



Universidade Federal do Rio de Janeiro
COPPE – Programa de Engenharia Química

COQ 790 – ANÁLISE DE SISTEMAS DA ENGENHARIA QUÍMICA

AULA 11:

Decomposição em valores e vetores singulares

Decomposição em Valores e Vetores Singulares (SVD)

Qualquer matriz $\mathbf{A} \in \mathfrak{R}^{m \times n}$ pode ser decomposta na forma:

$$\mathbf{A} = \mathbf{U} \cdot \Sigma \cdot \mathbf{V}^H$$

$\mathbf{U} \in \mathfrak{R}^{m \times m}$: matriz unitária formada pelos vetores característicos de $\mathbf{A} \cdot \mathbf{A}^H$

$\mathbf{V} \in \mathfrak{R}^{n \times n}$: matriz unitária formada pelos vetores característicos de $\mathbf{A}^H \cdot \mathbf{A}$

$\Sigma \in \mathfrak{R}^{m \times n}$: matriz diagonal da raiz quadrada dos valores característicos de $\mathbf{A} \cdot \mathbf{A}^H$

$$\Sigma^* = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$$

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r \geq 0 \quad r = \min(n, m)$$

$$\Sigma = \begin{bmatrix} \Sigma^* & \mathbf{0} \end{bmatrix} \quad \text{para } m < n$$

$$\Sigma = \Sigma^* \quad \text{para } n = m$$

$$\Sigma = \begin{bmatrix} \Sigma^* \\ \mathbf{0} \end{bmatrix} \quad \text{para } m > n$$

Propriedades da matriz \mathbf{A} :

$$\text{rank}(\mathbf{A}) = r$$

$$\text{null}(\mathbf{A}) = \text{span}(\mathbf{v}_{r+1}, \mathbf{v}_{r+2}, \dots, \mathbf{v}_n)$$

$$\text{range}(\mathbf{A}) = \text{span}(\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_r)$$

$$\text{range}(\mathbf{A}^H) = \text{span}(\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_r)$$

$$\mathbf{A} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \cdot \mathbf{v}_i^H$$

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^r \sigma_i^2} = \sqrt{\text{tr}(\mathbf{A} \cdot \mathbf{A}^H)} \quad (\text{norma de Frobenius})$$

$$\|\mathbf{A}\|_2 = \max_{\mathbf{x} \in \mathbb{C}^n, \mathbf{x} \neq 0} \frac{\|\mathbf{A} \cdot \mathbf{x}\|}{\|\mathbf{x}\|} = \max_{\mathbf{x} \in \mathbb{C}^n, \|\mathbf{x}\|=1} \|\mathbf{A} \cdot \mathbf{x}\| = \sigma_1$$

$$\mathbf{A} \cdot \mathbf{v}_i = \sigma_i \mathbf{u}_i$$

$$\mathbf{A}^H \cdot \mathbf{u}_i = \sigma_i \mathbf{v}_i$$

$$\mathbf{A}^\dagger = \mathbf{V} \cdot \Sigma^\dagger \cdot \mathbf{U}^H = (\mathbf{A}^H \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^H \quad (\text{pseudo-inversa de } \mathbf{A})$$

$$\mathbf{A}^\dagger \cdot \mathbf{A} \cdot \mathbf{A}^\dagger = \mathbf{A}^\dagger \quad \text{e} \quad \mathbf{A} \cdot \mathbf{A}^\dagger \cdot \mathbf{A} = \mathbf{A}$$

$$(\mathbf{A}^\dagger \cdot \mathbf{A})^H = \mathbf{A}^\dagger \cdot \mathbf{A} \quad \text{e} \quad (\mathbf{A} \cdot \mathbf{A}^\dagger)^H = \mathbf{A} \cdot \mathbf{A}^\dagger$$

Problema de valor singular para o sistema linear $\mathbf{y} = \mathbf{A} \cdot \mathbf{x}$:

$$\max_{\mathbf{x} \in \mathbb{C}^n, \|\mathbf{x}\|=1} \|\mathbf{y}\|^2 = \max_{\mathbf{x} \in \mathbb{C}^n, \|\mathbf{x}\|=1} \mathbf{y}^H \cdot \mathbf{y}$$

Usando o conceito dos multiplicadores de Lagrange:

$$\max_{\mathbf{x} \in \mathbb{C}^n, \lambda \in \mathbb{R}} \left\{ S(\mathbf{x}) = \mathbf{x}^H \cdot \mathbf{A}^H \cdot \mathbf{A} \cdot \mathbf{x} - \lambda (\mathbf{x}^H \cdot \mathbf{x} - 1) \right\}$$

$$\max_{\mathbf{x} \in \mathbb{C}^n, \lambda \in \mathbb{R}} \left\{ S(\mathbf{x}) = \mathbf{x}^H \cdot \mathbf{A}^H \cdot \mathbf{A} \cdot \mathbf{x} - \lambda (\mathbf{x}^H \cdot \mathbf{x} - 1) \right\}$$

Condição de otimalidade de primeira ordem:

$$\nabla_{\mathbf{x}} S(\mathbf{x}, \lambda) = 2(\mathbf{A}^H \cdot \mathbf{A} \cdot \mathbf{x} - \lambda \mathbf{x}) = 0$$

$$\nabla_{\lambda} S(\mathbf{x}, \lambda) = 1 - \mathbf{x}^H \cdot \mathbf{x} = 0$$

Que é equivalente a solução do problema de valor característico:


$$\mathbf{A}^H \cdot \mathbf{A} \cdot \mathbf{x} = \lambda \mathbf{x}$$

∴ ótimos locais: vetores característicos de $\mathbf{A}^H \cdot \mathbf{A}$, ou vetores singulares de \mathbf{A} ou ainda componentes principais de \mathbf{A} (direções de máxima variação de \mathbf{y} em função das variações de \mathbf{x} com a mesma energia:

$$\|\mathbf{x}\| = 1$$

e os respectivos multiplicadores de Lagrange são os valores característicos de $\mathbf{A}^H \cdot \mathbf{A}$ ou o quadrado dos valores singulares de \mathbf{A} .

Exemplo



$$F_m = F_1 + F_2$$

$$F_1 T_h + F_2 T_c = F_m T_m$$

$$\mathbf{K} = \begin{bmatrix} \frac{\partial T_m}{\partial F_1} & \frac{\partial T_m}{\partial F_2} \\ \frac{\partial F_m}{\partial F_1} & \frac{\partial F_m}{\partial F_2} \end{bmatrix}$$

Para determinar se o sistema linear, $\mathbf{y} = \mathbf{A} \cdot \mathbf{x}$, está bem escalonado deve-se verificar o condicionamento da matriz \mathbf{A} :

$$\gamma(\mathbf{A}) = \frac{\bar{\sigma}(\mathbf{A})}{\underline{\sigma}(\mathbf{A})} = \frac{\sigma_1(\mathbf{A})}{\sigma_r(\mathbf{A})}$$

Condicionamento mínimo da matriz \mathbf{A} :

$$\gamma^*(\mathbf{A}) = \min_{\mathbf{L}, \mathbf{R}} \gamma(\mathbf{L} \cdot \mathbf{A} \cdot \mathbf{R})$$

Variáveis escalonadas: $\mathbf{y}_e = \mathbf{L} \cdot \mathbf{y}$ e $\mathbf{x}_e = \mathbf{R}^{-1} \cdot \mathbf{x}$

No MATLAB, o condicionamento de uma matriz \mathbf{A} pode ser obtido através da função $cond(\mathbf{A})$, e as matrizes de escalonamento podem ser calculadas pela função:

$$[ub, \mathbf{D}] = mu(\mathbf{H}, ones(2*n, 2), 'C')$$

onde n é a ordem da matriz \mathbf{A} , $\mathbf{L} = diag(\mathbf{D}(n+1:2*n))$, $\mathbf{R} = inv(diag(\mathbf{D}(1:n)))$,

$$\mathbf{H} = \begin{bmatrix} \mathbf{0} & \mathbf{A}^{-1} \\ \mathbf{A} & \mathbf{0} \end{bmatrix}$$

$$\gamma^*(\mathbf{A}) = \left(\frac{ub(1)}{ub(2)} \right)^2 = cond(\mathbf{L} \cdot \mathbf{A} \cdot \mathbf{R})$$

Exemplo

