

## 4 Descomposició en Valors Singulars (SVD)

La descomposició  $QR$  d'una matriu és un mètode comú per a resoldre sistemes sobredeterminats i per trobar solucions a problemes de mínims quadrats, però no és pas l'únic. Un altre molt comú, i amb gran quantitat d'aplicacions, és l'anomenada *Descomposició en Valors Singulars* d'una matriu o, en anglès, *Singular Value Decomposition* (SVD).

**Teorema 4.1** (SVD [2]). *Sigui  $A \in \mathcal{M}_{m,n}(\mathbb{R})$ , amb  $m \geq n$ . Aleshores, existeix una descomposició de la matriu  $A$  de la forma*

$$A = U\Sigma V^\top \quad (1)$$

*satisfent les següents propietats:*

- $U \in \mathcal{M}_{m,n}(\mathbb{R})$  és matriu ortogonal,  $U^\top U = I_n$ . Els vectors-columna que formen  $U$ , és a dir  $U = (u_1 \ u_2 \ \dots \ u_n)$ , reben el nom de vector singulars per l'esquerra.
- $V \in \mathcal{M}_{n,n}(\mathbb{R})$  és també ortogonal,  $V^\top V = I_n$ . Anàlogament al punt anterior, els vectors-columna que formen  $V$ , o sigui  $V = (v_1 \ v_2 \ \dots \ v_n)$ , s'anomenen vector singulars per la dreta.
- $\Sigma \in \mathcal{M}_{n,n}(\mathbb{R}) = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$  amb  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$ , anomenats valors singulars de la matriu  $A$ . El valor  $\sigma_1$  es diu valor singular principal.

**Comentari 4.2.** 1. *En el cas  $A \in \mathcal{M}_{m,n}(\mathbb{R})$  amb  $m < n$  el mateix teorema s'aplica. És trivial comprovar que la descomposició SVD d' $A^\top$  és  $A^\top = V\Sigma^\top U^\top$ .*

2. *Per a matrius complexes el teorema és també cert canviant "trasposada" per "Hermítica":  $A = U\Sigma V^*$  amb  $U^*U = V^*V = I_n$ .*

*Demostració del Teorema 4.1.* Definim la matriu simètrica  $S := A^\top A \in \mathcal{M}_{n,n}(\mathbb{R})$ . Pel teorema espectral, existeix una base ortonormal de  $\mathbb{R}^n$  que consisteix en els VEPs de  $S$  i, a més, els VAPs corresponents a cada vector són reals; i.e., existeixen  $n$  vectors  $v_1, v_2, \dots, v_n \in \mathbb{R}^n$  t.q.:

$$Sv_i = \lambda_i v_i,$$

amb  $\mathbb{R}^n = [v_1, v_2, \dots, v_n]$  i  $\lambda_i \in \mathbb{R}$ ,  $\langle v_i, v_j \rangle = \delta_{i,j}$  per tot  $i, j = 1 \div n$ . En aquest cas, de fet,  $\lambda_i \geq 0$  per tot  $i = 1 \div n$ , ja que  $S$  és semidefinida positiva. En efecte, sigui  $\xi \in \mathbb{R}^n$ ,  $\xi \neq 0$ , llavors

$$\langle \xi, S\xi \rangle = \langle \xi, A^\top A\xi \rangle = \langle A\xi, A\xi \rangle = \|A\xi\|_2^2 \geq 0.$$

Sense pèrdua de generalitat, podem suposar que els vectors de la base ortonormal vénen ordenats de manera que els vaps respectius són decreixents, i.e.:  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$ . Sigui  $1 \leq r \leq n$

<sup>0</sup>T. Lázaro, M. Ollé i J.R. Pacha. Departament Matemàtica Aplicada I

t.q.:  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r > 0$ ,  $\lambda_{r+1} = \lambda_{r+2} = \dots = \lambda_n = 0$  (notem que pot ser  $r = n$ ). A continuació definim

$$\sigma_1 := \sqrt{\lambda_1}, \sigma_2 := \sqrt{\lambda_2}, \dots, \sigma_r := \sqrt{\lambda_r} \quad (2)$$

de manera que:  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$ . Introduïm també els vectors

$$u_1 = \frac{1}{\sigma_1} Av_1, u_2 = \frac{1}{\sigma_2} Av_2, \dots, u_r = \frac{1}{\sigma_r} Av_r.$$

Aquest vectors són ortogonals dos a dos i unitaris. Comprovem-ho:

$$\langle u_i, u_j \rangle = \frac{1}{\sigma_i \sigma_j} \langle Av_i, Av_j \rangle = \frac{1}{\sigma_i \sigma_j} \langle v_i, A^\top Av_j \rangle = \frac{1}{\sigma_i \sigma_j} \langle v_i, Sv_j \rangle = \frac{\lambda_j}{\sigma_i \sigma_j} \langle v_i, v_j \rangle = \frac{\sigma_j}{\sigma_i} \langle v_i, v_j \rangle = \delta_{ij}$$

per  $i, j = 1 \div r$ , on hem fet servir que, d'acord amb (2) és  $\lambda_j = \sigma_j^2$ , per  $j = 1 \div r$ . A continuació, completem els vectors  $u_1, u_2, \dots, u_r \in \mathbb{R}^m$  amb  $n - r$  vectors  $u_{r+1}, u_{r+2}, \dots, u_n \in \mathbb{R}^n$  de manera que  $\{u_1, u_2, \dots, u_n\}$  formen una família ortonormal a  $\mathbb{R}^m$ . Ara, en la base ortonormal  $\{v_1, v_2, \dots, v_n\}$  de  $\mathbb{R}^n$  i per a la família ortonormal  $\{u_1, u_2, \dots, u_n\}$  de  $\mathbb{R}^m$ , tenim

$$\begin{aligned} Av_j &= \sigma_j \frac{1}{\sigma_j} Av_j = \sigma_j u_j, & \text{per } j = 1 \div r, \\ Av_j &= 0, & \text{per } j = r + 1 \div n \end{aligned} \quad (3)$$

d'acord amb la definició de  $u_j$ ,  $j = 1 \div r$ . Ara, si escrivim  $U = (u_1 \ u_2 \ \dots \ u_n) \in \mathcal{M}_{m,n}(\mathbb{R})$  com la matriu que té per columnes els vectors  $u_1, u_2, \dots, u_n$ ;  $V = (v_1 \ v_2 \ \dots \ v_n) \in \mathcal{M}_{n,n}(\mathbb{R})$  com la matriu que té per columnes els vectors  $v_1, v_2, \dots, v_n$  i  $\Sigma = \text{diag}[\sigma_1, \sigma_2, \dots, \sigma_r, 0, \dots, 0] \in \mathcal{M}_{n,n}(\mathbb{R})$ ; podem expressar (3) en forma matricial com

$$AV = U\Sigma. \quad (4)$$

Finalment, com que les columnes de  $V$  són ortogonals, tenim que  $V^\top V = VV^\top = I_n$ , i multipliant (4) per la dreta a totes dues bandes per  $V^\top$  s'obté la descomposició buscada.  $\square$

La descomposició SVD d'una matriu satisfà moltes propietats importants. Al següent Teorema donem les més destacades.

**Teorema 4.3** ([2]). *Si  $A = U\Sigma V^\top$  la descomposició SVD de la matriu  $A \in \mathcal{M}_{m,n}(\mathbb{R})$ , amb  $m \geq n$ . Aleshores:*

1. *Suposeu que  $A$  és simètrica i que, per tant, admet una descomposició de la forma  $A = UDU^\top$  amb  $D = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ ,  $U = (u_1 \ u_2 \ \dots \ u_n)$  ortogonal, és a dir  $UU^\top = I_n$ . Aleshores una SVD d' $A$  és  $A = U\Sigma V^\top$  amb  $\sigma_i = |\lambda_i|$  i  $v_i = \text{sign}(\lambda_i)u_i$ , on  $\text{sign}$  és la funció "signe" i  $\text{sign}(0) = 1$ .*
2. *Els vaps de la matriu simètrica  $A^\top A \in \mathcal{M}_{n,n}(\mathbb{R})$  són  $\sigma_i^2$ . Els vectors singulars per la dreta  $\{v_1, v_2, \dots, v_n\}$  formen una base ortogonormal de vaps.*

3. Els vaps de la matriu simètrica  $AA^T \in \mathcal{M}_{m,m}(\mathbb{R})$  són  $\sigma_i^2$ ,  $i = 1, 2, \dots, n$ , i  $m - n$  zeros. Els vectors singulars per l'esquerra  $u_i$  són els vep's ortonormals corresponents als vaps  $\sigma_i^2$ .
4. Siguin  $A \in \mathcal{M}_{n-n}(\mathbb{R})$  una matriu quadrada i  $A = U\Sigma V^T$  la seva SVD amb  $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_n)$ ,  $U = (u_1 \ u_2 \ \dots \ u_n)$  i  $V = (v_1 \ v_2 \ \dots \ v_n)$ . Considereu la matriu per blocs

$$H = \begin{pmatrix} 0 & A^T \\ A & 0 \end{pmatrix}.$$

Aleshores, els vaps d' $H$  són  $\{\pm\sigma_1, \pm\sigma_2, \dots, \pm\sigma_n\}$  i els seus veps unitaris corresponents són

$$\frac{1}{\sqrt{2}} \begin{pmatrix} v_i \\ \pm u_i \end{pmatrix}.$$

5. Si  $A$  té rang màxim, és a dir,  $\text{rang}(A) = n$ , llavors

$$\min_x \|Ax - b\| = \|Ax^* - b\|$$

amb  $x^* = V\Sigma^{-1}U^T b$ . Per tant, proporciona la solució del problema de mínims quadrats.

6. La norma euclídea d' $A$  és  $\|A\|_2 = \sigma_1$ . Si  $A \in \mathcal{M}_{n,n}(\mathbb{R})$  és no singular aleshores  $\|A^{-1}\|_2 = 1/\sigma_n$  i el nombre de condició  $\mu_2(A) = \|A\|_2 \|A^{-1}\|_2 = \sigma_1/\sigma_n$ .

7. Suposem  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \sigma_{r+2} = \dots = \sigma_n = 0$ . Llavors,  $\text{rang}(A) = r$  i

$$\ker A = \text{span}\{v_{r+1}, v_{r+2}, \dots, v_n\}, \quad \text{Im} A = \text{span}\{u_1, u_2, \dots, u_r\}.$$

8. Siguin  $S_n = \{x \in \mathbb{R}^n : \|x\|_2 = 1\}$  l'esfera unitat  $n$ -dimensional i  $A(S_n) = \{Ax : x \in S_n\}$  la seva imatge per la matriu  $A \in \mathcal{M}_{m,n}(\mathbb{R})$ . Aleshores,  $A(S_n)$  és un el·lipsoide de centre l'origen d' $\mathbb{R}^m$  i eixos principals  $\sigma_i u_i$ .

*Demostració.* Cadascun dels apartats de la proposició es proven a partir del Teorema 4.1. Deixem doncs la demostració d'aquest teorema com exercici (o bé podeu consultar la referència [2]). *Nota:* aquesta activitat és voluntària i no cal que la presenteu a l'informe de la pràctica.  $\square$

**Exercici 4.4.** (Obligatori, cal que figuri a l'informe). Torneu a fer l'exercici 2 de la 2<sup>a</sup> pràctica (extrapolació de la població a Catalunya) aplicant —en fer l'aproximació per mínims quadrats—, la propietat 5 del Teorema 4.3 (en comptes de la descomposició QR). Compareu els resultats.

Una conseqüència molt interessant del Teorema 4.1 és que proporciona un mètode d'aproximació de la matriu  $A$  per matrius de menor rang. De fet,

**Proposition 4.5** ([2]). *Considerem la descomposició SVD d'una matriu  $A \in \mathcal{M}_{m,n}(\mathbb{R})$ ,  $A = U\Sigma V^\top$  i escrivim  $U = [u_1 \ u_2 \ \dots \ u_n]$  i  $V = [v_1 \ v_2 \ \dots \ v_n]$ , on cada  $u_j$ ,  $v_j$  és un vector columna d' $m$  components. Observeu que podem escriure, equivalentment, que*

$$A = U\Sigma V^\top = \sum_{i=1}^n \sigma_i u_i v_i^\top$$

essent  $\{\sigma_1, \sigma_2, \dots, \sigma_r, \sigma_{r+1} = 0, \dots, \sigma_n = 0\}$  els valors singulars d' $A$ . Aleshores,

$$A_k := \sum_{i=1}^k \sigma_i u_i v_i^\top = U \Sigma_k V^\top,$$

amb  $\Sigma_k = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k, 0, \dots, 0)$ , és la matriu de rang  $k$  que millor aproxima  $A$  en norma euclídea. A més,  $\|A - A_k\|_2 = \sigma_{k+1}$ .

*Demostració.* Es comprova fàcilment que  $\|A - A_k\|_2 = \sigma_{k+1}$ . Sigui  $B \in \mathcal{M}_{m,n}(\mathbb{R})$  de rang  $k < n$  i, per tant, amb  $\dim \text{Nuc} B = n - k$ . Considerem el subespai  $F = [v_1, v_2, \dots, v_{k+1}]$ . Aquests subespais,  $F$  i  $\text{Nuc} B$ , es solapen, ja que la suma de les seves dimensions  $(k + 1) + (n - k) > n$ . Sigui  $\xi$  un vector de la seva intersecció, que agafarem unitari; és a dir, t.q.:  $\|\xi\|_2 = 1$ . Llavors,

$$\|A - B\|_2^2 \geq \|(A - B)\xi\|_2^2 = \|A\xi\|_2^2 = \|U\Sigma V^\top \xi\|_2^2 = \|\Sigma V^\top \xi\|_2^2 \geq \sigma_{k+1}^2 \|V^\top \xi\|_2^2 = \sigma_{k+1}^2.$$

La qual cosa completa la prova. □

Una aplicació divertida a la vegada que pràctica d'aquest darrer resultat és la compressió d'imatges. L'il·lustrarem amb un exemple complet. Supposeu que teniu una fotografia en format `jpg` com aquesta que anomenem `camell.jpg`. El primer que farem serà convertir-la a escala de grisos i



Figura 1: Retrat d'un camell (color i blanc i negre).

després transformar-la en una matriu en doble precisió segons la intensitat de cada píxel o grup de píxels. Malgrat es pot fer amb programes de tractament d'imatge de lliure distribució (per exemple, l'`opencv`) nosaltres usarem `Matlab`. Les comandes són aquestes:



Figura 2: De dalt a baix i d'esquerra a dreta: fotografies corresponents a les diferents aproximacions usant els primers 1, 2, 5, 10, 25, 50, 100, 298 valors singulars d' $A$ , respectivament.

```
A = imread('camel.jpg');
A = rgb2gray(A);
A = im2double(A);
imshow(A)
dlmwrite('camel_matrix.dat', A, 'delimiter', '\t', 'precision', 4)
size(A)
```

La comanda `imshow(A)` mostra la imatge de nou mentre que `dlmwrite` escriu la matriu d'intensitats  $A$  en un fitxer ascii anomenat `camel_matrix.dat` de 600 files i 800 columnes separades per una tabulació. Si tornem a anomenar  $A$  la matriu (numèrica, d'intensitats) guardada al fitxer `camel_matrix.dat` i l'apliquem la SVD, obtenim les matrius que l'aproximen  $A_1, A_2, A_5, A_{10}, A_{25}, A_{100}$

i  $A_{298}$ , obtingudes considerant els  $1, 2, \dots, 298$  primers valors no singulars d' $A$ , respectivament. Si volem recuperar la imatge que correspon a cada una d'aquestes aproximacions, farem a MATLAB:

```
imwrite(Ak, sprintf('camel-%d.jpg', k));
```

on  $k = 1, 2, \dots, 298$ . El resultat el podeu veure a la Figura 2.

Observeu que ja amb només 100 valors singulars (penúltima fotografia a Figura 2) la resolució és força raonable.

**Exercici 4.6.** *Feu el mateix amb una fotografia de vosaltres (és a dir, dels dos components de cada grup). És important que preneu la fotografia a una resolució baixa per a evitar que la matriu surti massa gran. L'exemple del camell està fet a una resolució de  $600 \times 800$ .*

## 5 Presentació d'informes

Els informes s'hauran de lliurar en format PDF a la Intranet (Campus Digital Atenea), a l'espai que, al llarg de la setmana del 17 al 22 de desembre i amb data límit de divendres 22 a les 24 hores estarà actiu per pujar fitxers.

Cada informe haurà de contenir la resolució comentada dels exercicis 4.4 i 4.6 plantejats en aquest guió, una descripció detallada de l'algorisme triat per programar la descomposició SVD, així com la bibliografia (llibres, articles, pàgines güeb,...) que heu consultat.

## Referències

- [1] G. Dahlquist, A. Björck. *Numerical methods in Scientific Computing, vol 1, 2*. SIAM, Philadelphia, 2008.
- [2] J. Demmel *Applied Numerical Linear Algebra*. SIAM, Philadelphia, 1997. 1, 2, 3, 4
- [3] Wikipedia: [http://en.wikipedia.org/wiki/Singular\\_value\\_decomposition](http://en.wikipedia.org/wiki/Singular_value_decomposition)