

# Descomposición del valor singular y sus aplicaciones

Marlene J. Soldevilla Olivares<sup>1</sup>, William C. Echegaray Castillo†

## Resumen

El presente trabajo damos algunas propiedades de los valores singulares de una matriz  $A \in \mathbb{R}(m, n)$  que son las raíces cuadradas de los valores propios de  $A^T A$ , y de esta forma se tiene una relación muy importante entre los valores singulares y los valores propios y así obtener aplicaciones importantes en ingeniería, biología, cálculo variacional, etc.

## 1. INTRODUCCIÓN

Sabemos que toda matriz  $A \in \mathbb{C}(m, n)$  puede ser descompuesta en  $A = UDV^*$ , donde  $U$  y  $V$  son matrices unitarias,  $D$  es una matriz que posee una submatriz diagonal diagonal. Si  $A \in \mathbb{R}(m, n)$ , entonces  $U$  y  $V$  son matrices ortogonales reales.

Vamos a suponer en adelante que  $A \in \mathbb{R}(m, n)$ . Esta descomposición es llamada *DESCOMPOSICIÓN DEL VALOR SINGULAR DE A*.

## 2. EXISTENCIA DE LA DESCOMPOSICIÓN DEL VALOR SINGULAR

**Teorema 2.1.** Sea  $A \in \mathbb{R}(m, n)$  una matriz. Entonces existen matrices ortogonales  $U \in \mathbb{R}(m, m)$  y  $V \in \mathbb{R}(n, n)$  tales que:

$$U^T A V = \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} = D_{m \times n}$$

---

1. Facultad de Ciencias-Universidad Nacional de Ingeniería  
† Facultad de Ciencias-Universidad Nacional de Ingeniería

donde  $D_1$  es una matriz diagonal no singular,  $0$  son matrices nulas. Los elementos de la diagonal de  $D_1$  son no-negativos y estos pueden, sin pérdida de generalidad, ser ordenados en forma no creciente. El número de elementos en la diagonal de  $D_1$  es igual al  $r(A)$  (rango de  $A$ ).

**Prueba:**

Consideremos la matriz  $B = A^T A$

$\Rightarrow B$  es una matriz simétrica semidefinida positiva.

$\Rightarrow$  los valores propios de  $B$  son no-negativos.

Sean  $\lambda_1 = \sigma_1^2, \lambda_2 = \sigma_2^2, \dots, \lambda_n = \sigma_n^2$  los valores propios de  $B$  y supongamos que:  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  y  $\sigma_{r+1} = \sigma_{r+2} = \dots = \sigma_n = 0$

Sean  $v_1, v_2, \dots, v_n$  los vectores propios asociados a  $\lambda_1, \lambda_2, \dots, \lambda_n$ .

Como  $B$  es simétrica, entonces  $\{v_1, v_2, \dots, v_n\}$  es un conjunto ortonormal y satisfice:

$$Bv_i = \lambda_i v_i \quad i = 1, 2, \dots, n$$

$$\Rightarrow A^T A v_i = \sigma_i^2 v_i \quad i = 1, 2, \dots, n$$

$$\Rightarrow v_i^T (A^T A) v_i = \sigma_i^2 v_i^T v_i \quad i = 1, 2, \dots, n$$

$$\Rightarrow v_i^T (A^T A) v_i = \sigma_i^2 \quad i = 1, 2, \dots, n$$

$$\Rightarrow v_i^T (A^T A) v_i = \sigma_i^2 > 0 \quad i = 1, 2, \dots, r \quad (1)$$

$$\text{y} \quad v_i^T (A^T A) v_i = 0 \quad i = r + 1, \dots, n \quad (2)$$

$$\text{además} \quad v_i^T (A^T A) v_j = 0 \quad i, j = 1, 2, \dots, r; i \neq j \quad (3)$$

Definamos:

$V_1 = \{v_1, v_2, \dots, v_r\}$  donde  $v_i$  son vectores asociados a  $\lambda_i, i = 1, 2, \dots, r$ .  
 $V_2 = \{v_{r+1}, \dots, v_n\}$  donde  $v_i$  son vectores asociados a  $\lambda_i = 0, i = r + 1; \dots, n$ .

Entonces

$$V_2^T A^T A V_2 = V_2^T (A^T A) (v_{r+1}, \dots, v_n)$$

$$= V_2^T (A^T A v_{r+1}, \dots, A^T A v_n)$$

$$= V_2^T (0, 0, \dots, 0)$$

$$\Rightarrow V_2^T A^T A V_2 = 0$$

$$\Rightarrow \|A V_2\| = 0$$

$$\Rightarrow A V_2 = 0$$

$$\Rightarrow A v_k = 0 \quad k = r + 1, \dots, n \quad (4)$$

$$\text{Definamos } u_i = \frac{1}{\sigma_i} A v_i, i = 1, \dots, r \quad (5)$$

Veamos que  $\{u_i\}, i = 1, \dots, r$  es un conjunto ortonormal

$$u_i^T u_j = \frac{1}{\sigma_i} (A v_i)^T \frac{1}{\sigma_j} (A v_j)$$

$$= \frac{1}{\sigma_i \sigma_j} v_i^T (A^T A) v_j \quad (6)$$

$$= \begin{cases} 0 & \text{si } i \neq j \text{ por (3)} \\ 1 & \text{si } i = j \text{ por (1)} \end{cases}$$

$\Rightarrow \{u_i\}, i = 1, \dots, r$  es un conjunto ortonormal.

Definamos  $U_1 = (u_1, u_2, \dots, u_r)$  y elijamos  $U_2 = (u_{r+1}, u_{r+2}, \dots, u_n)$  tal que  $U = (U_1; U_2)$  sea una matriz ortogonal.

Entonces, para cualquier  $k > r$ , tenemos:

$$u_k^T Av_i = \sigma_i u_k^T u_i \quad i = 1, \dots, r \quad \text{por (5)}$$

$$= 0 \quad \text{por (6)}$$

$$\Rightarrow u_k^T Av_i = 0 \quad i = 1, \dots, r$$

$$y u_k^T Av_i = 0 \quad i = r+1, \dots, n \quad \text{por (4)}$$

Sea  $V = (V_1, V_2)$

$$(U^T) AV = \begin{pmatrix} u_1^T \\ u_2^T \\ \vdots \\ u_m^T \end{pmatrix} A(v_1, v_2, \dots, v_n) = \begin{pmatrix} \frac{1}{\sigma_1} v_1^T A^T \\ \frac{1}{\sigma_2} v_2^T A^T \\ \vdots \\ \frac{1}{\sigma_r} v_r^T A^T \\ u_{r+1}^T \\ \vdots \\ u_m^T \end{pmatrix} A(v_1, v_2, \dots, v_n)$$

$$= \begin{pmatrix} \sigma_1 & 0 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \sigma_2 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & 0 & \sigma_3 & \dots & 0 & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & \sigma_r & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 0 & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 0 & 0 & \dots & 0 \end{pmatrix}_{m \times n} = \begin{pmatrix} D_1 & 0 \\ 0 & 0 \end{pmatrix}_{m \times n} = D$$

entonces

$$U^T AV = \begin{pmatrix} D_1 & 0 \\ 0 & 0 \end{pmatrix} = D_{m \times n}$$

donde  $D_1 = \text{diag}(\sigma_1, \dots, \sigma_r) \in \mathbb{R}(r, r)$   
 Veamos que  $r(A) = r(D) = r$ :

$$\begin{aligned} \text{Como} \quad U^T AV &= D \\ \Rightarrow UU^T AV &= UD \\ AV &= UD \quad (UU^T = I_{m \times m} \text{ ortogonal}) \\ \Rightarrow AVV^T &= UDV^T \\ \Rightarrow A &= UDV^T \quad (VV^T = I_{n \times n} \text{ ortogonal}) \\ \Rightarrow r(A) &= r(UDV^T) = r(D) = r \end{aligned}$$

**Definición 2.0.1.** Las componentes de la diagonal de la matriz  $D$  son llamadas VALORES SINGULARES DE  $A$ , los números  $\sigma_1, \dots, \sigma_r$  son llamados valores singulares positivos.

**Definición 2.0.2.** Las columnas de  $U$  son llamadas VECTORES SINGULARES POR LA IZQUIERDA DE  $A$  y los de  $V$  VECTORES SINGULARES POR LA DERECHA DE  $A$ .

**2.1 UNICIDAD DE LA DESCOMPOSICIÓN DEL VALOR SINGULAR**

Existen  $k = \min(\{m, n\})$  valores singulares de  $A$ .

Sea  $r = r(A)$

$\Rightarrow \exists$  valores singulares positivos.

Sean  $\sigma_1 = \sqrt{\lambda_1}, \sigma_2 = \sqrt{\lambda_2}, \dots, \sigma_r = \sqrt{\lambda_r} > 0$ , donde  $\lambda_1, \lambda_2, \dots, \lambda_r$  son los valores propios de  $A^T A$ .

Si  $r < k \Rightarrow$  los  $(k - r)$  valores singulares son ceros (teorema 2.1).

Luego los valores singulares son únicos. Sin embargo los vectores singulares no son únicos.

**Ejemplo 2.1.1.** Calcular los valores y vectores singulares de:

$$A = \begin{pmatrix} 1 & 2 \\ 2 & 3 \\ 3 & 4 \end{pmatrix}$$

**1. Cálculo de Valores Singulares:**

Sea

$$B = A^T A = \begin{pmatrix} 1 & 2 & 3 \\ 2 & 3 & 4 \end{pmatrix} \begin{pmatrix} 1 & 2 \\ 2 & 3 \\ 3 & 4 \end{pmatrix} = \begin{pmatrix} 14 & 20 \\ 20 & 29 \end{pmatrix}$$

Entonces el polinomio característico de  $B$  es:

$$\begin{vmatrix} 14 - \lambda & 20 \\ 20 & 29 - \lambda \end{vmatrix} = (14 - \lambda)(29 - \lambda) - 400$$

Luego los ceros del polinomio anterior son:

$$\lambda_1 = \frac{1}{2}(43 + 5\sqrt{73}) \quad \text{y} \quad \lambda_2 = \frac{1}{2}(43 - 5\sqrt{73})$$

Entonces los valores singulares de  $A$  son:

$$\sigma_1 = \sqrt{\lambda_1} = \sqrt{\frac{1}{2}(43 + 5\sqrt{73})} \quad \text{y} \quad \sigma_2 = \sqrt{\lambda_2} = \sqrt{\frac{1}{2}(43 - 5\sqrt{73})}$$

**2. Cálculo de  $V$ :**

La matriz  $V_1$  compuesta por los vectores propios asociados a los valores propios de  $B = A^T A$ , en este caso hacemos  $V = V_1$ , debido a que  $r = r(A) = 2$ , donde  $V_1 = (v_1, v_2) \in \mathbb{R}(2, 2)$  y  $v_1, v_2 \in \mathbb{R}^2$  son los vectores propios asociados a  $\lambda_1, \lambda_2$  respectivamente.

Entonces

$$Bv_i = \lambda_i v_i, \quad i = 1, 2$$

entonces

$$v_1 = \sqrt{\frac{73 - 3\sqrt{73}}{146}} \begin{pmatrix} 1 \\ \sqrt{73 + 3} \\ 8 \end{pmatrix}, \quad v_2 = \sqrt{\frac{73 + 3\sqrt{73}}{146}} \begin{pmatrix} -1 \\ \sqrt{73 - 3} \\ 8 \end{pmatrix}$$

**3. Cálculo de  $U = (u_1, u_2, u_3)$**

$$u_1 = \frac{1}{\sigma_1} A v_1 = \frac{1}{\sqrt{\frac{1}{2}(43 + 5\sqrt{73})}} \begin{pmatrix} 1 & 2 \\ 2 & 3 \\ 3 & 4 \end{pmatrix} \sqrt{\frac{73 + 3\sqrt{73}}{146}} \begin{pmatrix} 1 \\ \sqrt{73 + 3} \\ 8 \end{pmatrix}$$

$$u_2 = \frac{1}{\sigma_2} A v_2 = \frac{1}{\sqrt{\frac{1}{2}(43 - 5\sqrt{73})}} \begin{pmatrix} 1 & 2 \\ 2 & 3 \\ 3 & 4 \end{pmatrix} \sqrt{\frac{73 - 3\sqrt{73}}{146}} \begin{pmatrix} -1 \\ \sqrt{73 - 3} \\ 8 \end{pmatrix}$$

Luego elegimos  $u_3$  tal que  $U = (u_1, u_2, u_3)$  sea una matriz ortogonal, es decir,

$$u_1^T u_3 = u_2^T u_3 = 0 \quad \text{y} \quad u_3^T u_3 = 1, \text{ obteniéndose } \begin{pmatrix} \frac{\sqrt{6}}{6} \\ -\frac{2\sqrt{6}}{6} \\ \frac{\sqrt{6}}{6} \end{pmatrix}$$

Así tenemos

$$D = U^T A V = \begin{pmatrix} \sqrt{\frac{1}{2}(43+5\sqrt{73})} & 0 & 0 \\ 0 & \sqrt{\frac{1}{2}(43-5\sqrt{73})} & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

**Notas:**

- a. Asumiremos en adelante, sin pérdida de generalidad, que  $m \geq n$ ; por que si  $m < n$ , consideraremos que la *DESCOMPOSICIÓN DEL VALOR SINGULAR* es para  $A^T$ , donde  $A^T = UDV^T$ , entonces la *DESCOMPOSICIÓN DEL VALOR SINGULAR* de  $A = VD^T U^T$ .
- b. Asumiremos que los valores singulares son no-crecientes. Luego  $\sigma_{máx} = \sigma_1$  es el mayor valor singular y  $\sigma_{mín} = \sigma_r$  es el menor valor singular diferente de cero y denotemos  $vs(A) = \{\sigma \in \mathbb{R}/s \text{ es un valor singular de } A\}$ .

### 3. RELACIÓN ENTRE LA DESCOMPOSICIÓN DEL VALOR SINGULAR Y LA DESCOMPOSICIÓN PROPIA

El siguiente teorema prueba como la *DESCOMPOSICIÓN DEL VALOR SINGULAR* de  $A$  está relacionada con los valores propios de  $AA^T$  y  $A^T A$ .

**Teorema 3.1.** Sea  $A \in \mathbb{R}(m, n)$  una matriz,  $A = UDV^T$  la descomposición del valor singular y sea  $r = r(A)$ . Entonces

1.  $V^T (A^T A) V = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)_{n \times n}$
2.  $U^T (AA^T) U = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)_{m \times m}$

Prueba:

$$\begin{aligned} \text{Como} \quad A &= UDV^T \\ \Rightarrow \quad A^T A &= (VD^T U^T)(UDV^T) \end{aligned}$$

$$\begin{aligned} &= VD^T D V^T \\ \Rightarrow \quad A^T A &= V \tilde{D} V^T \quad \tilde{D} = D^T D \end{aligned}$$

donde  $\tilde{D} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)_{n \times n}$

luego  $\tilde{D} = V^T A^T A V$ .

Para

$$\begin{aligned} AA^T &= (UDV^T)(VD^T U^T) \\ &= UDD^T U^T \\ \Rightarrow \quad AA^T &= U \hat{D} U^T \quad \hat{D} = D^T D \end{aligned}$$

donde  $\hat{D} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)_{m \times m}$ ,

luego  $\hat{D} = U^T AA^T U$ .

Del último Teorema se obtiene:

1. Los vectores singulares derechos  $v_1, v_2, \dots, v_n$  son los vectores propios de  $A^T A$ .
2. Los vectores singulares izquierdos  $u_1, u_2, \dots, u_m$  son los vectores propios de  $AA^T$ .
3.  $\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2$  son los valores propios de  $AA^T$  y  $A^T A$ .

**Ejemplo 3.0.2.** Sea

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

$$\text{definamos } B_1 = A^T A = \begin{pmatrix} 3 & 3 \\ 3 & 3 \end{pmatrix}$$

$$\Rightarrow |B_1 - \lambda I| = \lambda^2 - 6\lambda = 0 \Rightarrow \lambda = 0, \lambda = 6$$

$$\text{Definamos } B_2 = AA^T = \begin{pmatrix} 2 & 2 & 2 \\ 2 & 2 & 2 \\ 2 & 2 & 2 \end{pmatrix}$$

$$\Rightarrow |B_2 - \lambda I| = 6\lambda^2 - 6\lambda^3 = 0 \Rightarrow \lambda = 0, \lambda = 0, \lambda = 6$$

Los valores propios y vectores propios asociados de  $B_1$  son respectivamente:

$$\lambda = 6, v_1 = \begin{pmatrix} \frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} \end{pmatrix}, \quad \lambda = 0, v_2 = \begin{pmatrix} -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} \end{pmatrix}$$

Los valores propios y vectores propios asociados de  $B_2$  son respectivamente:

$$\lambda = 6, u_1 = \begin{pmatrix} \frac{\sqrt{3}}{3} \\ \frac{\sqrt{3}}{3} \\ \frac{\sqrt{3}}{3} \end{pmatrix}, \quad \lambda = 0, u_2 = \begin{pmatrix} -\frac{2\sqrt{6}}{6} \\ \frac{\sqrt{6}}{6} \\ \frac{\sqrt{6}}{6} \end{pmatrix}, \quad \lambda = 0, u_3 = \begin{pmatrix} 0 \\ -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} \end{pmatrix}$$

$$\Rightarrow A = UDV^T = \begin{pmatrix} \frac{\sqrt{3}}{3} & -\frac{2\sqrt{6}}{6} & 0 \\ \frac{\sqrt{3}}{3} & \frac{\sqrt{6}}{6} & -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{3}}{3} & \frac{\sqrt{6}}{6} & \frac{\sqrt{2}}{2} \end{pmatrix} D \begin{pmatrix} \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \end{pmatrix}$$

$$\text{donde } D = \begin{pmatrix} \sqrt{\lambda} & 0 \\ 0 & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \sqrt{6} & 0 \\ 0 & 0 \\ 0 & 0 \end{pmatrix}$$

Se verifica que:  $V A^T A V = \text{diag}(6, 0) \in \mathbb{R}(2, 2)$

$U A A^T U = \text{diag}(6, 0; 0) \in \mathbb{R}(3, 3)$ .

**Corolario 3.0.1.** Sea  $A \in \mathbb{R}(n, n)$  una matriz simétrica con valores propios  $\lambda_1, \lambda_2, \dots, \lambda_n$ . Entonces los valores singulares de  $A$  son  $\sigma_i = |\lambda_i|, i = 1, 2, \dots, n$ .

**Prueba:**

$$\text{Como } A = A^T$$

$$\Rightarrow A^T A = A^2$$

Del teorema (3.1) tenemos que:

$A$  tiene  $n$  valores singulares no-negativos que son las raíces de los  $n$  valores propios de  $A^2$ .

Debido a que los valores propios de  $A^2$  son  $\lambda_1^2, \lambda_2^2, \dots, \lambda_n^2$

$$\Rightarrow \sigma_1 = |\lambda_1|; \sigma_2 = |\lambda_2|; \dots; \sigma_n = |\lambda_n| \quad \blacksquare$$

**Corolario 3.0.2.** Una matriz  $A \in \mathbb{R}(n, n)$  es no-singular si, y sólo si todos los valores singulares son diferentes de cero.

**Prueba:**

Sabemos que  $\det(AA^T) = \det(A)\det(A^T) = \det(A)^2$ .

Luego  $A$  es una matriz no-singular  $\Leftrightarrow \det(A) \neq 0 \Leftrightarrow \lambda_i \neq 0$  (valores propios de

$A$ ),  $\forall i = 1, 2, \dots, n \Leftrightarrow \sigma_i \neq 0$  (valores singulares de  $A$ ),  $\forall i = 1, 2, \dots, n$  ■

**Teorema 3.2.** Sea  $A \in (m, n)$  ( $m \geq n$ ) y sea  $C \in \mathbb{R}(m+n, m+n)$  una matriz definida POR:

$$C = \begin{pmatrix} 0_{m \times m} & A \\ A^T & 0_{n \times n} \end{pmatrix}$$

Sean  $\sigma_1, \sigma_2, \dots, \sigma_n$  los valores singulares de  $A$ . Entonces los valores propios de  $C$  son:

$$\begin{aligned} \lambda_1 &= \sigma_1, & \lambda_2 &= \sigma_2, & \dots, & \lambda_n &= \sigma_n, \\ \lambda_{n+1} &= -\sigma_1, & \lambda_{n+2} &= -\sigma_2, & \dots, & \lambda_{2n} &= -\sigma_n, \\ \lambda_{2n+1} &= 0, & \lambda_{2n+2} &= 0; & \dots, & \lambda_{m+n} &= 0. \end{aligned}$$

**Prueba:**

Sea  $A = UDV^T$ ,

donde  $U = (U_1, U_2)$ ,  $U_1 \in \mathbb{R}(m, n)$ ,  $U_2 \in \mathbb{R}(m, m-n)$ ,

$$D = \begin{pmatrix} D_1 \\ \tilde{V} \\ 0 \end{pmatrix}, D_1 \in \mathbb{R}(n, n), \tilde{V} \in \mathbb{R}(m-n, n), V \in \mathbb{R}(n, n).$$

Definamos:

$$P = \begin{pmatrix} \tilde{U}_1 - \tilde{U}_1 & U_2 \\ \tilde{V} & \tilde{V} \\ & \tilde{0} \end{pmatrix} \in \mathbb{R}(m+n, m+n)$$

$$\text{donde } \tilde{U}_1 = \frac{1}{\sqrt{2}}U_1, \tilde{V} = \frac{1}{\sqrt{2}}V$$

$$\Rightarrow P^T C P = \begin{pmatrix} \tilde{U}_1^T & \tilde{V}^T \\ -\tilde{U}_1^T & \tilde{V}^T \\ \tilde{U}_2^T & 0 \end{pmatrix} \begin{pmatrix} 0_{m \times m} & A \\ A^T & 0_{n \times n} \end{pmatrix} \begin{pmatrix} \tilde{U}_1 - \tilde{U}_1 & U_2 \\ \tilde{V} & \tilde{V} \\ \tilde{0} & \tilde{0} \end{pmatrix}$$

$$\Rightarrow P^T C P = \begin{pmatrix} D_1 & 0 & 0 \\ 0 & -D_1 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

donde  $D_1 = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$ .

Además:

$\sigma_1, \sigma_2, \dots, \sigma_n, -\sigma_1, -\sigma_2, \dots, -\sigma_n, 0, 0, \dots, 0$  son los valores propios de  $C$ . ■

**Ejemplo 3.0.3.** Sea

$$A = \begin{pmatrix} 1 & 2 \\ 2 & 3 \\ 3 & 4 \end{pmatrix}$$

$$\Rightarrow C = \begin{pmatrix} 0_{3 \times 3} & A \\ A^T & 0_{2 \times 2} \end{pmatrix} \in \mathbb{R}(3+2, 3+2)$$

Usando los resultados del ejemplo (2.1.1) se tiene:

$U = (U_1, U_2)$ ,  $U_1 \in \mathbb{R}(3,2)$ ,  $U_2 \in \mathbb{R}(3,3-2)$ , luego

$$\tilde{U}_1 = \frac{1}{\sqrt{2}} U_1 = \frac{1}{\sqrt{2}} \begin{pmatrix} \alpha \left( \frac{\sqrt{73}+3}{4} \right) & \beta \left( \frac{\sqrt{73}+3}{4} \right) \\ \alpha \left( \frac{3\sqrt{73}+25}{8} \right) & \beta \left( \frac{3\sqrt{73}-25}{8} \right) \\ \alpha \left( \frac{\sqrt{73}+9}{2} \right) & \beta \left( \frac{\sqrt{73}-9}{2} \right) \end{pmatrix}$$

$$\text{donde } \alpha = \sqrt{\frac{73-3\sqrt{73}}{73(43+5\sqrt{73})}}, \quad \beta = \sqrt{\frac{73+3\sqrt{73}}{73(43-5\sqrt{73})}}$$

$$U_2 = \begin{pmatrix} \frac{\sqrt{6}}{6} \\ -\left(\frac{2\sqrt{6}}{6}\right) \\ \frac{\sqrt{6}}{6} \end{pmatrix} = \frac{\sqrt{6}}{6} \begin{pmatrix} 1 \\ -2 \\ 1 \end{pmatrix}$$

$$\tilde{V} = \frac{1}{\sqrt{2}} V = \frac{1}{\sqrt{2}} \begin{pmatrix} \gamma & -\delta \\ \gamma \left( \frac{\sqrt{73}+3}{8} \right) & \delta \left( \frac{\sqrt{73}-3}{8} \right) \end{pmatrix}$$

$$\text{donde } \gamma = \sqrt{\frac{73-3\sqrt{73}}{146}}, \quad \delta = \sqrt{\frac{73+3\sqrt{73}}{146}}$$

$$\Rightarrow P = \begin{pmatrix} \tilde{U}_1 & -\tilde{U}_1 & U_2 \\ \tilde{V} & \tilde{V} & \tilde{0} \end{pmatrix} \in \mathbb{R}(5,5) \text{ donde } \tilde{0} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

Entonces tenemos:

$$P^T C P = \text{diag}(t1, t2, -t1, -t2, 0)$$

$$\text{donde } t1 = \sqrt{\frac{1}{2}(43+5\sqrt{73})} \quad \text{y} \quad t2 = \sqrt{\frac{1}{2}(43-5\sqrt{73})} \quad \blacksquare$$

#### 4. SENSIBILIDAD DEL VALOR SINGULAR

Debido que el cuadrado de los valores singulares de  $A$  son justamente los valores propios de la matriz simétrica real  $A^T A$  y estudiar la sensibilidad de los valores singulares es estudiar la sensibilidad de los valores propios, entonces veremos esto a través del siguiente:

**Teorema 4.1 (Perturbación del Valor Singular).** *Consideremos las siguientes matrices  $A, B = A + E \in \mathbb{R}(m, n)$  ( $m \geq n$ ). Sean  $\sigma_i$  y  $\tilde{\sigma}_i$ ,  $i = 1; 2; \dots; n$ , respectivamente los valores singulares de  $A$  y  $B$ , en orden no-decreciente. Entonces  $|\sigma_i - \tilde{\sigma}_i| \leq \|E\|_2$  para todo  $i$ ; donde  $\|\cdot\|_2$  indica la norma 2.*

#### Prueba

Haremos la prueba usando la relación entre los valores singulares de una matriz  $A$  y los valores propios de la matriz simétrica.

$$\tilde{A} = \begin{pmatrix} 0 & A \\ A^T & 0 \end{pmatrix} \in \mathbb{R}(m, n)$$

sean  $\sigma_1, \sigma_2, \dots, \sigma_k$  los valores singulares de  $A$  diferentes de cero, entonces del teorema (3.2) tenemos que:

$\sigma_1, \sigma_2, \dots, \sigma_k, -\sigma_1, -\sigma_2, \dots, -\sigma_k$  son los valores propios de  $\tilde{A}$  distintos de cero y los otros  $m - 2k$  valores propios son ceros. Definamos

$$\tilde{B} = \begin{pmatrix} 0 & B \\ B^T & 0 \end{pmatrix} \quad \tilde{E} = \begin{pmatrix} 0 & E \\ E^T & 0 \end{pmatrix}$$



se observa que  $\tilde{B} - \tilde{A} = \tilde{E}$ .

Entonces, volviendo a usar el teorema (3.2) tenemos que los valores propios de  $\tilde{B}$  y  $\tilde{E}$  están relacionadas con los valores singulares de  $B$  y  $E$  respectivamente, entonces de acuerdo a un teorema del álgebra lineal tenemos:

$$|\tilde{\sigma}_i - \tilde{\sigma}_j| \leq \|\tilde{E}\|_2 = \|E\|_2 \quad \blacksquare$$

Ejemplo 4.0.4. Sean

$$A = \begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8 \end{pmatrix} \quad E = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.0002 \end{pmatrix}$$

entonces los valores propios de

$$A^T A = \begin{pmatrix} 1 & 3 & 6 \\ 2 & 4 & 7 \\ 3 & 5 & 8 \end{pmatrix} \begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8 \end{pmatrix} = \begin{pmatrix} 46 & 56 & 66 \\ 56 & 69 & 82 \\ 66 & 82 & 98 \end{pmatrix}$$

son:

$$\lambda_1 = 0 = 0.0000000000000000$$

$$\lambda_2 = \frac{213}{2} - \frac{1}{2}\sqrt{44457} \approx 1.075856655128756$$

$$\lambda_3 = \frac{213}{2} + \frac{1}{2}\sqrt{44457} \approx 211.92414334487142$$

entonces los valores singulares de  $A$  son:

$$\sigma_1 = \sqrt{0} = 0.0000000000000000$$

$$\sigma_2 = \sqrt{\frac{213}{2} - \frac{1}{2}\sqrt{44457}} \approx 1.03723510118418$$

$$\sigma_3 = \sqrt{\frac{213}{2} + \frac{1}{2}\sqrt{44457}} \approx 14.55761461726719$$

Sea

$$B = A + E = \begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.0002 \end{pmatrix} = \begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8.0002 \end{pmatrix}$$

entonces los valores propios de:

$$B^T B = \begin{pmatrix} 1 & 3 & 6 \\ 2 & 4 & 7 \\ 3 & 5 & 8.0002 \end{pmatrix} \begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8.0002 \end{pmatrix} = \begin{pmatrix} 46 & 56 & 66.0012 \\ 56 & 69 & 82.0014 \\ 66.0012 & 82.0014 & 98.00320004 \end{pmatrix}$$

son:

$$\tilde{\lambda}_1 \approx 0.0000000000702 \quad \tilde{\lambda}_2 \approx 1.075745478674 \quad \tilde{\lambda}_3 \approx 211.927454560624$$

entonces los valores singulares de  $B$  son:

$$\tilde{\sigma}_1 \approx 0.00002649528260$$

$$\tilde{\sigma}_2 \approx 1.03718150710189$$

$$\tilde{\sigma}_3 \approx 14.55772834478732$$

además tenemos que  $\|E\|_2 = 0.0002$

luego tenemos:

$$|\tilde{\sigma}_1 - \tilde{\sigma}_1| = 0.0264069522e - 03 < \|E\|_2 = 0.0002$$

$$|\tilde{\sigma}_2 - \sigma_2| = 0.0535940823e - 03 < \|E\|_2 = 0.0002$$

$$|\tilde{\sigma}_3 - \sigma_3| = 0.1137275201e - 03 < \|E\|_2 = 0.0002 \quad \blacksquare$$

**Teorema 4.2.** Sea  $A, E \in \mathbb{R}(m, n)$ ,  $\sigma_i, \tilde{\sigma}_i, i = 1; \dots; n$  los mismos como en el teorema (4.1). Entonces

$$\sqrt{\sum_{i=1}^n (\sigma_i - \tilde{\sigma}_i)^2} \leq \|E\|_F,$$

donde  $\|A\|_F = \sqrt{\sum_{j=1}^n \sum_{i=1}^m a_{ij}^2}$  es llamada la norma de Frobenius.

**Definición 4.0.1.** Sea  $A \in \mathbb{R}(n, n)$  una matriz no-singular, definimos la Condición de  $A$  con respecto a la norma 2, y lo denotamos  $Cond(A)_2$ , al número.

$$Cond(A)_2 = \|A\|_2 \|A^{-1}\|_2$$

## 5. APLICACIONES

La descomposición del valor singular puede ser usado para obtener propiedades muy importantes relacionadas a la estructura de las matrices, tales como la norma Euclídeana, bases ortonormales para el espacio nulo, problema de almacenamiento en el computador, entre otras propiedades como veremos en esta sección.

### 5.1 NORMAS

**Teorema 5.1.** Sean  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$  los valores singulares de una matriz  $A \in \mathbb{R}(m, n)$ . Entonces

$$I. \quad \|A\|_2 = \sigma_1 = \sigma_{max}$$

$$2. \quad \|A\|_F = \left( \sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2 \right)^{1/2}$$

$$3. \quad \|A^{-1}\|_2 = \frac{1}{\sigma_n} = \frac{1}{\sigma_{min}}, \text{ cuando } A \in \mathbb{R}(n, n) \text{ y no-singular.}$$

4. Si  $A \in \mathbb{R}(n, n)$  es una matriz no-singular, entonces

$$Cond_2(A) = \|A\|_2 \|A^{-1}\|_2 = \frac{\sigma_1}{\sigma_n} = \frac{\sigma_{max}}{\sigma_{min}}$$

### Prueba:

1. Sabemos que por el teorema (2.1) existen matrices ortogonales  $U \in \mathbb{R}(m, m)$ ,  $V \in \mathbb{R}(n, n)$  tales que:  $U^T A V = \begin{pmatrix} D_1 & 0 \\ 0 & 0 \end{pmatrix} = D$ , donde  $D_1$  es una matriz no-singular, entonces:

$$\|A\|_2 = \|UDV^T\|_2 = \|D\|_2 = \max_i (\{\sigma_i\}) = \sigma_1 = \sigma_{max}$$

2. De acuerdo al teorema (2.1) y la definición de  $\|\cdot\|_F$  tenemos:

$$\|A\|_F = \|UDV^T\|_F = \|D\|_F = \left( \sigma_1^2 + \dots + \sigma_n^2 \right)^{1/2}$$

3. En este caso  $A \in \mathbb{R}(n, n)$  es una matriz no-singular, entonces existe  $A^{-1} \in \mathbb{R}(n; n)$  y  $\sigma_n = \sigma_{min} > 0$ , luego  $\frac{1}{\sigma_n}$  es el mayor valor singular de  $A^{-1}$  y aplicando el teorema (5.1)(1) tenemos:

$$\|A^{-1}\|_2 = \frac{1}{\sigma_n} = \frac{1}{\sigma_{min}}$$

4. Sabemos que  $Cond(A)_2 = \|A\|_2 \|A^{-1}\|_2$ , entonces por la parte (1) y (3) del presente teorema tenemos:

$$Cond(A)_2 = \|A\|_2 \|A^{-1}\|_2 = \frac{\sigma_1}{\sigma_n} = \frac{\sigma_{max}}{\sigma_{min}} \quad \blacksquare$$

**Ejemplo 5.1.1.** Sea  $\begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 7.999 \end{pmatrix}$  cuyo valores singulares son:

$$\sigma_1 = 14.557046000106184607$$

$$\sigma_2 = 1.037503124456149584$$

$$\sigma_3 = 0.000132424274849910$$

y de acuerdo al teorema (5.1) tenemos:

$$1. \quad \|A\|_2 = \sigma_1 = 14.557046000106184607$$

$$2. \quad \|A\|_F = \sqrt{\sigma_1^2 + \sigma_2^2 + \sigma_3^2} = 14.5939713921865$$

$$3. \quad \|A^{-1}\|_2 = \frac{1}{\sigma_3} = \frac{1}{0.000132424274849910} = 7551.48556796174$$

$$4. \quad \text{Cond}(A)_2 = \frac{\sigma_1}{\sigma_3} = \frac{14.557046000106184607}{0.000132424274849910} = 109927.322781155 \quad \blacksquare$$

## 5.2 PROBLEMA DE ALMACENAMIENTO

Cuando se tiene una matriz  $A \in \mathbb{R}(m, n)$  de gran tamaño, tenemos el problema de almacenamiento, entonces podemos hacer uso de los vectores singulares por la izquierda y por la derecha respectivamente de  $A$ , sabiendo que se tiene  $r$  valores singulares positivos y  $\sigma_{r+1} = \dots = \sigma_n = 0$ , y esto nos permite tener  $(m+n)$  lugares en la memoria (del computador) en vez de  $mn$ ; lo cual queda justificado por el siguiente teorema.

**Teorema 5.2.** Sean  $A \in \mathbb{R}(m, n)$  una matriz y  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  los  $r$  valores singulares de  $A$ . Entonces:

$$A = \sum_{j=1}^r \sigma_j u_j v_j^T$$

### Prueba:

Debido al teorema (2.1) existen matrices ortogonales  $U \in \mathbb{R}(m, m)$  y  $V \in \mathbb{R}(n, n)$  tales que:  $A = UDV^T$ , entonces

$$A = (u_1, u_2, \dots, u_m) \begin{pmatrix} \sigma_1 & 0 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \sigma_2 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & 0 & \sigma_3 & \dots & 0 & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & \sigma_r & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 0 & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 0 & 0 & \dots & 0 \end{pmatrix} \begin{pmatrix} v_1^T \\ v_2^T \\ \vdots \\ v_n^T \end{pmatrix}$$

de donde obtenemos:

$$A = \sum_{j=1}^r \sigma_j u_j v_j^T$$

teniendo en cuenta que  $\sigma_{r+1} = \dots = \sigma_n = 0$

**Ejemplo 5.2.1.** Sea la matriz  $\begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8 \end{pmatrix}$ , cuyos valores singulares son:

$$\sigma_1 = 14.55761461726719$$

$$\sigma_2 = 1.03723510118419$$

$$\sigma_3 = 0.0000000000000000$$

de donde  $r = 2$  y de acuerdo al teorema (2.1) obtenemos:

$$v_1 = \begin{pmatrix} 0.46250865 \\ 0.57056873 \\ 0.67862882 \end{pmatrix}, \quad v_2 = \begin{pmatrix} -0.78703182 \\ -0.08823069 \\ 0.61057044 \end{pmatrix}$$

$$u_1 = \frac{1}{\sigma_1} Av_1 = \begin{pmatrix} 0.25000886 \\ 0.48517186 \\ 0.83791637 \end{pmatrix}, \quad u_2 = \frac{1}{\sigma_2} Av_2 = \begin{pmatrix} 0.83705046 \\ 0.32667037 \\ -0.43889976 \end{pmatrix}$$

y de esta manera se tiene:

$$\sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T = A = \begin{pmatrix} 1 & 2 & 3 \\ 3 & 4 & 5 \\ 6 & 7 & 8 \end{pmatrix}$$

Como observamos no hacemos uso de los vectores  $u_3$  y  $v_3$ . ■

### 5.3 SOLUCIÓN DE SISTEMAS DE ECUACIONES LINEALES

La descomposición del valor singular de una matriz también puede ser utilizada para resolver sistemas de ecuaciones lineales de la forma:

$$Ax = b$$

donde  $A \in \mathbb{R}(m, n)$ ,  $b \in \mathbb{R}^m$  son dados y  $x \in \mathbb{R}^n$  es la incógnita a encontrar; entonces hacemos lo siguiente: descomponemos  $A = UDV^T$  y lo reemplazamos en el sistema original obteniendo

$$\begin{aligned} UDV^T x &= b \\ DV^T x &= U^T b \\ Dy &= b^1 = U^T b \end{aligned}$$

donde  $y = V^T x$ ; ahora simplemente resolvemos la última ecuación que es mucho fácil, donde  $D \in \mathbb{R}(m, n)$  es la matriz del teorema (2.1).

### 6. CONCLUSIONES

Observamos que la descomposición del valor singular de una matriz  $A \in \mathbb{R}(m; n)$  abrevia el cálculo debido a la propiedad que tiene una matriz simétrica ( $A^T A$  en este caso) con sólo calcular los valores propios de  $A^T A$  que son no-negativos.

Geoméricamente, la descomposición del valor singular de la matriz  $A \in \mathbb{R}(m, n)$  puede interpretarse como una transformación de la siguiente manera:

$$\begin{aligned} A : \mathbb{R}^n &\rightarrow \mathbb{R}^m \\ x &\mapsto y = A(x) \end{aligned}$$

donde  $\|x\|_2 = 1$ .

**Ejemplo 6.0.1.** Sea la matriz  $A = \begin{pmatrix} 0.72 & 1.04 \\ 1.46 & 0.72 \end{pmatrix} \in \mathbb{R}(2, 2)$ , en este caso  $m = n = 2$ , entonces los valores singulares de  $A$  son:  $\sigma_1 = 2.00$ ,  $\sigma_2 = 0.50$ ;

$$U = \begin{pmatrix} 0.6 & -0.8 \\ 0.8 & 0.6 \end{pmatrix} \quad y \quad V = \begin{pmatrix} 0.8 & 0.6 \\ 0.6 & -0.8 \end{pmatrix} \quad \text{entonces tenemos:}$$

$$Ax = UDV^T x = \begin{pmatrix} 0.6 & -0.8 \\ 0.8 & 0.6 \end{pmatrix} \begin{pmatrix} 2 & 0 \\ 0 & -0.5 \end{pmatrix} \begin{pmatrix} 0.8 & 0.6 \\ 0.6 & -0.8 \end{pmatrix} x$$

$$\text{consideremos } x = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix}, \text{ entonces}$$