

# Aplicaciones de la SVD (ejemplos)

① Compresión de datos: Una matriz de rango  $r$  se puede

escribir como suma de  $r$  matrices de rango 1:

$$A = U \Sigma V^* = \sum_{k=1}^r \sigma_k U_k V_k^*$$

$U_k = k$ -ésima columna de  $U$

$V_k^* = k$ -ésima fila de  $V^*$

Se puede hacer la cuenta pero es más fácil verlos directamente en la base  $\{v_1, \dots, v_n\}$  de  $K^n$ :

Sabemos que  $A v_j = U \Sigma V^* v_j = U \Sigma e_j = U \sigma_j e_j = \sigma_j e_j, 1 \leq j \leq r$   
y  $A v_j = 0, r+1 \leq j \leq n$

Por otro lado

$$\sum_{k=1}^r \sigma_k U_k V_k^* \cdot v_j = \begin{cases} \sigma_j U_j & \text{para } 1 \leq j \leq r \quad (\text{pues } V_k^* \cdot v_j = \delta_{kj}) \\ 0 & \text{para } r+1 \leq j \leq n. \quad \text{Coinciden!} \end{cases}$$


¿Por qué compresión de datos?

En principio la matriz  $A$  tiene  $m \times n$  coeficientes

Pero para guardar cada  $U_k V_k^*$  se necesitan solo  $m+n$  coeficientes  
y luego se suman  $r$  así  $\Rightarrow r(m+n) + r$  datos ...

y  $r(m+n) \ll mn$  si  $\text{rg}(A)$  chico y  $m, n$  grandes por ejplo!

Ejemplo

Sea  $A =$    $\in \mathbb{R}^{3n \times 3n}$

$\square = 1$   
 $\square = 0$

Dimensions:  $m$  (rows),  $2n$  (columns),  $n$  (width of T),  $n$  (width of T).

$A$  tiene claramente rango 2, luego se puede escribir como suma de 2 matrices de rango 1: Se comprimen (en forma sistemática) los  $9n^2$  coeficientes de  $A$  en 2 valores singulares no nulos

2 vectores  $u_1, u_2$ :  $6n$  coeficientes

2 vectores  $v_1, v_2$ :  $6n$  coeficientes:

o sea  $12n + 2$  contra  $9n^2$  coeficientes

Por ejplo para  $n = 100$ : 1202 contra 90000 .....

Aquí:  $A^t A =$    $=$ 

$n$	$n$	$n$
$n$	$3n$	$n$
$n$	$n$	$n$

comple  $N(A^t A) = N(A) = \langle \underbrace{e_2 - e_1, \dots, e_n - e_1}_{n-1}, \underbrace{e_{2n+1} - e_1, \dots, e_{3n} - e_1}_n, \underbrace{e_{2n+1} - e_{2n}, \dots, e_{3n-1} - e_{2n}}_{n-1} \rangle$

y  $N(A^t A)^\perp = \langle \underbrace{(1, \dots, 1, 0, \dots, 0)}_n, \underbrace{(0, \dots, 0, 1, \dots, 1)}_n, \underbrace{(-1, \dots, -1)}_n \rangle$  es invariante  
 $\omega_1$   $\omega_2$

Se tiene  $A^t A \omega_1 = (2n^2, \dots, 2n^2) = 2n^2 \omega_1 + 2n^2 \omega_2$

$A^t A \omega_2 = (n^2, 3n^2, n^2) = n^2 \omega_1 + 3n^2 \omega_2$

luego en bloque (restringido a  $\langle \omega_1, \omega_2 \rangle$ ) es  $\begin{bmatrix} 2n^2 & n^2 \\ 2n^2 & 3n^2 \end{bmatrix}$

con característicos  $\lambda^2 - 5n^2 \lambda + 4n^4 = (\lambda - 4n^2)(\lambda - n^2)$

y auto vectores  $\omega_1 + 2\omega_2 = (1, \dots, 1, 2, \dots, 2, 1, \dots, 1)$  asociado a  $4n^2$

y  $\omega_1 - \omega_2 = (1, \dots, 1, -1, \dots, -1, 1, \dots, 1)$  asociado a  $n^2$

Así  $A = U \Sigma V^t$  con  $\Sigma = \begin{bmatrix} 2n & & & \\ & n & & \\ & & 0 & \\ & & & 0 \end{bmatrix}$ ,  $V = [v_1 \ v_2 \ \dots]$ ,  $U = [u_1 \ u_2 \ \dots]$

$= \sigma_1 u_1 v_1^t + \sigma_2 u_2 v_2^t$

$= 2n u_1 v_1^t + n u_2 v_2^t$

donde  $v_1 = \left( \underbrace{\frac{\sqrt{6n}}{6n}, \dots, \frac{\sqrt{6n}}{6n}}_n, \underbrace{\frac{\sqrt{6n}}{3n}, \dots, \frac{\sqrt{6n}}{3n}}_n, \underbrace{\frac{\sqrt{6n}}{6n}, \dots, \frac{\sqrt{6n}}{6n}}_n \right)$

$v_2 = \left( \underbrace{\frac{\sqrt{3n}}{3n}, \dots, \frac{\sqrt{3n}}{3n}}_n, \underbrace{-\frac{\sqrt{3n}}{3n}, \dots, -\frac{\sqrt{3n}}{3n}}_n, \underbrace{\frac{\sqrt{3n}}{3n}, \dots, \frac{\sqrt{3n}}{3n}}_n \right)$

y  $u_1 = \frac{A v_1}{\sigma_1} = \left( \underbrace{\frac{\sqrt{6n}}{3n}, \dots, \frac{\sqrt{6n}}{3n}}_n, \underbrace{\frac{\sqrt{6n}}{6n}, \dots, \frac{\sqrt{6n}}{6n}}_{2n} \right)$

$u_2 = \frac{A v_2}{\sigma_2} = \left( \underbrace{\frac{\sqrt{3n}}{3n}, \dots, \frac{\sqrt{3n}}{3n}}_n, \underbrace{-\frac{\sqrt{3n}}{3n}, \dots, -\frac{\sqrt{3n}}{3n}}_{2n} \right)$

2) Aproximación a matrices de rango k

Teorema de Eckart-Young, 1936:

$A = U \Sigma V^*$  con  $\Sigma = \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{bmatrix} \in \mathbb{C}^{m \times n}$ , con  $\sigma_1 \geq \dots \geq \sigma_r > 0$

Sea  $\|A\|_F = \sqrt{\text{tr}(AA^*)}$  la norma Frobenius de A, y sea k fijo,  $1 \leq k \leq r$ :  
 Entonces la matriz  $A_k$  más cercana a A de rango k con esa distancia

es la matriz  $A_k = U \Sigma_k V^*$  donde  $\Sigma_k = \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_k \end{bmatrix} \in \mathbb{C}^{m \times n}$ .

(Se truncan los valores singulares luego del k-ésimo)

Además observemos que dado que  $U, V^*$  son unitarias,

$$\|A\|_F^2 = \text{tr}(U \Sigma V^* V \Sigma^* U^*) = \text{tr}(U \Sigma \Sigma^* U^*) = \text{tr}(\Sigma \Sigma^*) = \sigma_1^2 + \dots + \sigma_r^2$$

y de la misma forma

$$\|A - A_k\|_F^2 = \sigma_{k+1}^2 + \dots + \sigma_r^2$$

Es decir  $d_F(A, M_k) = \|A - A_k\|_F = \sqrt{\sigma_{k+1}^2 + \dots + \sigma_r^2}$   
matrices de rango k

Esto sirve por ejemplo para "eliminar ruido," errores de medición etc, estableciendo una línea de corte entre los valores singulares, los más chicos o por debajo de un umbral se consideran despreciables y se reemplazan por 0.

Después la matriz "medida"  $A$  corresponde en realidad a la matriz real  $A_k$  y se puede establecer el "rango efectivo de  $A$ "

• Con otras normas vale lo mismo. En particular para la norma

$$\text{operador } \|A\|_2 = \sup_{x \in \mathbb{C}^n} \frac{\|Ax\|_2}{\|x\|_2} = \sup_{\|x\|_2=1} \|Ax\|_2 = \max_{\|x\|_2=1} \|Ax\|_2$$

(donde  $\|x\|_2, \|Ax\|_2$  es la norma usual de  $\mathbb{C}^n$  y  $\mathbb{C}^m$  respectivamente)

Vale  $d_2(A, M_k) = \|A - A_k\|_2 = \sigma_{k+1}$  (Ver ejercicio 13 de la práctica)  
con esta norma

### 3) "Condición" de una matriz

La condición de  $A$  para el problema de resolución de un sistema lineal mediante  $Ax=b$  mide cuán mal se comporta la solución  $x'$  cuando se midió mal  $b$  y se resolvió  $Ax'=b'$  en lugar de  $Ax=b$ .

Para  $A$  invertible se evalúa cuán grande puede ser el error relativo  $\frac{\|x'-x\|}{\|x\|}$  en términos del error relativo  $\frac{\|b'-b\|}{\|b\|}$

Fijada una norma como  $\|A\|_F$  ó  $\|A\|_2$ , se tiene:

$$\text{Cond}_F(A) := \|A\|_F \|A^{-1}\|_F \quad (\text{resp } \text{Cond}_2(A) := \|A\|_2 \|A^{-1}\|_2)$$

para  $A$  invertible, y  $\text{Cond}(A) = \infty$  para  $A$  no invertible

satisface en cada caso  $\frac{\|x'-x\|}{\|x\|} \leq \text{Cond}(A) \frac{\|b'-b\|}{\|b\|}$  y se alcanza

Se tiene  $\text{Cond}_2(A) = \frac{\sigma_1}{\sigma_m}$  si  $A \in \text{GL}(n, \mathbb{C})$

Ver Ej. 13 Práctica

4

Las matrices mal puestas son las que son no invertibles, ya que perturbandolas un poco cambia drasticamente el comportamiento c/r a las soluciones

En 1936, Eckerd y Young demostraron (perz  $\| \cdot \|_F$  en realidad)

$$d_F(A, \mathcal{M}_0) = \frac{\|A\|_F}{\text{Cond}_F(A)} \quad \left( \text{donde } \mathcal{M}_0 = \left\{ A \in \mathbb{C}^{n \times n} : \det(A) = 0 \right\} \right)$$

matrices no invertibles

#### 4) Inversa de Moore - Penrose y SVD (Ver Ej. 16 de la práctica)

Sea  $A \in \mathbb{C}^{m \times n}$ , no necesariamente cuadrada

Existen definiciones de matrices "pseudo-inversas" que son matrices lo más cercanas a lo que podría ser una inversa.

La más famosa es la pseudo-inversa de Moore-Penrose  $A^\dagger$  de  $A$  (descrita por E.H. Moore, 1920, Arne Bjerhammar, 1951, y R. Penrose, 1955)

que es una matriz  $A^\dagger \in \mathbb{C}^{n \times m}$  que satisface


- $AA^\dagger A = A$     y     $A^\dagger A A^\dagger = A^\dagger$
- $(AA^\dagger)^* = AA^\dagger$     y     $(A^\dagger A)^* = A^\dagger A$

Se puede probar que esa matriz  $A^\dagger$  existe y es única, y se calcula fácil usando SVD:

Si  $A = U \Sigma V^*$ , entonces  $A^\dagger = V \Sigma^\dagger U^*$  donde para

$$\Sigma = \begin{bmatrix} \sigma_1 & & & \\ & \sigma_r & & \\ & & & \end{bmatrix} \in \mathbb{C}^{m \times n}, \quad \text{se tiene } \Sigma^\dagger = \begin{bmatrix} 1/\sigma_1 & & & \\ & & & \\ & & & 1/\sigma_r \\ & & & \end{bmatrix} \in \mathbb{C}^{n \times m}.$$

#### 5) Y cuadrados mínimos (Ver Ejercicio 16 de la práctica)



¿Cuál es la recta  $L: y = ax + b$  que se "ajusta mejor" a los pts  $(x_1, y_1), \dots, (x_n, y_n)$  del plano dados?

Donde "ajusta mejor" se refiere a minimiza la suma de los cuadrados de las distancias de  $y_i$  a  $(ax_i + b)$ :  $\min \left( \sum_{i=1}^n \|y_i - (ax_i + b)\|^2 \right)$

El problema se puede plantear como resolver

$$\underbrace{\begin{pmatrix} x_1 & \vdots & 1 \\ \vdots & \vdots & \vdots \\ x_n & \vdots & 1 \end{pmatrix}}_A \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \quad \text{que en general no tiene solución.}$$

Se puede probar que la solución es dada por  $\begin{pmatrix} a \\ b \end{pmatrix} = A^+ \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$ ,  
y esto se generaliza a pbs de cuadrados mínimos de dimensión mayor.

Etc, etc, etc... Hay muchas aplicaciones más...

## Endomorfismos ortogonales y unitarios

Hemos visto que  $U \in \mathbb{C}^{n \times n}$  es unitaria si sus columnas son una base ortonormal de  $\mathbb{C}^n$ , o equivalentemente si  $U$  es invertible y  $U^{-1} = U^*$ .

Si miramos  $f_U: \mathbb{C}^n \rightarrow \mathbb{C}^n$ , esto significa que  $f_U$  manda la base canónica de  $\mathbb{C}^n$  a una base ortonormal de  $\mathbb{C}^n$  (dada por las columnas de  $U$ ), o también, dado que en la base canónica  $\mathcal{B}$ ,  $[f_U^*]_{\mathcal{B}} = [f_U]_{\mathcal{B}}^* = U^*$ , que  $f_U$  es invertible y  $f_U^{-1} = f_U^*$  (pues  $[f_U^*]_{\mathcal{B}} = U^{-1} = [f_U]_{\mathcal{B}}^{-1}$ ).

Más aún,  $f_U \in \text{End}_{\mathbb{C}}(\mathbb{C}^n)$  preserva el producto escalar, y la norma:

$$\text{pues } \langle f_U(v), f_U(w) \rangle = \langle v, f_U^* f_U(w) \rangle = \langle v, w \rangle, \quad \forall v, w \in \mathbb{C}^n.$$

Y sea en el caso real, donde el ángulo proviene del p.i,  $f_U$  preserva ángulos y distancias. Es un ejemplo de lo que se llama una isometría.

De hecho, todas estas propiedades caracterizan lo que se llama los endomorfismos unitarios (en el caso  $K = \mathbb{C}$ ) u ortogonales (para  $K = \mathbb{R}$ ) al menos en dimensión finita.

### Definición (Endomorfismo unitario)

Sea  $(V, \langle \cdot, \cdot \rangle)$  un  $K$ -e.v. con p.i, y sea  $f \in \text{End}_K(V)$ .

Se dice que  $f$  es unitaria si  $f$  preserva el p.i, es decir

$$\langle f(v), f(w) \rangle = \langle v, w \rangle, \quad \forall v, w \in V$$

(En el caso euclideo, i.e.  $K = \mathbb{R}$ , se dice que  $f$  es ortogonal)

Observación: p.i. vs. norma

En un K-e.v V con p.i.,  $f \in \text{End}_K(V)$  preserva  $\langle, \rangle$  si

$f$  preserva  $\| \cdot \|$ . I.e.

$\langle f(v), f(w) \rangle = \langle v, w \rangle, \forall v, w \in V \iff \|f(v)\| = \|v\|, \forall v \in V$

Demostación

$(\implies)$  Es obvio. Para  $(\impliedby)$  recuperemos  $\langle, \rangle$  de  $\| \cdot \|$ :

$\forall v, w \in V, \langle v, w \rangle = \text{Re} \langle v, w \rangle + i \text{Im} \langle v, w \rangle$

y  $\langle f(v), f(w) \rangle = \text{Re} \langle f(v), f(w) \rangle + i \text{Im} \langle f(v), f(w) \rangle$

Se tiene:

$\|v+w\|^2 = \langle v+w, v+w \rangle = \|v\|^2 + \langle v, w \rangle + \langle w, v \rangle + \|w\|^2 = \|v\|^2 + \|w\|^2 + 2\text{Re} \langle v, w \rangle$

y del mismo modo  $\|f(v)+f(w)\|^2 = \|f(v)\|^2 + \|f(w)\|^2 + 2\text{Re} \langle f(v), f(w) \rangle$

Esto implica, dado que  $f$  preserva la norma, que  $\text{Re} \langle f(v), f(w) \rangle = \text{Re} \langle v, w \rangle$

Aunlo general, para recuperar  $\text{Im} \langle f(v), f(w) \rangle = \text{Im} \langle v, w \rangle$  en el caso complejo, y observando que  $\text{Im}(z) = -\text{Re}(iz)$  para  $z \in \mathbb{C}$ :

$\|v+iw\|^2 = \langle v+iw, v+iw \rangle = \|v\|^2 + \bar{i} \langle v, w \rangle + i \langle w, v \rangle + \|w\|^2$   
 $= \|v\|^2 + \|w\|^2 - i \langle v, w \rangle - \overline{i \langle v, w \rangle} = \|v\|^2 + \|w\|^2 - 2\text{Re}(i \langle v, w \rangle)$

y  $\|f(v+iw)\|^2 = \|f(v)\|^2 + \|f(w)\|^2 - 2\text{Re}(i \langle f(v), f(w) \rangle)$

Añ'  $-\text{Re}(i \langle v, w \rangle) = -\text{Re}(i \langle f(v), f(w) \rangle) \implies \text{Im} \langle f(v), f(w) \rangle = \text{Im} \langle v, w \rangle \quad \square$

Proposición (transformaciones unitarias e inversa)

Sea  $(V, \langle, \rangle)$  un K-e.v con p.i. de dim. finita y sea  $f \in \text{End}_K(V)$ .

Entonces  $f$  es unitaria (ortogonal)  $\iff f$  es invertible y  $f^{-1} = f^*$   
(Luego también  $\iff [f]_{\mathcal{B}}$  es unitaria para  $\mathcal{B}$  base ortonormal de  $V$ )

Demostación

$(\Leftarrow)$   $\forall v \neq w \langle f(v), f(w) \rangle = \langle v, w \rangle, \forall v, w \in V$ .

Pero  $\langle f(v), f(w) \rangle = \langle v, f^* f(w) \rangle = \langle v, \text{id}_V(w) \rangle = \langle v, w \rangle$   
 $f^* = f^{-1}$

$(\implies)$   $\forall v \neq w$   $f$  es invertible y  $f^{-1} = f^*$ , o sea  $\forall v \neq w \ f^* \circ f(w) = w, \forall w \in V$   
(por estar en dim. finita,  $f^* \circ f = \text{id}_V \implies f \circ f^* = \text{id}_V$  también)

Pero  $\langle v, f^* \circ f(w) \rangle = \langle f(v), f(w) \rangle$  por def de  $f^*$   
 $= \langle v, w \rangle$  por ser unitaria,  $\forall v \in V, \forall w \in V$

Luego  $f^* \circ f(w) = w, \forall w \in V$ , considerando por ejempl  $v = f^* \circ f(w) - w$ :  
 $\|f^* \circ f(w) - w\|^2 = 0 \implies f^* \circ f(w) - w = 0 \implies f^* \circ f(w) = w, \forall w \in V$ .

La segunda equivalencia es simplemente porque sobre una base o.n.  $\mathcal{B}$

$[f^*]_{\mathcal{B}} = [f]_{\mathcal{B}}^* : f^{-1} = f^* \iff [f]_{\mathcal{B}}^{-1} = [f]_{\mathcal{B}}^* \quad \square$

Ejercicio Probar que  $f$  unitaria  $\iff f$  manda base o.n en base o.n (en dim. finita)