

DESCOMPOSICIÓN EN VALORES SINGULARES II

Hemos probado que toda matriz $A \in \mathbb{C}^{m \times n}$ se puede escribir como $A = U \Sigma V^*$ con $U \in \mathcal{U}(m)$, $V \in \mathcal{U}(n)$ y $\Sigma \in \mathbb{C}^{m \times n}$ "diagonal".

Vimos dos versiones

$$A = \begin{matrix} \boxed{U} & \boxed{\Sigma} & \boxed{V^*} \\ m \times m & m \times n & n \times n \end{matrix}$$

Full SVD

$$A v_i = \sigma_i u_i$$

↳ (cambio de notación respecto a clase anterior, ... mal yo!)

$$A = \begin{matrix} \boxed{} & \boxed{} & \boxed{} \\ m \times n & m \times m & n \times n \end{matrix}$$

Una forma de interpretar la SVD es que se pueden elegir bases ortonormales en el dominio y codominio de manera tal que el operador es diagonal.

$Ax = b$, $\begin{matrix} \mathbb{C}^n & \xrightarrow{A} & \mathbb{C}^m \end{matrix}$ podemos expresarlo en las bases adecuadas y ver que efectivamente es diagonal.

Escribamos $x \in \mathbb{C}^n$ en la base generada por columnas de V , i.e. $x = V \alpha$ y hacemos lo mismo con $b \in \mathbb{C}^m$, expresado en la base de U generada por columnas de U , i.e. $b = U \beta$.

$$\text{Luego tenemos } b = Ax \iff b = U \beta = U (V \alpha) = U V \alpha = \Sigma \alpha$$

i.e. $\beta = \Sigma \alpha$

SVD vs EVD (eigenvalue decomposition)

Vale mencionar primero que este "juego" solo tiene sentido si $m=n$, dado que EVD solo tiene sentido cuando el operador A "opera" en el mismo espacio: $A: \mathbb{C}^n \rightarrow \mathbb{C}^n$.

Assumiendo $m=n$, y que A es diagonalizable podemos escribir

$A = X \Lambda X^{-1}$ donde columnas de X son vectores propios y

Λ es la diagonal de valores propios. Más precisamente,

$$X = (\nu_1 | \dots | \nu_n), \quad A \nu_i = \lambda_i \nu_i \quad (i=1, \dots, n)$$

$$\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n).$$

Si tomamos $\{\nu_1, \dots, \nu_n\}$ como base de \mathbb{C}^n y escribimos los vectores en esta base (como hicimos en sección anterior) tenemos

$$x' = X^{-1} x, \quad b' = X^{-1} b \quad \text{luego} \quad b = Ax \Leftrightarrow b' = \Lambda x'.$$

O sea A opera también como un operador diagonal, PERO: en la misma base!!

En particular, esto implica que el comportamiento de iterar A varias veces, A^k , es fácilmente analizado via el espectro.

$$A^k = (X \Lambda X^{-1}) \cdots (X \Lambda X^{-1}) = X \Lambda^k X^{-1} \quad (A^k \nu_i = \lambda_i^k \nu_i)$$

Sin embargo la SVD no nos ayuda a entender la dinámica A^k ,

~~pero~~ como vemos la SVD sí da información muy valiosa sobre la "geometría" de A , o ~~al menos~~ ~~algo~~, la SVD encapsula la información relevante del operador A .

Para ser más precisos, veamos algunas propiedades.

Propiedades de Matrices via SVD $A = (u_1 | \dots | u_m) \begin{pmatrix} \sigma_1 & & \\ & \sigma_k & \\ & & 0 \end{pmatrix} \begin{pmatrix} v_1 \\ \vdots \\ v_n \end{pmatrix}$

- Rango: El rango de A es el n $^{\circ}$ de valores singulares no nulos.

Es fácil ver que como el rango de U y V son maximales resulta que el rango de A es el mismo que el rango de Σ .

- Imagen y núcleo: $\text{Im}(A) = \{u_1, \dots, u_k\}$, $\text{Ker} A = \{v_1, \dots, v_k\}$
siendo $k = \text{rk}(A)$.

- Normas $\|A\|_2$ y $\|A\|_F$: Resulta $\|A\|_2 = \|\Sigma\|_2 = \sigma_1$
 $\|A\|_F = \|\Sigma\|_F = (\sigma_1^2 + \dots + \sigma_k^2)^{1/2}$

- Caso Hermitiano: $A^* = A$ entonces $|\lambda_i|$, $\lambda_i \in \text{Sp}(A)$ son los valores singulares.


- Determinante: $A \in \mathbb{C}^{n \times n} \Rightarrow |\det A| = \prod_{i=1}^n \sigma_i$

Esto resulta de que si $U \in \text{U}(n) \Rightarrow U^*U = \text{Id}$ y por lo tanto $1 = \det(U^*U) = \det U^* \cdot \det U = \overline{\det U} \det U = |\det U|^2$

LOW-RANK Approximation

He aquí una de las propiedades aplicaciones más importantes de SVD.

Supongamos que tenemos una matriz $A \in \mathbb{C}^{m \times n}$, $A = (a_1 | \dots | a_m)$ de rango \underline{r} , i.e. $\text{Im}(A) = \langle a_1, \dots, a_r \rangle$ es un espacio de dimensión \underline{r} .



Luego tomando un base de ese espacio, por ejemplo $\{b_1, \dots, b_r\}$ tenemos que podemos escribir cada columna de A como combinación lineal de los vectores $\{b_i\}$, a saber,

$$a_1 = c_{11}b_1 + \dots + c_{r1}b_r$$

$$a_m = c_{1m}b_1 + \dots + c_{rm}b_r$$

$$A = B \cdot C$$

$$\begin{bmatrix} a_1 & \dots & a_m \end{bmatrix} = \begin{bmatrix} b_1 & \dots & b_r \end{bmatrix} \begin{bmatrix} c \end{bmatrix}$$

$m \times n$ $m \times r$ $r \times n$

$$\begin{bmatrix} A \end{bmatrix} = \begin{bmatrix} B \end{bmatrix} \begin{bmatrix} C \end{bmatrix}$$

$r \ll \min\{m, n\}$

Lo que acabamos de probar es que toda matriz ~~de rango~~ $m \times n$ de rango $\leq r$ puede ser escrita representada por un producto de matrices de tamaños $m \times r$ y $r \times n$.

Observar que en el caso $r \ll \min\{m, n\}$ resulta que A puede ser descrita por $r(m+n)$ coeficientes (en vez de $m \cdot n$ que es mucho mayor).

~~Aproximar~~ Obs: Lo que acabamos de hacer es una generalización ~~de~~ de lo hecho para matrices de rango 1 (producto tensorial). Básicamente estamos diciendo que matrices de rango k las podemos escribir tipo $(b_1 \dots b_r) \begin{pmatrix} z_1^* \\ \vdots \\ z_r^* \end{pmatrix}$.

Aproximar matrices por matrices de rango menor es muy utilizado en diversas aplicaciones (compresión, "de-noising", completación de matrices, procesamiento de imágenes, etc...)

Observar que ^{del SVD} podemos escribir $A = \sigma_1 u_1 v_1^* + \dots + \sigma_r u_r v_r^*$ que es una suma de r matrices de rango 1, y las cuales son ortogonales entre sí con $\langle \cdot, \cdot \rangle_F$.

Definimos $A_k := \sigma_1 u_1 v_1^* + \dots + \sigma_k u_k v_k^*$ $A_r = A$
($k=1 \dots r$)

Teorema (Low-Rank Approx) ($k \leq r$)

$$\min_{\substack{B \in \mathbb{C}^{m \times n} \\ \text{rk}(B) \leq k}} \|A - B\|_2 = \|A - A_k\|_2 = \sigma_{k+1}.$$

~~Nota~~ Un caso particular importante (a veces llamado Eckart-Young) es cuando $m=n$ y A invertible.

Luego $\min_{\text{rk}(B) \leq n-1} \|A - B\|_2 = \|A - A_{n-1}\|_2 = \sigma_n$.

Comenzamos haciendo la prueba de este caso:

Si $B \in \mathbb{C}^{n \times n}$ / $\exists w \in \mathbb{C}^n$ ($\|w\|=1$), $Bw=0 \Rightarrow \|A - B\| \geq \|(A - B)w\| = \|Aw\|$

Afirmación: $\|Aw\| \geq \sigma_n$ ($\|w\|=1$)

Esto resulta del hecho que $\|A^{-1}Aw\| = \|w\|$. Mas precisamente:

$$\begin{aligned} \|Aw\|^2 &= \|U \Sigma v^* w U^T\|^2 = \|\Sigma v^* w\|^2 = \|\Sigma y\|^2 = \left\| \begin{pmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_n \end{pmatrix} \begin{pmatrix} |y_1| \\ \vdots \\ |y_n| \end{pmatrix} \right\|^2 = \sigma_1^2 |y_1|^2 + \dots + \sigma_n^2 |y_n|^2 \\ &= \sigma_1^2 |y_1|^2 + \dots + \sigma_n^2 |y_n|^2 \geq \sigma_n^2 (|y_1|^2 + \dots + |y_n|^2) = \sigma_n^2 \|y\|^2 = \sigma_n^2 \|v^* w\|^2 = \sigma_n^2 \|w\|^2 = \sigma_n^2 \end{aligned}$$

$\sigma_1 \geq \dots \geq \sigma_n$

$\|v^* w\|^2 = \|w\|^2 = 1$

(Alternativa: $1 = \|w\| = \|A^{-1}Aw\| \leq \|A^{-1}\| \cdot \|Aw\| = \frac{\|Aw\|}{\sigma_n}$
 $\Rightarrow \|Aw\| \geq \sigma_n$.)

Luego tenemos que $\|A - B\| \geq \sigma_n \quad \forall B \text{ de rango } \leq n-1$.

Basta ver que esta desigualdad se alcanza en $B = A_{n-1} = \sigma_1 u_1 v_1^* + \dots + \sigma_{n-1} u_{n-1} v_{n-1}^*$

$$\|A - A_{n-1}\| = \|\sigma_n u_n v_n^*\| = |\sigma_n| = \sigma_n. \quad \square$$

Observar que la misma prueba vale para el caso de norma de Frobenius.

Dem Teo: Sea $B \in \mathbb{C}^{m \times n}$ de rango k ($k \leq \text{rango}(A) = r$)

Luego $\dim \text{Ker } B \geq n - k$. Por otro lado sea $W = \langle v_1, \dots, v_{k+1} \rangle$ es decir el espacio generado por los primeros $k+1$ vectores singulares.

Por estar W y $\text{Ker } B$ en \mathbb{C}^n resulta $\exists w \in \text{Ker } B \cap W$ no trivial.

Es decir $\exists w = \alpha_1 v_1 + \dots + \alpha_{k+1} v_{k+1}$, con $|\alpha_1|^2 + \dots + |\alpha_{k+1}|^2 = 1$

y que satisface $Bw = 0$.

$$\text{Luego } \|A - B\|_2 \geq \|(A - B)w\| = \|Aw\| = \|\alpha_1 \sigma_1 v_1 + \dots + \alpha_{k+1} \sigma_{k+1} v_{k+1}\|$$

$$\stackrel{\text{Pitagoras}}{=} \left(|\alpha_1|^2 \sigma_1^2 + \dots + |\alpha_{k+1}|^2 \sigma_{k+1}^2 \right)^{1/2} \geq \left(|\alpha_1|^2 + \dots + |\alpha_{k+1}|^2 \right)^{1/2} \sigma_{k+1} = \sigma_{k+1}.$$

Veamos que el mínimo se alcanza en $B = A_k \in \{k = k\}$

$$\|A - A_k\| = \|\sigma_{k+1} u_{k+1} v_{k+1}^* + \dots + \sigma_n u_n v_n^*\| = \sigma_{k+1}$$

multiplicando por U^* a izq. y V^* a derecha queda una matriz tipo $\begin{pmatrix} \sigma_{k+1} & & \\ & \dots & \\ & & \sigma_n \\ & & & 0 \end{pmatrix}$,
y para ese caso es fácil ver $\|\tilde{\Sigma}\| = \sigma_{k+1}$.

Un resultado similar ocurre si cambiamos $\|\cdot\|_2$ por $\|\cdot\|_F$.

Tro: A como antes.

$$\Rightarrow \min_{B \in \mathbb{C}^{m \times n}} \|A - B\|_F = \|A - A_k\|_F = \sqrt{\sigma_{k+1}^2 + \dots + \sigma_n^2}$$

$$B \in \mathbb{C}^{m \times n}$$

$$\text{rk}(B) \leq k$$

Omitimos la prueba. De cualquier manera la segunda desigualdad es muy fácil.

$$\|A - A_k\|_F^2 = \|\sigma_{k+1} u_{k+1} v_{k+1}^* + \dots + \sigma_n u_n v_n^*\|_F^2$$

$$= \sigma_{k+1}^2 + \dots + \sigma_n^2 \quad \text{dado que } \langle u_i v_i^*, u_j v_j^* \rangle = \delta_{ij}.$$

□