



Uso de LS

$$\min \sum_i^M \left(S_i - S_0 \exp^{-bg_i^T \mathbf{D} g_i} \right)^2, \quad \text{con } g_i \text{ en } \mathbb{R}^3$$




Esta matriz de 3x3 simétrica y definida positiva es un tensor de difusión de hidrógeno.

En cada posición del cerebro tenemos una matriz




Tractografía cerebral





Tractografía cerebral



La forma de los elipsoides tambien es importante



A veces esta solución no es buena



- ¡No se pierda su próximo curso de optimización!

Descomposicion SVD y aplicaciones

MAT-25 I

Dr. Alonso Ramírez Manzanares
CIMAT

e-mail: alam@cimat.mx

web: http://www.cimat.mx/~alam/met_num/

Dr. Joaquín Peña Acevedo
CIMAT A.C.

e-mail: joaquin@cimat.mx

Descomposición SVD

- El nombre SVD viene de Singular Value Decomposition
- Partimos del teorema de algebra lineal que nos dice: *Cualquier matriz rectangular, siempre se puede descomponer como producto de 3 matrices*

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T$$

- donde \mathbf{U} es ortonormal (cuadrada), \mathbf{S} es diagonal y \mathbf{V} es ortonormal (cuadrada). Entonces $\mathbf{U}^T \mathbf{U} = \mathbf{I}$ y $\mathbf{V}^T \mathbf{V} = \mathbf{I}$.
- Las columnas de \mathbf{U} son los eigenvectores (ortonormales) de $\mathbf{A}\mathbf{A}^T$ y las columnas de \mathbf{V} son los eigenvectores (ortonormales) de $\mathbf{A}^T \mathbf{A}$.
- Las entradas de \mathbf{S} se llaman *valores singulares* y son las raíces cuadradas de los eigenvalores de \mathbf{U} o \mathbf{V} en orden descendente, las cuales son no-negativas.

Descomposición SVD

- La descomposición es “casi” única: permutaciones en columnas y en los elementos de la diagonal generan otras descomposiciones.

- USV^T se puede descomponer como suma de matrices de rango 1.

$$USV^T = s_1 \mathbf{u}_1 \mathbf{v}_1^T + \dots + s_r \mathbf{u}_r \mathbf{v}_r^T$$

- Cuando la matriz A es compleja, la descomposición se da en términos de la transpuesta conjugada

Descomposición SVD

- La descomposición es “casi” única: permutaciones en columnas y en los elementos de la diagonal generan otras descomposiciones.

- USV^T se puede descomponer como suma de matrices de rango 1.

$$USV^T = s_1 \mathbf{u}_1 \mathbf{v}_1^T + \cdots + s_r \mathbf{u}_r \mathbf{v}_r^T$$

- Cuando la matriz A es compleja, la descomposición se da en términos de la transpuesta conjugada

$$A_{mn} = U_{mm} S_{mn} V_{nn}^*$$

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$
- Calculamos:
- Definición de descomposición espectral
- Uso del determinante
- Resolviendo el polinomio
- Sustituyendo en el SEL

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$
- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$
- Definición de descomposición espectral
- Uso del determinante
- Resolviendo el polinomio
- Sustituyendo en el SEL

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$

- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$

- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

- Uso del determinante

- Resolviendo el polinomio

- Sustituyendo en el SEL

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$

- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$

- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

- Uso del determinante $\begin{vmatrix} (11 - \lambda) & 1 \\ 1 & (11 - \lambda) \end{vmatrix} = 0$

- Resolviendo el polinomio

- Sustituyendo en el SEL

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$
- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$
- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$
- Uso del determinante $\begin{vmatrix} (11 - \lambda) & 1 \\ 1 & (11 - \lambda) \end{vmatrix} = 0$
- Resolviendo el polinomio $\lambda = 10, \lambda = 12$
- Sustituyendo en el SEL

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$

- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$

- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

- Uso del determinante $\begin{vmatrix} (11 - \lambda) & 1 \\ 1 & (11 - \lambda) \end{vmatrix} = 0$

- Resolviendo el polinomio $\lambda = 10, \lambda = 12$

- Sustituyendo en el SEL $(11 - 10)x_1 + x_2 = 0$

$$x_1 = -x_2$$

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$

- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$

- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

- Uso del determinante $\begin{vmatrix} (11 - \lambda) & 1 \\ 1 & (11 - \lambda) \end{vmatrix} = 0$

- Resolviendo el polinomio $\lambda = 10, \lambda = 12$

- Sustituyendo en el SEL $(11 - 10)x_1 + x_2 = 0$

$$x_1 = -x_2$$

eigenvector $[1, -1]$

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$
- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$
- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$
- Uso del determinante $\begin{vmatrix} (11 - \lambda) & 1 \\ 1 & (11 - \lambda) \end{vmatrix} = 0$
- Resolviendo el polinomio $\lambda = 10, \lambda = 12$
- Sustituyendo en el SEL $(11 - 10)x_1 + x_2 = 0$ $(11 - 12)x_1 + x_2 = 0$
 $x_1 = -x_2$ $x_1 = x_2$
eigenvector $[1, -1]$

Ejemplo:

- Dada $A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$
- Calculamos: $AA^T = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix}$
- Definición de descomposición espectral $\begin{bmatrix} 11 & 1 \\ 1 & 11 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$
- Uso del determinante $\begin{vmatrix} (11 - \lambda) & 1 \\ 1 & (11 - \lambda) \end{vmatrix} = 0$
- Resolviendo el polinomio $\lambda = 10, \lambda = 12$
- Sustituyendo en el SEL $(11 - 10)x_1 + x_2 = 0$ $(11 - 12)x_1 + x_2 = 0$
 $x_1 = -x_2$ $x_1 = x_2$
eigenvector $[1, -1]$ eigenvector $[1, 1]$

Ejemplo (2)

- Usando la orthonormalización
- Hacemos el mismo proceso para

$$U = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \end{bmatrix}$$

- Obteniendo
- Usando los eigenvalores antes calculados (o también los de $A^T A$) construimos

Ejemplo (2)

- Usando la orthonormalización

$$U = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \end{bmatrix}$$

- Hacemos el mismo proceso para

$$A^T A = \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} = \begin{bmatrix} 10 & 0 & 2 \\ 0 & 10 & 4 \\ 2 & 4 & 2 \end{bmatrix}$$

- Obteniendo
- Usando los eigenvalores antes calculados (o también los de $A^T A$) construimos

Ejemplo (2)

- Usando la orthonormalización

$$U = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \end{bmatrix}$$

- Hacemos el mismo proceso para

$$A^T A = \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} = \begin{bmatrix} 10 & 0 & 2 \\ 0 & 10 & 4 \\ 2 & 4 & 2 \end{bmatrix}$$

- Obteniendo

$$V^T = \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix}$$

- Usando los eigenvalores antes calculados (o también los de $A^T A$) construimos

Ejemplo (2)

- Usando la orthonormalización

$$U = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \end{bmatrix}$$

- Hacemos el mismo proceso para

$$A^T A = \begin{bmatrix} 3 & -1 \\ 1 & 3 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix} = \begin{bmatrix} 10 & 0 & 2 \\ 0 & 10 & 4 \\ 2 & 4 & 2 \end{bmatrix}$$

- Obteniendo

$$V^T = \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix}$$

- Usando los eigenvalores antes calculados (o también los de $A^T A$) construimos

$$S = \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix}$$

Ejemplo (3)

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & \frac{-1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

Ejemplo (3)

- Y finalmente

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -1 \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

Ejemplo (3)

- Y finalmente

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -1 \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

Ejemplo (3)

- Y finalmente

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -1 \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

Ejemplo (3)

- Y finalmente

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -1 \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

Ejemplo (3)

- Y finalmente

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -1 \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

Ejemplo (3)

- Y finalmente

$$A_{mn} = U_{mm} S_{mn} V_{nn}^T = \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & \frac{-1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \sqrt{12} & 0 & 0 \\ 0 & \sqrt{10} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} =$$
$$\begin{bmatrix} \frac{\sqrt{12}}{\sqrt{2}} & \frac{\sqrt{10}}{\sqrt{2}} & 0 \\ \frac{\sqrt{12}}{\sqrt{2}} & \frac{-\sqrt{10}}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{6}} & \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \\ \frac{2}{\sqrt{5}} & \frac{-1}{\sqrt{5}} & 0 \\ \frac{1}{\sqrt{30}} & \frac{2}{\sqrt{30}} & \frac{-5}{\sqrt{30}} \end{bmatrix} = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$

- Algo interesante es que esta descomposición nos indica que el operador lineal \mathbf{A} aplicado a un vector realiza una rotación, luego un escalamiento y luego otra rotación.

Una aplicación: condicionamiento (1)

- Descomponemos la matriz como: $\mathbf{a} = \mathbf{u} \mathbf{w} \mathbf{v}^T$

- con
$$\mathbf{w} = \begin{bmatrix} w_1 & 0 & \cdot & 0 & 0 \\ 0 & w_1 & \cdot & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & w_{n-1} & 0 \\ 0 & 0 & \cdot & 0 & w_n \end{bmatrix}$$

- y sabemos que $\mathbf{u} \mathbf{u}^T = \mathbf{I}$ y $\mathbf{v} \mathbf{v}^T = \mathbf{I}$.

- $w_1, w_2, \dots, w_n \geq 0$ (los valores singulares de la matriz).

Una aplicación: condicionamiento (2)

- Si la matriz \mathbf{a} es cuadrada, las matrices \mathbf{u} y \mathbf{v} también lo son, entonces la inversa de \mathbf{a} es

- $\mathbf{a}^{-1} = (\mathbf{u} \mathbf{w} \mathbf{v}^T)^{-1}$
 $= (\mathbf{v}^T)^{-1} \mathbf{w}^{-1} \mathbf{u}^{-1}$
 $= \mathbf{v} \mathbf{w}^{-1} \mathbf{u}^T$

- con

-

Una aplicación: condicionamiento (2)

- Si la matriz \mathbf{a} es cuadrada, las matrices \mathbf{u} y \mathbf{v} también lo son, entonces la inversa de \mathbf{a} es

- $$\begin{aligned}\mathbf{a}^{-1} &= (\mathbf{u} \mathbf{w} \mathbf{v}^T)^{-1} \\ &= (\mathbf{v}^T)^{-1} \mathbf{w}^{-1} \mathbf{u}^{-1} \\ &= \mathbf{v} \mathbf{w}^{-1} \mathbf{u}^T\end{aligned}$$

- con

- $$\mathbf{w}^{-1} = \begin{bmatrix} \frac{1}{w_1} & 0 & \cdot & 0 & 0 \\ 0 & \frac{1}{w_2} & \cdot & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \frac{1}{w_{n-1}} & 0 \\ 0 & 0 & \cdot & 0 & \frac{1}{w_n} \end{bmatrix}$$

Una aplicación: condicionamiento (2)

- Si la matriz \mathbf{a} es cuadrada, las matrices \mathbf{u} y \mathbf{v} también lo son, entonces la inversa de \mathbf{a} es

- $\mathbf{a}^{-1} = (\mathbf{u} \mathbf{w} \mathbf{v}^T)^{-1}$
 $= (\mathbf{v}^T)^{-1} \mathbf{w}^{-1} \mathbf{u}^{-1}$
 $= \mathbf{v} \mathbf{w}^{-1} \mathbf{u}^T$

- con

- $$\mathbf{w}^{-1} = \begin{bmatrix} \frac{1}{w_1} & 0 & \cdot & 0 & 0 \\ 0 & \frac{1}{w_2} & \cdot & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \frac{1}{w_{n-1}} & 0 \\ 0 & 0 & \cdot & 0 & \frac{1}{w_n} \end{bmatrix}$$

- Cuando algún w_i es cero la matriz es singular.

Una aplicación: condicionamiento (3)

- Veamos que pasa al tratar de resolver un SLE con una matriz singular

$$\mathbf{ax} = \mathbf{y}$$

$$\mathbf{a}^{-1}(\mathbf{ax}) = \mathbf{a}^{-1}\mathbf{y}$$

$$(\mathbf{a}^{-1}\mathbf{a})\mathbf{x} = \mathbf{a}^{-1}\mathbf{y}$$

$$\mathbf{x} = \mathbf{a}^{-1}\mathbf{y} = \mathbf{vw}'\mathbf{u}^t\mathbf{y}$$

- Para evitar errores por singularidad, usamos

Una aplicación: condicionamiento (3)

- Veamos que pasa al tratar de resolver un SLE con una matriz singular

$$\mathbf{ax} = \mathbf{y}$$

$$\mathbf{a}^{-1}(\mathbf{ax}) = \mathbf{a}^{-1}\mathbf{y}$$

$$(\mathbf{a}^{-1}\mathbf{a})\mathbf{x} = \mathbf{a}^{-1}\mathbf{y}$$

$$\mathbf{x} = \mathbf{a}^{-1}\mathbf{y} = \mathbf{vw}'\mathbf{u}^t\mathbf{y}$$

- Para evitar errores por singularidad, usamos

$$\mathbf{w}' = \begin{bmatrix} w'_1 & 0 & \cdot & 0 & 0 \\ 0 & w'_2 & \cdot & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & w'_{n-1} & 0 \\ 0 & 0 & \cdot & 0 & w'_n \end{bmatrix}$$

Una aplicación: condicionamiento (3)

- Veamos que pasa al tratar de resolver un SLE con una matriz singular

$$\mathbf{ax} = \mathbf{y}$$

$$\mathbf{a}^{-1}(\mathbf{ax}) = \mathbf{a}^{-1}\mathbf{y}$$

$$(\mathbf{a}^{-1}\mathbf{a})\mathbf{x} = \mathbf{a}^{-1}\mathbf{y}$$

$$\mathbf{x} = \mathbf{a}^{-1}\mathbf{y} = \mathbf{vw}'\mathbf{u}^t\mathbf{y}$$

- Para evitar errores por singularidad, usamos

$$\mathbf{w}' = \begin{bmatrix} w'_1 & 0 & \cdot & 0 & 0 \\ 0 & w'_2 & \cdot & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & w'_{n-1} & 0 \\ 0 & 0 & \cdot & 0 & w'_n \end{bmatrix}$$

con

Una aplicación: condicionamiento (3)

- Veamos que pasa al tratar de resolver un SLE con una matriz singular

$$\mathbf{ax} = \mathbf{y}$$

$$\mathbf{a}^{-1}(\mathbf{ax}) = \mathbf{a}^{-1}\mathbf{y}$$

$$(\mathbf{a}^{-1}\mathbf{a})\mathbf{x} = \mathbf{a}^{-1}\mathbf{y}$$

$$\mathbf{x} = \mathbf{a}^{-1}\mathbf{y} = \mathbf{vw}'\mathbf{u}^t\mathbf{y}$$

- Para evitar errores por singularidad, usamos

$$\mathbf{w}' = \begin{bmatrix} w'_1 & 0 & \cdot & 0 & 0 \\ 0 & w'_2 & \cdot & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & w'_{n-1} & 0 \\ 0 & 0 & \cdot & 0 & w'_n \end{bmatrix}$$

con

$$w'_i = \begin{cases} \frac{1}{w_i} & (w_i \geq \varepsilon) \\ 0 & (w_i < \varepsilon) \end{cases}$$

Una aplicación: condicionamiento (4)

- El valor de ε en

$$w'_i = \begin{cases} \frac{1}{w_i} & (w_i \geq \varepsilon) \\ 0 & (w_i < \varepsilon) \end{cases}$$

depende de la precisión de la máquina.

- Cuando la matriz \mathbf{a} es singular el SLE no tiene solución, pero mediante esta formulación obtenemos la solución \mathbf{x} de mínimos cuadrados $\|\mathbf{ax}-\mathbf{y}\|_2$.

- Es decir, la operación

$$\mathbf{x} = \mathbf{a}^{-1}\mathbf{y} = \mathbf{vw}'\mathbf{u}^t\mathbf{y}$$



- se puede usar cuando tenemos mas ecuaciones que incógnitas, es decir se puede usar en solución general de mínimos cuadrados, esto es conocido como una *pseudo inversa* de SVD.

Condicionamiento

- Nótese que en este caso explícitamente sabemos qué es lo que está fallando, es decir, que tan singular es la matriz, mientras que si usamos eliminación Gaussiana o descomposición LU no tenemos la información.

Otra aplicación Reducción de dimensionalidad en Datos (1)



- En este ejemplo trabajaremos con algo que se llama SVD reducido.
- La idea es capturar la información relevante de un conjunto de datos y eliminar la que no nos sirve (a veces es ruido), veamos esto graficamente:



- Entonces, lo que queremos es explicar los datos en bajas dimensiones.

Otra aplicación Reducción de dimensionalidad en Datos (1)



- En este ejemplo trabajaremos con algo que se llama SVD reducido.
- La idea es capturar la información relevante de un conjunto de datos y eliminar la que no nos sirve (a veces es ruido), veamos esto graficamente:



- Entonces, lo que queremos es explicar los datos en bajas dimensiones.


Otra aplicación Reducción de dimensionalidad en Datos (1)

- En este ejemplo trabajaremos con algo que se llama SVD reducido.
- La idea es capturar la información relevante de un conjunto de datos y eliminar la que no nos sirve (a veces es ruido), veamos esto graficamente:




- Entonces, lo que queremos es explicar los datos en bajas dimensiones.

Maldición de la dimensionalidad, experimento



- En \mathbf{R}^1 $d_{ab} = 3$, $d_{bc} = 1$
- Cuando aumentamos de dimensión solo agregamos $\pm\epsilon$ en la nueva dimensión con signo aleatorio, de tal forma que los puntos a, b y c siguen muy cerca de 1, 4 y 5 en la recta \mathbf{R}^1 respectivamente.
- En \mathbf{R}^{105} $d_{ab} = 3.698648$, $d_{bc} = 2.493993$
- Con $\epsilon = 0.15$



Otra aplicación Reducción de dimensionalidad en Datos (1)

- Veamos como se aplica esto a datos de un análisis de semántica llamado latente, la matriz tiene información de la ocurrencia de palabras en documentos de texto, entonces es una matriz *palabras x documentos*

$$A = \begin{array}{c} \begin{array}{ccccc} \text{doc 1} & \text{doc 2} & \text{doc 3} & \text{doc 4} & \text{doc 5} \\ \text{doc} & \text{doc} & \text{doc} & \text{doc} & \text{doc} \end{array} \\ \left[\begin{array}{ccccc} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{array} \right] \begin{array}{l} \text{doctor} \\ \text{car} \\ \text{nurse (enfermera)} \\ \text{hospital} \\ \text{wheel (rueda)} \end{array} \end{array}$$

- ¿Qué información tiene un renglón de la matriz?
- ¿Qué información tiene una columna de la matriz?

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Veamos como se aplica esto a datos de un análisis de semántica llamado latente, la matriz tiene información de la ocurrencia de palabras en documentos de texto, entonces es una matriz *palabras x documentos*

$$A = \begin{array}{c} \begin{array}{ccccc} \text{doc 1} & \text{doc 2} & \text{doc 3} & \text{doc 4} & \text{doc 5} \\ \text{doc} & \text{doc} & \text{doc} & \text{doc} & \text{doc} \end{array} \\ \left[\begin{array}{ccccc} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{array} \right] \begin{array}{l} \text{doctor} \\ \text{car} \\ \text{nurse (enfermera)} \\ \text{hospital} \\ \text{wheel (rueda)} \end{array} \end{array}$$

- ¿Qué información tiene un renglón de la matriz?
 - Características de las palabras en \mathbb{R}^5
- ¿Qué información tiene una columna de la matriz?

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Veamos como se aplica esto a datos de un análisis de semántica llamado latente, la matriz tiene información de la ocurrencia de palabras en documentos de texto, entonces es una matriz *palabras x documentos*

$$A = \begin{array}{c} \begin{array}{ccccc} \text{doc 1} & \text{doc 2} & \text{doc 3} & \text{doc 4} & \text{doc 5} \\ \begin{bmatrix} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{bmatrix} \end{array} \end{array} \begin{array}{l} \text{doctor} \\ \text{car} \\ \text{nurse (enfermera)} \\ \text{hospital} \\ \text{wheel (rueda)} \end{array}$$

- ¿Qué información tiene un renglón de la matriz?
 - Características de las palabras en \mathbb{R}^5
- ¿Qué información tiene una columna de la matriz?
 - Características de los documentos en \mathbb{R}^5

Otra aplicación Reducción de dimensionalidad en Datos (1)



- De la descomposición de $A = USV^T$

- $$AA^T = \begin{bmatrix} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{bmatrix} \begin{bmatrix} 2 & 1 & 5 & 7 & 0 \\ 0 & 6 & 0 & 0 & 10 \\ 8 & 0 & 7 & 8 & 0 \\ 6 & 1 & 4 & 5 & 0 \\ 0 & 7 & 0 & 0 & 7 \end{bmatrix} = \begin{bmatrix} 104 & 8 & 90 & 108 & 0 \\ 8 & 87 & 9 & 12 & 109 \\ 90 & 9 & 90 & 111 & 0 \\ 108 & 12 & 111 & 138 & 0 \\ 0 & 109 & 0 & 0 & 149 \end{bmatrix}$$

- tiene los productos puntos de los descriptores de palabras es decir sus vectores involucrados contienen características de palabras. Por otro lado, $A^T A$ contiene información de las características de los documentos.

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Cuando calculamos \mathbf{U} y \mathbf{V} , es decir los eigenvectores de \mathbf{AA}^T y de $\mathbf{A}^T\mathbf{A}$, estamos obteniendo componentes ortogonales que describen los datos y la matriz \mathbf{S} tiene los valores singulares que indican que componentes son más importantes ya que es donde hay mas variabilidad entre los datos.



Otra aplicación Reducción de dimensionalidad en Datos (1)

- Haciendo los cálculos para obtener U y V tenemos:

$$A = \begin{bmatrix} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{bmatrix} =$$

$$\begin{bmatrix} -0.5423 & 0.0650 & 0.8216 & 0.1057 & -0.1245 \\ -0.1018 & -0.5935 & -0.1126 & 0.7881 & 0.0603 \\ -0.5250 & 0.0594 & -0.2130 & -0.1157 & 0.8137 \\ -0.6449 & 0.0704 & -0.5087 & -0.0599 & -0.5628 \\ -0.0645 & -0.7969 & 0.0900 & -0.5922 & -0.0441 \end{bmatrix} * \begin{bmatrix} 17.9184 & 0 & 0 & 0 & 0 \\ 0 & 15.1714 & 0 & 0 & 0 \\ 0 & 0 & 3.5640 & 0 & 0 \\ 0 & 0 & 0 & 1.9842 & 0 \\ 0 & 0 & 0 & 0 & 0.3496 \end{bmatrix} * \begin{bmatrix} -0.4646 & 0.0215 & -0.8685 & 0.0008 & -0.1713 \\ -0.0701 & -0.7600 & 0.0631 & -0.6013 & -0.2278 \\ -0.7351 & 0.0988 & 0.2840 & -0.2235 & 0.5650 \\ -0.4844 & 0.0254 & 0.3989 & 0.3327 & -0.7035 \\ -0.0650 & -0.6415 & -0.0443 & 0.6912 & 0.3233 \end{bmatrix}^T$$

- A esta reconstrucción se le llama SVD completo (full - SVD)

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Por otro lado, ¿qué pasa si tomamos únicamente las primeras 4 dimensiones con más variabilidad?, las 4 más importantes:

$$A = \begin{bmatrix} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{bmatrix}$$

$$\begin{bmatrix} -0.5423 & 0.0650 & 0.8216 & 0.1057 \\ -0.1018 & -0.5935 & -0.1126 & 0.7881 \\ -0.5250 & 0.0594 & -0.2130 & -0.1157 \\ -0.6449 & 0.0704 & -0.5087 & -0.0599 \\ -0.0645 & -0.7969 & 0.0900 & -0.5922 \end{bmatrix}
 \begin{bmatrix} -0.1245 & 0.0603 & 0.8137 & -0.5628 & -0.0441 \\ 17.9184 & 0 & 0 & 0 & 0 \\ 0 & 15.1714 & 0 & 0 & 0 \\ 0 & 0 & 3.5640 & 0 & 0 \\ 0 & 0 & 0 & 1.9842 & 0 \\ 0 & 0 & 0 & 0 & 0.3496 \end{bmatrix}
 \begin{bmatrix} -0.4646 & 0.0215 & -0.8685 & 0.0008 \\ -0.0701 & -0.7600 & 0.0631 & -0.6013 \\ -0.7351 & 0.0988 & 0.2840 & -0.2235 \\ -0.4844 & 0.0254 & 0.3989 & 0.3327 \\ -0.0650 & -0.6415 & -0.0443 & 0.6912 \end{bmatrix}
 \begin{bmatrix} -0.1713 \\ -0.2278 \\ 0.5650 \\ -0.7035 \\ 0.3233 \end{bmatrix}^T$$

$$= \begin{bmatrix} 1.9925 & -0.0099 & 8.0246 & 5.9694 & 0.0141 \\ 1.0036 & 6.0048 & -0.0119 & 1.0148 & 6.9932 \\ 5.0487 & 0.0648 & 6.8393 & 4.2001 & -0.0920 \\ 6.9663 & -0.0448 & 8.1112 & 4.8616 & 0.0636 \\ -0.0026 & 9.9965 & 0.0087 & -0.0109 & 7.0050 \end{bmatrix} = \hat{A}$$

- A esta reconstrucción se le llama SVD reducido (reduced - SVD)

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Por otro lado, que pasa si tomamos únicamente las primeras 3 dimensiones con mas variabilidad, las 3 más importantes:

$$A = \begin{bmatrix} 2 & 0 & 8 & 6 & 0 \\ 1 & 6 & 0 & 1 & 7 \\ 5 & 0 & 7 & 4 & 0 \\ 7 & 0 & 8 & 5 & 0 \\ 0 & 10 & 0 & 0 & 7 \end{bmatrix}$$

$$\begin{bmatrix} -0.5423 & 0.0650 & 0.8216 & 0.1057 & -0.1245 \\ -0.1018 & -0.5935 & -0.1126 & 0.7881 & 0.0603 \\ -0.5250 & 0.0594 & -0.2130 & -0.1157 & 0.8137 \\ -0.6449 & 0.0704 & -0.5087 & -0.0599 & -0.5628 \\ -0.0645 & -0.7969 & 0.0900 & -0.5922 & -0.0441 \end{bmatrix} * \begin{bmatrix} 17.9184 & 0 & 0 \\ 0 & 15.1714 & 0 \\ 0 & 0 & 3.5640 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} * \begin{bmatrix} -0.4646 & 0.0215 & -0.8685 \\ -0.0701 & -0.7600 & 0.0631 \\ -0.7351 & 0.0988 & 0.2840 \\ -0.4844 & 0.0254 & 0.3989 \\ -0.0650 & -0.6415 & -0.0443 \end{bmatrix} \begin{matrix} 0.0008 & -0.1713 \\ -0.6013 & -0.2278 \\ -0.2235 & 0.5650 \\ 0.3327 & -0.7035 \\ 0.6912 & 0.3233 \end{matrix}^T$$

$$= \begin{bmatrix} 1.9924 & 0.1163 & 8.0715 & 5.8996 & -0.1310 \\ 1.0024 & 6.9452 & 0.3376 & 0.4946 & 5.9123 \\ 5.0489 & -0.0733 & 6.7880 & 4.2765 & 0.0668 \\ 6.9664 & -0.1163 & 8.0846 & 4.9011 & 0.1458 \\ -0.0017 & 9.2899 & -0.2539 & 0.3801 & 7.8172 \end{bmatrix} = \hat{A}$$

- A esta reconstrucción se le llama SVD [más :)] reducido (reduced - SVD)

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Existen criterios basados en la varianza para determinar cuantas dimensiones nos quedamos. Por ahora nos quedaremos con 3.
- Dado que \mathbf{U} tiene la información (ortonormal) de las palabras, si operamos las matrices reducidas (las delimitadas en los rectángulos rojos) $\mathbf{U}_r\mathbf{S}_r$ (es decir, pesamos los componentes ortogonales por su importancia dada por los valores singulares) obtenemos:

doctor	-9.7163	0.9861	2.9282
car	-1.8243	-9.0036	-0.4011
nurse (enfermera)	-9.4063	0.9009	-0.7590
hospital	-11.5550	1.0682	-1.8132
wheel (rueda)	-1.1556	-12.0905	0.3208

Otra aplicación Reducción de dimensionalidad en Datos (1)

- Por el otro lado, la matriz V tiene la información de los documentos, de tal forma que si operamos la matrices reducidas $V_r S_r$ (las delimitadas en los rectángulos rojos) obtenemos:

doc 1	-8.3252	0.3263	-3.0954
doc 2	-1.2558	-11.5301	0.2248
doc 3	-13.1717	1.4989	1.0122
doc 4	-8.6795	0.3861	1.4216
doc 5	-1.1642	-9.7327	-0.1578

- Con lo cual tenemos descriptores de dimensionalidad menor (R^3) que nos pueden servir para clasificar de manera más eficiente.

Nota General

- Nótese que dado que estamos aproximando la matriz con menos eigenvalores y vectores, en dado caso de que la matriz sea cercana a ser singular podemos eliminar todas las columnas asociadas a los valores singulares muy pequeños y tener aun así una buena aproximación de la matriz con una no singular.
- O quizá una mala representación pero que no es singular, todo depende de la aplicación.

Más aplicaciones

Solving homogeneous linear equations

A set of **homogeneous linear equations** can be written as $\mathbf{A} \mathbf{x} = \mathbf{0}$ for a matrix \mathbf{A} and vector \mathbf{x} . A typical situation is that \mathbf{A} is known and a non-zero \mathbf{x} is to be determined which satisfies the equation. Such an \mathbf{x} belongs to \mathbf{A} 's **null space** and is sometimes called a (right) null vector of \mathbf{A} . \mathbf{x} can be characterized as a right-singular vector corresponding to a singular value of \mathbf{A} that is zero. This observation means that if \mathbf{A} is a **square matrix** and has no vanishing singular value, the equation has no non-zero \mathbf{x} as a solution. It also means that if there are several vanishing singular values, any linear combination of the corresponding right-singular vectors is a valid solution.

As a consequence, the **rank** equals the number of non-zero singular values which is the same as the number of non-zero diagonal elements in Σ .

Más aplicaciones

Solving homogeneous linear equations

A set of **homogeneous linear equations** can be written as $\mathbf{A} \mathbf{x} = \mathbf{0}$ for a matrix \mathbf{A} and vector \mathbf{x} . A typical situation is that \mathbf{A} is known and a non-zero \mathbf{x} is to be determined which satisfies the equation. Such an \mathbf{x} belongs to \mathbf{A} 's **null space** and is sometimes called a (right) null vector of \mathbf{A} . \mathbf{x} can be characterized as a right-singular vector corresponding to a singular value of \mathbf{A} that is zero.

This observation means that if \mathbf{A} is a **square matrix** and has no vanishing singular value, the equation has no non-zero \mathbf{x} as a solution. It also means that if there are several vanishing singular values, any linear combination of the corresponding right-singular vectors is a valid solution.

As a consequence, the **rank** equals the number of non-zero singular values which is the same as the number of non-zero diagonal elements in Σ .

Total least squares minimization

A **total least squares** problem refers to determining the vector \mathbf{x} which minimizes the **2-norm** of a vector $\mathbf{A} \mathbf{x}$ under the constraint $\|\mathbf{x}\| = 1$. The solution turns out to be the right-singular vector of \mathbf{A} corresponding to the smallest singular value.

Más aplicaciones

Nearest orthogonal matrix

It is possible to use the SVD of A to determine the orthogonal matrix R closest to A . The closeness of fit is measured by the Frobenius norm of $R - A$. The solution is the product UV^* .^[3] This intuitively makes sense because an orthogonal matrix would have the decomposition UIV^* where I is the identity matrix, so that if $A = U\Sigma V^*$ then the product $A = UV^*$ amounts to replacing the singular values with ones.