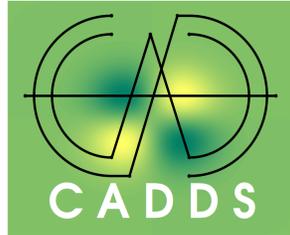


**Lecturas de Optimización Numérica:**  
**FACTORIZACIONES MATRICIALES, SERIES DE NEUMANN Y**  
**DESCOMPOSICIONES ORTOGONALES**



Prof. Dr. Fredy Vides  
*Scientific Computing Innovation Center, UNAH &*  
*Centre for Analysis of Data-Driven Systems*  
*E-mail: fredy.vides@unah.edu.hn*

ÍNDICE

Objetivos	1
1. Factorizaciones Matriciales	1
1.1. Factorización LU	1
2. Matrices Simétricas Positivas Definidas	2
3. Factorización de Cholesky	4
4. Series de Neumann	4
5. Principios de Métodos de Gradiente Conjugado: Un Enfoque Iterativo	6
6. Principios de Despomposiciones ortogonales y Descomposición en valores singulares	6
6.1. Descomposición QR	6
6.2. Descomposición en valores singulares	7
Referencias	7

OBJETIVOS

1. Estudiar algunas propiedades elementales de las factorizaciones matriciales.
2. Estudiar algunas propiedades elementales de las series matriciales de Neumann.

1. FACTORIZACIONES MATRICIALES

**1.1. Factorización LU.** Considerando un sistema de ecuaciones lineales representado en forma matricial:

$$(1.1) \quad Ax = b$$

donde  $A \in \mathbb{R}^{n \times n}$ ,  $b \in \mathbb{R}^n$  están dados, y  $x \in \mathbb{R}^n$  debe determinarse resolviendo el sistema (1.1).

**Observación.** Como se establece en §6.1 y §6.5 del libro de texto [1], al aplicar un algoritmo de eliminación gaussiana para resolver (1.1) se necesitan  $\mathcal{O}(n^3/3)$  operaciones aritméticas.

**Notación.** En este curso,  $\mathbb{GL}_n$ ,  $\mathbb{D}(n)$ ,  $\mathbb{I}(n)$  y  $\mathbb{S}(n)$  denotarán los conjuntos de matrices invertibles, diagonales, triangulares inferiores, y triangulares superiores en  $\mathbb{R}^{n \times n}$  (en el sentido estudiado en MM 211 vectores y matrices), respectivamente.

**Notación:** En este curso, al considerar un sistema de ecuaciones  $Ax = b$  se asumirá, a menos que se especifique lo contrario, que  $A, x$  son compatibles en el producto, y que  $Ax$  y  $b$  pertenecen al mismo tipo de vectores (matrices).

**Propiedad.** Si la eliminación gaussiana se puede realizar en el sistema lineal  $Ax = b$  sin intercambios de renglones, entonces la matriz  $A$  se puede factorizar como el producto de una matriz triangular  $L = [l_{jk}] \in \mathbb{I}(n)$  y una matriz triangular superior  $U = [u_{jk}] \in \mathbb{S}(n)$ , es decir,  $A = LU$ , donde  $l_{jj} = 1$ , para  $j = 1, \dots, n$ .

Considerando el siguiente procedimiento para resolver un sistema  $Ax = b$  tal que  $A$  puede factorizarse como  $A = LU$ :

1. Solución del sistema  $Ax = b$  por factorización LU:
  - a) Definir  $y = Ux$  (consideración teórica, no se realiza ninguna operación).
  - b) Resolver  $Ly = b$  (se requieren  $\mathcal{O}(n^2)$  operaciones dado que  $L \in \mathbb{I}(n)$ ).
  - c) Resolver  $Ux = y$  (se requieren  $\mathcal{O}(n^2)$  operaciones dado que  $U \in \mathbb{S}(n)$ ).

**Observación.** Al aplicar la factorización LU el número de operaciones necesario para resolver el sistema  $Ax = b$  se reduce a partir de  $\mathcal{O}(n^3/3)$  a  $\mathcal{O}(2n^2)$ .

## 2. MATRICES SIMÉTRICAS POSITIVAS DEFINIDAS

En la clase de vectores y matrices se estableció que  $A \in \mathbb{R}^{n \times n}$  es simétrica si  $A^\top = A$ .

**Definición.** Decimos que una matriz simétrica  $A \in \mathbb{R}^{n \times n}$  es positiva semi-definida o **SPSD**, si para cada  $x \in \mathbb{R}^n$  se cumple que  $x^\top Ax \geq 0$ . Si  $A \in \mathbb{R}^{n \times n}$  es una matriz simétrica que cumple la restricción  $x^\top Ax > 0$  para cada  $x \in \mathbb{R}^n \setminus \{0\}$ , se dice que  $A$  es simétrica positiva definida o **SPD**.

**Notación.** En este curso también utilizaremos la notación  $A > 0$  para denotar que la matriz  $A \in \mathbb{R}^{n \times n}$  es SPD, las matrices SPD también serán llamadas definidas positivas (**DP**) o positivas definidas (**PD**) en este curso.

**Definición.** Una **primera submatriz principal** de una matriz  $A$  es una matriz  $A_k$  de la forma

$$A_k = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1k} \\ a_{21} & a_{22} & \cdots & a_{2k} \\ \vdots & \vdots & & \vdots \\ a_{k1} & a_{k2} & \cdots & a_{kk} \end{bmatrix}$$

para algunas  $1 \leq k \leq n$ .

**Propiedades.** Si  $A \in \mathbb{R}^{n \times n}$  es una matriz SPD:

1.  $A \in \mathbb{GL}_n$ ;
2.  $a_{ii} > 0$ , para cada  $i = 1, 2, \dots, n$ ;
3.  $\max_{1 \leq k, j \leq n} |a_{kj}| \leq \max_{1 \leq i \leq n} |a_{ii}|$ ;
4.  $(a_{ij})^2 < a_{ii}a_{jj}$  para cada  $i \neq j$

**Propiedad.** Dada una matriz  $A \in \mathbb{R}^{n \times n}$ , las siguientes proposiciones son equivalentes:

1.  $A$  es SPD;
2.  $\det(A_k) > 0$  para cada una de sus primeras submatrices principales;

3. Se puede realizar eliminación gaussiana sin intercambios de renglones en el sistema  $Ax = b$  con todos los elementos pivote positivos.
4.  $A$  se puede factorizar como  $A = LDL^T$ , donde  $L \in \mathbb{I}(n)$ ,  $D \in \mathbb{D}(n)$ , con  $d_{jj} > 0$  y  $l_{jj} = 1$ , para cada  $1 \leq j \leq n$ .
5.  $A$  se puede factorizar en la forma  $A = LL^T$ , donde  $L = [l_{jk}] \in \mathbb{I}(n)$  y  $l_{jj} \neq 0$  para cada  $1 \leq j \leq n$ .

**Ejemplo computacional.** Consideremos la matriz:

$$U = \begin{bmatrix} 1 & -1 & 0 \\ 0 & 1 & -1 \\ 0 & 0 & 1 \end{bmatrix}$$

Es claro que la matriz:

$$A = U^T U = \begin{bmatrix} 1 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix}$$

es SPD dado que para cada  $x \in \mathbb{R}^3 \setminus \{0\}$ :

$$x^T A x = x^T U^T U x = (Ux)^T (Ux) = (Ux) \cdot (Ux) = \|Ux\|_2^2 > 0$$

dado que  $Ux \neq 0$ , debido a que  $x \neq 0$ , y que  $U \in \mathbb{GL}_n$  como consecuencia de que  $\det(U) = 1 > 0$ . Podemos ahora calcular los determinantes de las primeras submatrices principales  $A_1, A_2, A_3$

$$A_1 = [1], A_2 = \begin{bmatrix} 1 & -1 \\ -1 & 2 \end{bmatrix}, A_3 = A$$

con las siguientes secuencias de comandos:

```
>> A1=A(1,1)
A1 = 1
>> A2=A(1:2,1:2)
A2 =

    1  -1
   -1   2

>> A3=A(1:3,1:3)
A3 =

    1  -1   0
   -1   2  -1
    0  -1   2

>> det(A1)
ans = 1
>> det(A2)
ans = 1
>> det(A3)
ans = 1
```

Es posible observar que todos los determinantes son positivos, como lo establecen las propiedades previas.

### 3. FACTORIZACIÓN DE CHOLESKY

**Propiedad.** Si  $A \in \mathbb{R}^{n \times n}$  es una matriz simétrica, tal que se puede aplicar eliminación gaussiana sin intercambios de renglones al sistema  $Ax = b$  correspondiente. Entonces  $A$  se puede factorizar como  $A = LDL^T$ , donde  $L \in \mathbb{I}(n)$ ,  $D \in \mathbb{D}(n)$  con  $l_{jj} = 1$ , para cada  $1 \leq j \leq n$ .

**Algunas Observaciones:**

1. Por propiedades previas de matrices SPD, y por la propiedad anterior, tenemos que para cada  $A \in \mathbb{R}^{n \times n}$  SPD,  $A = LDL^T \implies$

$$\det(A) = \det(LDL^T) = \det(L) \det(D) \det(L^T) = 1 \cdot \det(D) \cdot 1 = \det(D)$$

2. Dado que  $L \in \mathbb{GL}_n$  como consecuencia de que  $\det(L) = 1 \neq 0$ ,  $A = LDL^T \implies$

$$L^{-1}A(L^{-1})^T = D$$

de manera que  $D = L^{-1}A(L^{-1})^T$  es claramente SPD, dado que para cada  $x \in \mathbb{R}^n \setminus \{0\}$ :

$$x^T Dx = x^T L^{-1}A(L^{-1})^T x = ((L^{-1})^T x)^T A((L^{-1})^T x) > 0$$

dado que  $A$  es SPD, y dado que  $(L^{-1})^T x \neq 0$  siempre que  $x \neq 0$  debido que  $L \in \mathbb{GL}_n$ .

Por propiedades de matrices SPD  $D = L_D L_D^T$  para  $L_D \in \mathbb{I}(n)$ , y por las ecuaciones previas, tenemos entonces que,

$$A = LL_D L_D^T L^T = LL_D (LL_D)^T$$

si definimos  $L_A = LL_D$  tenemos entonces que.

$$A = L_A L_A^T$$

**Definición.** Dada una matriz  $A \in \mathbb{R}^{n \times n}$  SPD, la factorización  $LL^T = A$  con  $L \in \mathbb{I}(n)$ , recibe el nombre de factorización de **Cholesky** de  $A$ .

### 4. SERIES DE NEUMANN

Consideremos una norma matricial (inducida)  $\|\cdot\| : \mathbb{R}^{n \times n} \rightarrow \mathbb{R}$  arbitraria.

Dada una matriz  $X \in \mathbb{R}^{n \times n}$ , sea  $S_N(X)$  la matriz definida por la expresión:

$$S_N(X) = \sum_{k=0}^N X^k$$

**Definición.** Dada una matriz  $A \in \mathbb{R}^{n \times n}$ , se define la serie matricial de Neumann  $\mathbb{N}(A)$  de  $A$  como la serie matricial dada por la expresión:

$$\mathbb{N}(A) = \sum_{k=0}^{\infty} A^k$$

Si suponemos que  $\|A\| < 1$  (donde  $I$  denota la identidad compatible en la suma con  $A$ ),

tenemos que:

$$\begin{aligned}(I - A) \left( \sum_{k=0}^N A^k \right) &= (I - A)(I + A + A^2 + \dots + A^{N-1} + A^N) \\ &= I - A^{N+1}\end{aligned}$$

$\implies$

$$\begin{aligned}\left\| (I - A) \left( \sum_{k=0}^N A^k \right) - I \right\| &= \|I - A^{N+1} - I\| \\ &= \| -A^{N+1} \| \\ &\leq \|A\| \xrightarrow[N \rightarrow \infty]{N+1} 0\end{aligned}$$

$\implies S_N(A) \rightarrow \mathbb{N}(A) = (I - A)^{-1}$  ( $S_N(A)$  converge a  $\mathbb{N}(A) = (I - A)^{-1}$  con respecto a la distancia inducida por  $\|\cdot\|$ ). Consideremos ahora una matriz  $A \in \mathbb{R}^{n \times n}$  tal que  $\|I - A\| < 1$ . Por las observaciones previas, tenemos que.

$$S_N(I - A) \rightarrow \mathbb{N}(A) = (I - (I - A))^{-1} = A^{-1}$$

Consideremos ahora  $A, B \in \mathbb{G}\mathbb{L}_n$  tales que  $\|I - BA\| < 1$  y  $\|I - AB\| < 1$ , tenemos entonces que:

$$S_N(I - AB) \rightarrow (AB)^{-1} = B^{-1}A^{-1}$$

$\implies$

$$BS_N(I - AB) \rightarrow BB^{-1}A^{-1} = A^{-1}$$

De forma similar se cumple también que:

$$S_N(I - BA) \rightarrow (BA)^{-1} = A^{-1}B^{-1}$$

$\implies$

$$S_N(I - BA)B \rightarrow A^{-1}B^{-1}B = A^{-1}$$

Las expresiones normadas anteriores nos permiten pensar en  $B$  como una aproximación de  $A^{-1}$ , dado que en el caso exacto  $B = A^{-1}$ , se tendría que  $\|I - BA\| = \|I - I\| = \|\mathbf{0}\| = 0 < 1$ , y de forma similar  $\|I - AB\| = \|I - I\| = \|\mathbf{0}\| = 0 < 1$ . De manera que si consideramos el sistema de ecuaciones  $Ax = b$ ,  $y = BAx = Bb$  sería una primer aproximación de la solución  $x$  del sistema, y podemos refinar (mejorar la precisión) de la aproximación  $y \approx x$  utilizando el esquema iterativo:

$$S_N(I - BA)y = S_N(I - BA)Bb \rightarrow A^{-1}B^{-1}Bb = A^{-1}b = x$$

**Ejercicio para el lector:** Verificar en detalle que  $S_N(I - BA)y \rightarrow x$  con respecto a la distancia inducida por la norma vectorial correspondiente (que a su vez induce la norma vectorial en consideración), es decir, demostrar que:

$$\lim_{N \rightarrow \infty} \|S_N(I - BA)y - x\| = 0$$

bajo las hipótesis consideradas en los argumentos anteriores.

**Ejercicio para el lector:** Probar o refutar que para cada  $A, B \in \mathbb{R}^{n \times n}$  y cada entero  $k \geq 0$ :

$$A(I - BA)^k = (I - AB)^k A$$

**Ejercicio para el lector:** Dadas  $A, B \in \mathbb{GL}_n$  y un vector  $b \in \mathbb{R}^n$ , diseñar un algoritmo iterativo que permita calcular las siguientes expresiones en términos de productos matriz vector, evitando en la medida de lo posible productos matriz-matriz explícitamente calculados:

$$y_N = S_N(I - BA)Bb$$

$$z_N = BS_N(I - AB)b$$

## 5. PRINCIPIOS DE MÉTODOS DE GRADIENTE CONJUGADO: UN ENFOQUE ITERATIVO

Consideremos una matriz  $A \in \mathbb{R}^{n \times n}$  arbitraria y un vector arbitrario  $b \in \mathbb{R}^n$ , y consideremos el funcional cuadrático:

$$q_{A,b}(x) = x^\top Ax - 2x^\top b$$

**Propiedad.** Si  $A \in \mathbb{R}^{n \times n}$  es SPD, resolver el sistema  $Ax = b$  equivale a resolver el siguiente problema de programación cuadrática.

$$(5.1) \quad \min_{x \in \mathbb{R}^n} q_{A,b}(x)$$

La solución de los problemas cuadráticos de la forma (5.1) correspondientes a un sistema  $Ax = b$  con matriz de coeficientes  $A$  SPD, pueden resolverse implementando métodos de gradiente conjugado que producen una secuencia  $\{x_k\}_{k \geq 0} \subset \mathbb{R}^n$  tal que  $x_k \rightarrow x = A^{-1}b$  y donde cada elemento  $x_k$  de la sucesión está dado por la expresión:

$$x_k = x_{k-1} + \alpha_{k-1}p_{k-1}, \quad k \geq 1$$

donde  $\alpha_k \in \mathbb{R}$  y  $p_k \in \mathbb{R}^n$  se calculan de acuerdo a criterios de optimización que serán estudiados en detalle más adelante, y  $x_0 \in \mathbb{R}^n$  es un elemento que se utiliza para inicializar el esquema iterativo.

## 6. PRINCIPIOS DE DESCOMPOSICIONES ORTOGONALES Y DESCOMPOSICIÓN EN VALORES SINGULARES

**6.1. Descomposición QR.** Iniciamos esta sección recordando que por el teorema de ortogonalización de Gram-Schmidt dados  $x_1, \dots, x_m \in \mathbb{R}^n$  linealmente independientes, existen  $q_1, \dots, q_m \in \mathbb{R}^n$  ortonormales tales que:

$$\text{gen} \{x_1, \dots, x_m\} = \text{gen} \{q_1, \dots, q_m\}$$

Además si  $X, Q \in \mathbb{R}^{n \times m}$  son las matrices definidas por las expresiones:

$$X = \begin{bmatrix} | & & | \\ x_1 & \cdots & x_m \\ | & & | \end{bmatrix}$$

$$Q = \begin{bmatrix} | & & | \\ q_1 & \cdots & q_m \\ | & & | \end{bmatrix}$$

Se cumple que:

$$Q^\top Q = I_m$$

$$Q^\top X = R$$

$$QR = X$$

donde  $I_m$  representa la matriz identidad en  $\mathbb{R}^{m \times m}$  y  $R \in \mathbb{S}(m)$ . La descomposición ortogonal  $X = QR$  recibe el nombre de descomposición QR de  $X$ .

**Notación.** Una matriz  $U \in \mathbb{R}^{n \times m}$  que cumple  $U^T U = I_m$  se denominará **matriz ortogonal** en este curso.

**Notación.** El conjunto de matrices ortogonales en  $\mathbb{R}^{n \times m}$ , será denotado por  $\mathbb{O}(n, m)$ , en el caso de las matrices ortogonales en  $\mathbb{R}^{n \times n}$ , en algunas ocasiones se escribirá  $\mathbb{O}(n)$  en lugar de  $\mathbb{O}(n, n)$ .

**Ejercicio para el lector:** Aplicar el teorema de ortogonalización de Gram-Schmidt para verificar que toda matriz  $X \in \mathbb{R}^{n \times m}$  con columnas linealmente independientes tiene una factorización QR.

**Pregunta para el lector:** Es posible que toda matriz  $X \in \mathbb{R}^{n \times n}$  tenga una factorización QR?

**6.1.1. Matrices de Permutación.** Un tipo especial de matrices ortogonales en  $\mathbb{R}^{n \times n}$ , son las matrices de permutación, las cuales se obtienen a partir de la matriz identidad  $I \in \mathbb{R}^{n \times n}$  permutando sus columnas (o renglones).

**Ejemplos.** En  $\mathbb{R}^{4 \times 4}$  las siguientes matrices son ejemplos de matrices de permutación:

$$Q_1 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, Q_2 = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}, Q_3 = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 \end{bmatrix}, Q_4 = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

**Ejercicio para el lector.** Calcular el número de matrices de permutación en  $\mathbb{R}^{n \times n}$ .

**6.2. Descomposición en valores singulares.** En esta sección consideraremos por primera vez uno de los teoremas fundamentales del análisis matricial numérico.

**Propiedad (Teorema fundamental de descomposición en valores singulares SVD)** Si  $A \in \mathbb{R}^{m \times n}$ , entonces existen matrices ortogonales  $U \in \mathbb{R}^{m \times m}$  y  $V \in \mathbb{R}^{n \times n}$  tales que:

$$U^T A V = \Sigma = \text{diag}(\sigma_1, \dots, \sigma_p) \in \mathbb{R}^{m \times n}, \quad p = \min\{m, n\}$$

donde  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p \geq 0$ .

Donde  $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_p) \in \mathbb{R}^{m \times n}$  es una matriz en  $\mathbb{R}^{m \times n}$  determinada por la expresión:

$$\Sigma_{jk} = \begin{cases} \sigma_j, & j = k \\ 0, & j \neq k \end{cases}, \quad 1 \leq j \leq p$$

#### REFERENCIAS

- [1] R. L. Burden, D. J. Faires, A. M. Burden. (2017). Análisis Numérico. 10a Ed. Cengage Learning Editores.
- [2] Golub, G. H., Van Loan C. F (1996). Matrix Computations (3aEd.). The Johns Hopkins University Press.
- [3] Quarteroni A., Saleri F., Gervasio P. (2014). Scientific computing with MATLAB and Octave (Textbook).
- [4] D. G. Luenberger, Y. Ye. (2016). Linear and Nonlinear Programming. 4a Ed. Springer International Publishing Switzerland.