

Análisis Numérico

Primer cuatrimestre 2022

Introducción a la descomposición SVD

- 1 SVD: Descomposición en valores singulares

- 1 SVD: Descomposición en valores singulares

Teorema (Descomposición SVD)

Sea A una matriz real $m \times n$ con $m \geq n$. Entonces $A = USV^t$ donde

- U es $m \times m$ con $U^t U = Id$ en $\mathbb{R}^{m \times m}$
- V es $n \times n$ con $V^t V = Id$
- $S = \text{diag}(\sigma_1, \dots, \sigma_n)$ es $n \times n$, con $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$

Teorema (Descomposición SVD)

Sea A una matriz real $m \times n$ con $m \geq n$. Entonces $A = USV^t$ donde

- U es $m \times m$ con $U^t U = Id$ en $\mathbb{R}^{m \times m}$
- V es $n \times n$ con $V^t V = Id$
- $S = \text{diag}(\sigma_1, \dots, \sigma_n)$ es $n \times n$, con $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$

- *Vectores singulares a izquierda*: columnas de U , u_1, u_2, \dots, u_n
- *Vectores singulares a derecha*: columnas de V , v_1, v_2, \dots, v_n
- *valores singulares*: σ_i , $i = 1, \dots, n$
- Si $m < n$ definir la SVD considerando A^t

SVD: interpretación geométrica

- $\{v_1, v_2, \dots, v_n\}$ es una BON de \mathbb{R}^n

SVD: interpretación geométrica

- $\{v_1, v_2, \dots, v_n\}$ es una BON de \mathbb{R}^n
- $Av_j = USV^t v_j = USe_j = \sigma_j Ue_j = \sigma_j u_j$

SVD: interpretación geométrica

- $\{v_1, v_2, \dots, v_n\}$ es una BON de \mathbb{R}^n
- $Av_i = USV^t v_i = USe_i = \sigma_i Ue_i = \sigma_i u_i$
- Podemos pensar a A como una transformación

$$A: \mathbb{R}^n \rightarrow \mathbb{R}^m \quad A(x) = Ax$$

En este caso tenemos una BON de $\text{dom } A$, $\{v_i\}_{i=1}^n$ y una BON del rango de A , $\{u_i\}_{i=1}^n$. En estas bases A actúa como una matriz diagonal

$$A \left(\sum_{i=1}^n \beta_i v_i \right) = \sum_{i=1}^n \sigma_i \beta_i u_i, \quad \circ \quad A(\beta_i) = S(\beta_i)$$

Propiedades de la SVD

- Los autovalores de la matriz simétrica $A^t A$ son σ_i^2 . Los vectores singulares a derecha forman una BON de autovectores de $A^t A$

Propiedades de la SVD

- Los autovalores de la matriz simétrica $A^t A$ son σ_i^2 . Los vectores singulares a derecha forman una BON de autovectores de $A^t A$

$$A^t A = (USV^t)^t (USV^t) = (VSU^t)(USV^t) = VS(U^t U)SV^t = VS^2 V^t$$

Propiedades de la SVD

- Los autovalores de la matriz simétrica $A^t A$ son σ_i^2 . Los vectores singulares a derecha forman una BON de autovectores de $A^t A$

$$A^t A = (USV^t)^t (USV^t) = (VSU^t)(USV^t) = VS(U^t U)SV^t = VS^2 V^t$$

- Si A es *full rank* ($\text{rg}(A) = \min(m, n) = n$), entonces la solución de

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2$$

es $x = VS^{-1}U^t b$. $VS^{-1}U^t$ se llama inversa de Moore-Penrose de A

Propiedades de la SVD

- Los autovalores de la matriz simétrica $A^t A$ son σ_i^2 . Los vectores singulares a derecha forman una BON de autovectores de $A^t A$

$$A^t A = (USV^t)^t (USV^t) = (VSU^t)(USV^t) = VS(U^t U)SV^t = VS^2 V^t$$

- Si A es *full rank* ($\text{rg}(A) = \min(m, n) = n$), entonces la solución de

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2$$

es $x = VS^{-1}U^t b$. $VS^{-1}U^t$ se llama inversa de Moore-Penrose de A

$$\begin{aligned} A^t Ax &= A^t A(VS^{-1}U^t b) = (VS^2 V^t)(VS^{-1}U^t b) \\ &= VS^2(V^t V)S^{-1}U^t b = VS^2 S^{-1}U^t b = VSU^t b \end{aligned}$$

Propiedades de la SVD

- $\|A\|_2 = \sigma_1$, $\|A^{-1}\|_2 = \sigma_n^{-1}$

Propiedades de la SVD

- $\|A\|_2 = \sigma_1$, $\|A^{-1}\|_2 = \sigma_n^{-1}$
- Supongamos $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0$. Entonces:
 - $rg(A) = r$
 - $ran(A)(= Im(A)) = \langle u_1, \dots, u_r \rangle$
 - $ker A = \langle v_{r+1}, \dots, v_n \rangle$

Propiedades de la SVD

- $\|A\|_2 = \sigma_1$, $\|A^{-1}\|_2 = \sigma_n^{-1}$
- Supongamos $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0$. Entonces:
 - $rg(A) = r$
 - $ran(A)(= Im(A)) = \langle u_1, \dots, u_r \rangle$
 - $ker A = \langle v_{r+1}, \dots, v_n \rangle$

recordar que $A(\sum_{i=1}^n \beta_i v_i) = \sum_{i=1}^n \sigma_i \beta_i u_i$

Propiedades de la SVD

- $\|A\|_2 = \sigma_1$, $\|A^{-1}\|_2 = \sigma_n^{-1}$
- Supongamos $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0$. Entonces:
 - $rg(A) = r$
 - $ran(A)(= Im(A)) = \langle u_1, \dots, u_r \rangle$
 - $ker A = \langle v_{r+1}, \dots, v_n \rangle$

recordar que $A(\sum_{i=1}^n \beta_i v_i) = \sum_{i=1}^n \sigma_i \beta_i u_i$

- Para $k < n$ sea $S_k = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k, 0, \dots, 0)$, y $A_k = US_k V^t$. Entonces A_k tiene rango k y

$$\|A - A_k\|_2 = \min \{ \|A - B\|_2 : B \text{ matriz } m \times n \text{ de rango } k \}$$

Propiedades de la SVD

- $\|A\|_2 = \sigma_1$, $\|A^{-1}\|_2 = \sigma_n^{-1}$
- Supongamos $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0$. Entonces:
 - $rg(A) = r$
 - $ran(A)(= Im(A)) = \langle u_1, \dots, u_r \rangle$
 - $ker A = \langle v_{r+1}, \dots, v_n \rangle$

recordar que $A(\sum_{i=1}^n \beta_i v_i) = \sum_{i=1}^n \sigma_i \beta_i u_i$

- Para $k < n$ sea $S_k = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k, 0, \dots, 0)$, y $A_k = US_k V^t$. Entonces A_k tiene rango k y

$$\|A - A_k\|_2 = \min \{ \|A - B\|_2 : B \text{ matriz } m \times n \text{ de rango } k \}$$

$A - A_k = U(S - S_k)V^t$ por lo tanto $\|A - A_k\|_2 = \sigma_{k+1}$. Además sea B con $rg B = k$. Sea h vector unitario en $ker(A) \cap \langle v_1, \dots, v_{k+1} \rangle$. Entonces

$$\begin{aligned} \|A - B\|_2^2 &\geq \|(A - B)h\|_2^2 = \|Ah\|_2^2 = \\ &\|USV^t h\|_2^2 = \|S(V^t h)\|_2^2 \geq \sigma_{k+1} \|V^t h\|_2^2 = \sigma_{k+1}^2 \end{aligned}$$

Propiedades de la SVD

```
1 n = 10;
2 A = imread('imagen.jpg');
3 [U,S,V] = svd(A,"econ");
4 d = diag(S);
5 d1 = d(1:n);
6 d1(1:n) = d(1:n);
7 U1 = U(:,1:n);
8 S1 = diag(d1);
9 V1 = V(:,1:n);
10 A1 = U1*S1*V1';
11 imshow(A1,[min(min(A1)) max(max(A1))])
```