

Álgebra II (Curso 23)
Segundo cuatrimestre, 2021
NOTAS EN LA EMERGENCIA SANITARIA:
BORRADORES PARA LA CLASE DEL 1 DE DICIEMBRE
Sebastian GRYNBERG



*El único héroe válido es el héroe “en grupo”,
nunca el héroe individual, el héroe solo.*

H. G. OESTERHELD

ÍNDICE

1. Propiedades de las matrices simétricas	2
1.1. Subespacios fundamentales	2
1.2. Espectro	2
1.3. Autoespacios	2
1.4. Teorema espectral	2
1.5. Courant-Fisher	3
2. Para un estudio de $A^T A$	4
2.1. Subespacios fundamentales	4
2.2. Espectro	5
2.3. Diagonalización ortogonal	5
2.4. Estructura geométrica de A	5

1. PROPIEDADES DE LAS MATRICES SIMÉTRICAS

1.1. Subespacios fundamentales.

Lema 1.1. Si $A \in \mathbb{R}^{n \times n}$ es una matriz simétrica, el subespacio nulo de A es ortogonal al subespacio columna de A . En otras palabras,

$$\text{nul}(A) \perp \text{col}(A).$$

Demostración. Inmediata: $\text{nul}(A) \perp \text{col}(A^T) = \text{col}(A)$. □

1.2. Espectro.

Lema 1.2. Todas las raíces del polinomio característico de una matriz simétrica $A \in \mathbb{R}^{n \times n}$ son números reales.

Demostración. Si $\lambda \in \sigma_{\mathbb{C}}(A)$ y $z \in \text{nul}(A - \lambda I) \setminus \{0\}$, entonces

$$\begin{aligned} \lambda \|z\|^2 &= \lambda \langle z, z \rangle = \langle \lambda z, z \rangle = \langle Az, z \rangle = \langle z, A^* z \rangle \\ &= \langle z, Az \rangle = \langle z, \lambda z \rangle = \bar{\lambda} \langle z, z \rangle = \bar{\lambda} \|z\|^2. \end{aligned}$$

Como $\|z\|^2 \neq 0$, resulta que $\lambda = \bar{\lambda}$. Por lo tanto, $\lambda \in \mathbb{R}$. □

1.3. Autoespacios.

Lema 1.3. Si $A \in \mathbb{R}^{n \times n}$ es una matriz simétrica, autovectores correspondientes a distintos autovalores son ortogonales entre sí. En otras palabras,

$$\text{nul}(A - \lambda_i I) \perp \text{nul}(A - \lambda_j I) \text{ para } \lambda_i \neq \lambda_j.$$

Demostración. Sean $x \in \text{nul}(A - \lambda_i I)$ e $y \in \text{nul}(A - \lambda_j I)$, vale que

$$\lambda_i \langle x, y \rangle = \langle \lambda_i x, y \rangle = \langle Ax, y \rangle = \langle x, Ay \rangle = \langle x, \lambda_j y \rangle = \lambda_j \langle x, y \rangle.$$

Como $\lambda_i \neq \lambda_j$, resulta que $\langle x, y \rangle = 0$. Por lo tanto, $x \perp y$. □

1.4. Teorema espectral.

Teorema 1.4. Una matriz $A \in \mathbb{R}^{n \times n}$ con espectro $\sigma(A) = \{\lambda_1, \lambda_2, \dots, \lambda_m\}$ es simétrica si y sólo si existen matrices $\{P_1, P_2, \dots, P_m\}$ tales que

$$(1) \quad A = \lambda_1 P_1 + \lambda_2 P_2 + \dots + \lambda_m P_m,$$

donde las P_i tienen las siguientes propiedades

- a) P_i es la proyección ortogonal sobre $\text{nul}(A - \lambda_i I)$.
- b) $P_i P_j = 0$ para $i \neq j$.
- c) $P_1 + P_2 + \dots + P_m = I$.

Nota Bene. Nótese que si $\{u_1, \dots, u_r\}$ es un sistema ortonormal de vectores de \mathbb{R}^n y $U_r = [u_1 \ \dots \ u_r] \in \mathbb{R}^{n \times r}$, entonces

$$P = U_r U_r^T$$

es la matriz de la proyección ortogonal sobre el subespacio $\text{gen}\{u_1, \dots, u_r\}$. En efecto,

$$Px = U_r U_r^T x = \left(\sum_{j=1}^r u_j u_j^T \right) x = \sum_{j=1}^r (u_j^T x) u_j = \sum_{j=1}^r \langle x, u_j \rangle u_j.$$

1.5. Courant-Fisher.

Como los autovalores de una matriz simétrica $A \in \mathbb{R}^{n \times n}$ son números reales, se los puede organizar en forma decreciente: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$. Además, existe una matriz ortogonal $U \in \mathbb{R}^{n \times n}$ tal que $U^T A U = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$, o, lo que es lo mismo $A = U \Lambda U^T$. Definiendo $y = U^T x$ podemos escribir

$$(2) \quad x^T A x = x^T U \Lambda U^T x = y^T \Lambda y = \sum_{j=1}^n \lambda_j y_j^2.$$

Como $\|y\| = \|U^T x\| = \|x\|$, las relaciones

$$\begin{aligned} \sum_{j=1}^n \lambda_j y_j^2 &\leq \lambda_1 \sum_{j=1}^n y_j^2 = \lambda_1 \|y\|^2, \\ \sum_{j=1}^n \lambda_j y_j^2 &= \lambda_1 \text{ para } y = e_1, \end{aligned}$$

junto a las identidades (2), implican que

$$\lambda_1 = \max_{\|x\|=1} x^T A x.$$

Del mismo modo, las relaciones

$$\begin{aligned} \sum_{j=1}^n \lambda_j y_j^2 &\geq \lambda_n \sum_{j=1}^n y_j^2 = \lambda_n \|y\|^2, \\ \sum_{j=1}^n \lambda_j y_j^2 &= \lambda_n \text{ para } y = e_n, \end{aligned}$$

implican que

$$\lambda_n = \min_{\|x\|=1} x^T A x.$$

Con un poco más de trabajo se puede demostrar el siguiente resultado

Teorema 1.5 (Courant-Fischer). *Los autovalores $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ de una matriz simétrica $A \in \mathbb{R}^{n \times n}$ son*

$$\lambda_i = \min_{\dim(\mathbb{S})=n-i+1} \max_{x \in \mathbb{S}: \|x\|=1} x^T A x$$

Demostración. Usando una diagonalización ortogonal de A el problema se reduce a demostrar que

$$\lambda_i = \min_{\dim(\mathbb{S})=n-i+1} \max_{y \in \mathbb{S}: \|y\|=1} y^T \Lambda y$$

Sea $\mathbb{T} = \text{gen}\{e_1, \dots, e_i\} \neq \{0\}$. Si \mathbb{S} tiene dimensión $n+i-1$, entonces $\mathbb{S} \cap \mathbb{T} \neq \{0\}$. Si se supone lo contrario se obtiene una contradicción. Consideramos

$$\Sigma_{\mathbb{S}} = \{y \in \mathbb{S} : \|y\| = 1\}.$$

Como $\mathbb{S} \cap \mathbb{T} \neq \{0\}$, $\Sigma_{\mathbb{S}} \cap \mathbb{T} \neq \emptyset$. Para cada $y \in \Sigma_{\mathbb{S}} \cap \mathbb{T}$ vale que

$$y^T \Lambda y = \sum_{j=1}^i \lambda_j y_j^2 \geq \lambda_i \sum_{j=1}^i y_j^2 = \lambda_i$$

Como $\Sigma_{\mathbb{S}} \cap \mathbb{T} \subseteq \Sigma_{\mathbb{S}}$, tenemos

$$\max_{y \in \Sigma_{\mathbb{S}}} y^T \Lambda y \geq \max_{y \in \Sigma_{\mathbb{S}} \cap \mathbb{T}} y^T \Lambda y = \lambda_i,$$

y en consecuencia,

$$\min_{\dim(\mathbb{S})=n-i+1} \max_{y \in \Sigma_{\mathbb{S}}} y^T \Lambda y \geq \lambda_i.$$

Si $\mathbb{S}^* = \{e_1, \dots, e_{i-1}\}$

$$y^T \Lambda y = \sum_{j=1}^n \lambda_j y_j^2 \leq \lambda_i \sum_{j=i}^n y_j^2 = \lambda_i \quad \text{para todo } y \in \Sigma_{\mathbb{S}^*}.$$

En consecuencia,

$$\min_{\dim(\mathbb{S})=n-i+1} \max_{y \in \Sigma_{\mathbb{S}}} y^T \Lambda y \leq \max_{y \in \Sigma_{\mathbb{S}^*}} y^T \Lambda y \leq \lambda_i,$$

y por lo tanto,

$$\lambda_i = \min_{\dim(\mathbb{S})=n-i+1} \max_{y \in \mathbb{S}: \|y\|=1} y^T \Lambda y.$$

□

2. PARA UN ESTUDIO DE $A^T A$

Nota Bene. Nótese que si $A \in \mathbb{R}^{m \times n}$, entonces $A^T A \in \mathbb{R}^{n \times n}$ es una matriz simétrica.

2.1. Subespacios fundamentales.

Lema 2.1. Sea $A \in \mathbb{R}^{m \times n}$. Vale que

$$\begin{aligned} \text{nul}(A^T A) &= \text{nul}(A) \\ \text{col}(A^T A) &= \text{col}(A^T) \end{aligned}$$

Demostración. Ejercicio.

□

2.2. Espectro.

Lema 2.2. Sea $A \in \mathbb{R}^{m \times n}$. Vale que $\sigma(A^T A) \subset \mathbb{R}^+$.

Demostración. Si $\lambda \in \sigma(A^T A)$ y $x \in \text{nul}(A^T A - \lambda I) \setminus \{0\}$, entonces

$$\lambda \|x\|^2 = \lambda \langle x, x \rangle = \langle \lambda x, x \rangle = \langle A^T A x, x \rangle = \langle A x, A x \rangle = \|A x\|^2.$$

Como $\|x\|^2 > 0$ y $\|A x\|^2 \geq 0$, resulta que $\lambda \geq 0$. Por lo tanto, $\sigma(A^T A) \subset \mathbb{R}^+$. \square

2.3. Diagonalización ortogonal.

Sea $A \in \mathbb{R}^{m \times n}$ una matriz de rango r . Como $\text{rango}(A^T) = \text{rango}(A)$ y $\text{col}(A^T A) = \text{col}(A^T)$ tenemos que $\text{rango}(A^T A) = r$. Ordenando los autovalores no nulos de $A^T A$ de manera decreciente podemos escribir $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > 0$. Como $A^T A$ es simétrica, existe una matriz ortogonal $V \in \mathbb{R}^{n \times n}$ tal que

$$A^T A = V \Lambda V^T,$$

donde $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_r, 0, \dots, 0)$.

Nota Bene. Nótese que si $V = [v_1 \ \dots \ v_n]$, entonces

$$A^T A v_i = \lambda_i v_i.$$

2.4. Estructura geométrica de A .

Lema 2.3. Sea $A \in \mathbb{R}^{m \times n}$ una matriz de rango r . Si $\{v_1, v_2, \dots, v_r\}$ es una base ortonormal de $\text{col}(A^T)$ compuesta por autovectores de $A^T A$ correspondientes a los autovalores $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > 0$, entonces los vectores de \mathbb{R}^m definidos por

$$(3) \quad u_i := \frac{1}{\sqrt{\lambda_i}} A v_i, \quad i \in \mathbb{I}_r,$$

constituyen una base ortonormal del espacio columna de A y además vale que

$$(4) \quad A v_i = \sqrt{\lambda_i} u_i.$$

Demostración. Una cuenta:

$$\begin{aligned} \langle u_i, u_j \rangle &= \frac{1}{\sqrt{\lambda_i} \sqrt{\lambda_j}} \langle A v_i, A v_j \rangle = \frac{1}{\sqrt{\lambda_i} \sqrt{\lambda_j}} \langle v_i, A^T A v_j \rangle \\ &= \frac{1}{\sqrt{\lambda_i} \sqrt{\lambda_j}} \langle v_i, \lambda_j v_j \rangle = \frac{\sqrt{\lambda_j}}{\sqrt{\lambda_i}} \langle v_i, v_j \rangle = 0. \end{aligned}$$

\square

Nota Bene. Nótese que las igualdades (4) significan que

$$(5) \quad A [v_1 \ v_2 \ \dots \ v_r] = [u_1 \ u_2 \ \dots \ u_r] \begin{bmatrix} \sqrt{\lambda_1} & & & \\ & \sqrt{\lambda_2} & & \\ & & \ddots & \\ & & & \sqrt{\lambda_r} \end{bmatrix}.$$

Definiendo

- $\sigma_i := \sqrt{\lambda_i}$ para cada $i \in \mathbb{I}_r$,

$$\begin{aligned} \blacksquare \Sigma_r &:= \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_r \end{bmatrix}, \\ \blacksquare V_r &:= [v_1 \ v_2 \ \cdots \ v_r], \\ \blacksquare U_r &:= [u_1 \ u_2 \ \cdots \ u_r], \end{aligned}$$

tenemos que

$$(6) \quad AV_r = U_r \Sigma_r.$$

Podemos completar la base ortonormal de $\text{col}(A^T)$, $\{v_1, \dots, v_r\}$, a una base ortonormal de \mathbb{R}^n , $\{v_1, \dots, v_r, v_{r+1}, \dots, v_n\}$ y la base ortonormal de $\text{col}(A)$, a una base ortonormal de \mathbb{R}^m , $\{u_1, \dots, u_r, u_{r+1}, \dots, u_m\}$. Definiendo

$$V_{n-r} = [v_{r+1} \ \cdots \ v_n] \text{ y } U_{m-r} = [u_{r+1} \ \cdots \ u_m],$$

tenemos que

$$(7) \quad A \underbrace{[V_r \ V_{n-r}]}_{V \in \mathbb{R}^{n \times n}} = [AV_r \ AV_{n-r}] = [U_r \Sigma_r \ 0] = \underbrace{[U_r \ U_{m-r}]}_{U \in \mathbb{R}^{m \times m}} \underbrace{\begin{bmatrix} \Sigma_r & 0 \\ 0 & 0 \end{bmatrix}}_{\Sigma \in \mathbb{R}^{m \times n}}.$$

Teorema 2.4 (Descomposición en valores singulares). *Sea $A \in \mathbb{R}^{m \times n}$ una matriz de rango r . Existe una factorización de la forma*

$$A = U \Sigma V^T,$$

donde $U \in \mathbb{R}^{m \times m}$ y $V \in \mathbb{R}^{n \times n}$ son matrices ortogonales y $\Sigma \in \mathbb{R}^{m \times n}$ es una matriz de la forma

$$\Sigma = \begin{bmatrix} \Sigma_r & 0 \\ 0 & 0 \end{bmatrix},$$

con $\Sigma_r = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r) \in \mathbb{R}^{r \times r}$, donde $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$.