}$$

## Números de Condición de una Matriz (2/4)

### □ Propagación de errores en SEAL:

- Error relativo en la solución debido al error en el término independiente:

$$\left. \begin{array}{l} \mathbf{Ax} = \mathbf{b} \\ \mathbf{A}(\mathbf{x} + \delta\mathbf{x}) = \mathbf{b} + \delta\mathbf{b} \end{array} \right\} \Rightarrow \left. \begin{array}{l} \mathbf{Ax} = \mathbf{b} \\ \mathbf{A}\delta\mathbf{x} = \delta\mathbf{b} \end{array} \right\} \Rightarrow \left. \begin{array}{l} \mathbf{Ax} = \mathbf{b} \\ \delta\mathbf{x} = \mathbf{A}^{-1}\delta\mathbf{b} \end{array} \right\} \Rightarrow \left. \begin{array}{l} \|\mathbf{b}\| \leq \|\mathbf{A}\|\|\mathbf{x}\| \\ \|\delta\mathbf{x}\| \leq \|\mathbf{A}^{-1}\|\|\delta\mathbf{b}\| \end{array} \right\}$$

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

- Error relativo en la solución debido al error en la matriz del sistema:

$$\left. \begin{array}{l} \mathbf{Ax} = \mathbf{b} \\ (\mathbf{A} + \delta\mathbf{A})(\mathbf{x} + \delta\mathbf{x}) = \mathbf{b} \end{array} \right\} \Rightarrow \mathbf{A}\delta\mathbf{x} + \delta\mathbf{A}(\mathbf{x} + \delta\mathbf{x}) = 0 \Rightarrow \delta\mathbf{x} = -\mathbf{A}^{-1}\delta\mathbf{A}(\mathbf{x} + \delta\mathbf{x})$$

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

- En ambas expresiones el error relativo en los datos se multiplica por un factor:

$$\boxed{\kappa(\mathbf{A}) \equiv \|\mathbf{A}^{-1}\|\|\mathbf{A}\|}, \quad \kappa(\mathbf{A}) \geq 1 \text{ pues } \mathbf{I} = \mathbf{A}^{-1}\mathbf{A}, \quad 1 \leq \|\mathbf{A}^{-1}\|\|\mathbf{A}\| = \kappa(\mathbf{A})$$

### □ Número de condición numérica:

- Se llama número de condición o condición numérica al escalar positivo  $\kappa(\mathbf{A})$  que controla la transmisión de errores en los sistemas de ecuaciones lineales

## Números de Condición de una Matriz (3/4)

### □ Fórmula general de propagación de errores en SEAL

- Los desarrollos matemáticos son este caso un poco más complicados. Se suponen unas perturbaciones en  $\mathbf{A}$  y  $\mathbf{b}$  que producen un error en  $\mathbf{x}$ :

$$(\mathbf{A} + \delta\mathbf{A})(\mathbf{x} + \delta\mathbf{x}) = \mathbf{b} + \delta\mathbf{b} \quad (1)$$

- Se supone que las perturbaciones en  $\mathbf{A}$  son pequeñas, de modo que se cumple:

$$\|\delta\mathbf{A}\| < \frac{1}{\|\mathbf{A}^{-1}\|} = \frac{\|\mathbf{A}\|}{\|\mathbf{A}^{-1}\|\|\mathbf{A}\|} = \frac{\|\mathbf{A}\|}{\kappa(\mathbf{A})} \Rightarrow \frac{\|\delta\mathbf{A}\|}{\|\mathbf{A}\|} \leq \frac{1}{\kappa(\mathbf{A})} \quad \kappa(\mathbf{A}) \equiv \text{condición numérica de } \mathbf{A}$$

- La matriz  $(\mathbf{A}^{-1}\delta\mathbf{A})$  es convergente, pues por hipótesis se cumple:

$$\|\mathbf{A}^{-1}\delta\mathbf{A}\| \leq \|\mathbf{A}^{-1}\|\|\delta\mathbf{A}\| < 1, \quad (\mathbf{I} + \mathbf{A}^{-1}\delta\mathbf{A}) \text{ no singular}$$

- Aplicando a la matriz  $(-\mathbf{A}^{-1}\delta\mathbf{A})$  la desigualdad de la proposición anterior:

$$\left\| (\mathbf{I} + \mathbf{A}^{-1}\delta\mathbf{A})^{-1} \right\| \leq \frac{1}{1 - \|\mathbf{A}^{-1}\delta\mathbf{A}\|} \leq \frac{1}{1 - \|\mathbf{A}^{-1}\|\|\delta\mathbf{A}\|} \quad (2)$$

- Desarrollando la expresión (1):

$$\mathbf{A}^{-1}(\mathbf{A} + \delta\mathbf{A})(\mathbf{x} + \delta\mathbf{x}) = \mathbf{A}^{-1}(\mathbf{b} + \delta\mathbf{b}) \Rightarrow (\mathbf{I} + \mathbf{A}^{-1}\delta\mathbf{A})(\mathbf{x} + \delta\mathbf{x}) = \mathbf{x} + \mathbf{A}^{-1}\delta\mathbf{b}$$

- Despejando  $\delta\mathbf{x}$  y tomando normas:

$$\delta\mathbf{x} = (\mathbf{I} + \mathbf{A}^{-1}\delta\mathbf{A})^{-1} \mathbf{A}^{-1}(\delta\mathbf{b} - \delta\mathbf{A}\mathbf{x}) \Rightarrow \|\delta\mathbf{x}\| \leq \left\| (\mathbf{I} + \mathbf{A}^{-1}\delta\mathbf{A})^{-1} \right\| \|\mathbf{A}^{-1}\| (\|\delta\mathbf{b}\| + \|\delta\mathbf{A}\|\|\mathbf{x}\|)$$

## Números de Condición de una Matriz (4/4)

### □ Fórmula general de propagación de errores en SEAL (cont.)

- Dividiendo por  $\|\mathbf{x}\|$  y teniendo en cuenta la desigualdad (2):

$$\frac{\|\delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \frac{1}{1 - \|\mathbf{A}^{-1}\|\|\delta\mathbf{A}\|} \|\mathbf{A}^{-1}\| \left( \frac{\|\delta\mathbf{b}\|}{\|\mathbf{x}\|} + \|\delta\mathbf{A}\| \right) \stackrel{\|\mathbf{b}\| \|\mathbf{A}\| = 1}{\Rightarrow} \frac{\|\delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \frac{\|\mathbf{A}^{-1}\|}{1 - \|\mathbf{A}^{-1}\|\|\delta\mathbf{A}\|} \left( \frac{\|\delta\mathbf{b}\|}{\|\mathbf{b}\|} \|\mathbf{A}\| + \|\delta\mathbf{A}\| \right)$$

- Haciendo aparecer la condición numérica  $\kappa(\mathbf{A})$  se llega finalmente a:

$$\frac{\|\delta\mathbf{x}\|}{\|\mathbf{x}\|} \leq \frac{\|\mathbf{A}^{-1}\|}{1 - \|\mathbf{A}^{-1}\|\|\delta\mathbf{A}\|} \left( \frac{\|\delta\mathbf{b}\|}{\|\mathbf{b}\|} \|\mathbf{A}\| + \|\delta\mathbf{A}\| \right) = \frac{\|\mathbf{A}^{-1}\|\|\mathbf{A}\|}{1 - \|\mathbf{A}^{-1}\|\|\mathbf{A}\| \frac{\|\delta\mathbf{A}\|}{\|\mathbf{A}\|}} \left( \frac{\|\delta\mathbf{b}\|}{\|\mathbf{b}\|} + \frac{\|\delta\mathbf{A}\|}{\|\mathbf{A}\|} \right)$$

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

- De nuevo la condición numérica es el factor que controla la amplificación (siempre es  $\kappa(\mathbf{A}) \geq 1$ ) de los errores relativos en los datos.
- La condición numérica no depende de la magnitud de los elementos de una matriz: Si la matriz se multiplica por el escalar  $\alpha$  la condición numérica permanece invariable.

## Números de Condición para la Norma Euclídea

□ Número de condición para la norma Euclídea o espectral:

➤ La norma euclídea de una matriz  $\mathbf{A} \in \mathbf{C}^{n \times n}$  es la raíz cuadrada del radio espectral de  $\mathbf{A}^H \mathbf{A}$ :

$$\|\mathbf{A}\|_2 = \sqrt{\rho(\mathbf{A}^H \mathbf{A})}$$

➤ La matriz  $\mathbf{A}^H \mathbf{A}$  es *hermítica* y todos sus valores propios son reales y no negativos, pues dicha matriz es –al menos– *semidefinida positiva*.

➤ Además, si la matriz  $\mathbf{A}$  es *normal* y sus valores propios son  $\lambda_j$ , los valores propios de la matriz  $\mathbf{A}^H \mathbf{A}$  son

$$\mathbf{U}^H \mathbf{A} \mathbf{U} = \mathbf{D}, \quad \mathbf{U}^H \mathbf{A}^H \mathbf{U} = \bar{\mathbf{D}} \quad \Rightarrow \quad \mathbf{U}^H \mathbf{A} \mathbf{U} \mathbf{U}^H \mathbf{A}^H \mathbf{U} = \mathbf{U}^H \mathbf{A} \mathbf{A}^H \mathbf{U} = \mathbf{D} \bar{\mathbf{D}}$$

$$\mathbf{U}^H \mathbf{A} \mathbf{A}^H \mathbf{U} = \mathbf{D} \bar{\mathbf{D}} = \text{diag}(|\lambda_1|^2, \dots, |\lambda_n|^2) \quad \Rightarrow \quad \|\mathbf{A}\|_2 = \sqrt{\rho(\mathbf{A}^H \mathbf{A})} = \sqrt{|\lambda_n|^2} = |\lambda_n| = \rho(\mathbf{A})$$

➤ Si la matriz  $\mathbf{A}$  es regular los valores propios de  $\mathbf{A}^{-1}$  son los inversos de los valores propios de  $\mathbf{A}$ . Por tanto, se verificará que:

$$\|\mathbf{A}^{-1}\|_2 = \sqrt{\rho(\mathbf{A}^{-H} \mathbf{A}^{-1})} = \sqrt{\frac{1}{\lambda_1^2}} = \frac{1}{|\lambda_1|} = \rho(\mathbf{A}^{-1})$$

➤ De acuerdo con esto, el número de condición de una matriz normal y regular será:

$$\kappa^{(2)}(\mathbf{A}) = \|\mathbf{A}^{-1}\|_2 \|\mathbf{A}\|_2 = \rho(\mathbf{A}^{-1}) \rho(\mathbf{A}) = \frac{|\lambda_n|}{|\lambda_1|}$$

## Consideraciones Generales y Conclusiones

- Consideraciones sobre las fórmulas de propagación del error
  - La *condición numérica* indica cómo se amplifican los errores  $\delta A$  y  $\delta b$ .
  - Como mínimo estos errores son de la *precisión de los datos* ( $\epsilon = 2.22e-16$ ).
  - Además, en el transcurso de los cálculos se introducen errores de redondeo. Existen dos formas de estudiar los efectos de estos errores:
    - ✓ El *análisis directo* considera el error en cada operación y trata de estudiar cómo se propaga y acumula hasta el resultado final. Conduce a resultados muy pesimistas.
    - ✓ El *análisis inverso* (Wilkinson, 1965) considera los errores de redondeo como perturbaciones en los datos iniciales y trata de acotarlos. Los resultados son mucho más precisos.

$$\left| (\delta A)_{ij} \right| \leq 2n\epsilon \max_{1 \leq i, j, k \leq n} \left| a_{ij}^{(k)} \right|$$

- Resultado del análisis inverso de errores con la factorización:  $L*U* = (A + \delta A)$  donde  $n$  es el número de ecuaciones,  $\epsilon$  es la precisión de la máquina ( $2.22e-16$  para las PCs) y  $a_{ij}^{(k)}$  son los elementos que van apareciendo en  $A$  en el proceso de factorización.
- El pivotamiento por columnas basta para evitar que estos elementos crezcan incontroladamente.
- Las matrices definidas positivas no necesitan pivotamiento y no suelen dar problemas de errores de redondeo.
- Conviene estimar los errores a través de un número de condición aproximado.