

7. DECOMPOSIÇÃO EM VALORES SINGULARES (SVD)

A decomposição em valores singulares é um método muito útil para a análise de sistemas multivariáveis. Em termos da operação de um processo o método SVD facilita a sua avaliação em função da:

- possibilidade de se conseguir os objetivos operacionais desejados;
- determinação dos locais mais apropriados para aumentar a sensibilidade das medidas;
- determinação das variáveis que mais vão influenciar na operação; etc.

O método utiliza a decomposição em valores singulares da matriz de ganhos estáticos do processo:

$$\mathbf{K} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T$$

Os valores singulares de uma matriz \mathbf{K} são dados pela seguinte relação:

$$\sigma = +\sqrt{\lambda(\mathbf{K}^T \mathbf{K})} \quad (\text{ou} \quad \sigma = +\sqrt{\lambda(\mathbf{K} \cdot \mathbf{K}^T)})$$

onde $\lambda(\mathbf{A})$ representa o valor característico de \mathbf{A} .

A SVD é usada em álgebra linear para minimizar erros computacionais em operações com matrizes de grande porte.

O interesse da SVD para a área de sistemas multivariáveis é fácil de se justificar. Qualquer estratégia de operação busca, basicamente, determinar a inversa da matriz de funções de transferência:

$$\mathbf{y}(s) = \mathbf{G}(s) \cdot \mathbf{m}(s)$$

Exigindo

$$\mathbf{y}(s) = \mathbf{y}^d(s)$$

resulta

$$\mathbf{m}(s) = \mathbf{G}^{-1} \mathbf{y}^d(s)$$

No estado estacionário

$$\mathbf{m} = \mathbf{K}^{-1} \mathbf{y}^d$$

Os valores singulares medem a inversibilidade da matriz; o menor valor singular é uma medida da distância que a matriz está de se transformar em singular; e a razão entre o maior e o menor valor singular mede a dificuldade de invertê-la.

Os componentes da SVD da matriz \mathbf{K} , de dimensão $n \times m$, são:

\mathbf{U} : matriz **unitária** ($\mathbf{U}^{-1} = \mathbf{U}^T$) ou **ortonormal**, $n \times n$; suas colunas são os vetores singulares à esquerda da matriz \mathbf{K} ; são os vetores característicos da matriz $\mathbf{K} \cdot \mathbf{K}^T$.

\mathbf{V} : matriz **unitária** ($\mathbf{V}^{-1} = \mathbf{V}^T$), $m \times m$; suas colunas são os vetores singulares à direita da matriz \mathbf{K} ; são os vetores característicos da matriz $\mathbf{K}^T \mathbf{K}$.

Σ : matriz $n \times m$ com a seguinte estrutura:

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

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

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

onde $\Sigma^* = \text{diag}(\sigma_i)$

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

Define-se o **número de condicionamento** como:

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

que mede o “condicionamento” da matriz. Quanto maior esse número pior será o condicionamento da matriz em questão, em termos computacionais. Para a operação de um processo associado a essa matriz, o CN mede a dificuldade para se conseguir boa operabilidade do sistema multivariável.

É possível visualizar o significado dos valores singulares da matriz de ganhos estáticos no caso de um sistema 2×2 .

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \mathbf{K}_{11} & \mathbf{K}_{12} \\ \mathbf{K}_{21} & \mathbf{K}_{22} \end{bmatrix} \cdot \begin{bmatrix} m_1 \\ m_2 \end{bmatrix} = \begin{bmatrix} \mathbf{K}_{11} \cdot m_1 + \mathbf{K}_{12} \cdot m_2 \\ \mathbf{K}_{21} \cdot m_1 + \mathbf{K}_{22} \cdot m_2 \end{bmatrix} = \begin{bmatrix} u_1^1 & u_2^1 \\ u_1^2 & u_2^2 \end{bmatrix} \cdot \begin{bmatrix} \sigma_1 & 0 \\ 0 & \sigma_2 \end{bmatrix} \cdot \begin{bmatrix} v_1^1 & v_1^2 \\ v_2^1 & v_2^2 \end{bmatrix} \cdot \begin{bmatrix} m_1 \\ m_2 \end{bmatrix}$$

Podemos expressar o vínculo estático da seguinte forma:

$$y_1 = (u_1^1 \cdot \sigma_1 \cdot v_1^1 + u_2^1 \cdot \sigma_2 \cdot v_2^1) \cdot m_1 + (u_1^1 \cdot \sigma_1 \cdot v_1^2 + u_2^1 \cdot \sigma_2 \cdot v_2^2) \cdot m_2$$

$$y_2 = (u_1^2 \cdot \sigma_1 \cdot v_1^1 + u_2^2 \cdot \sigma_2 \cdot v_2^1) \cdot m_1 + (u_1^2 \cdot \sigma_1 \cdot v_1^2 + u_2^2 \cdot \sigma_2 \cdot v_2^2) \cdot m_2$$

Observa-se que K_{ij} , o ganho estático observado, é uma combinação dos valores singulares σ_1 e σ_2 , determinada pelos elementos de \mathbf{U} e \mathbf{V} :

$$K_{ij} = \sum_{k=1}^r u_k^i \cdot v_k^j \cdot \sigma_k$$

Uma outra forma de se representar o vínculo estático é:

$$y_1 = u_1^1 \cdot \sigma_1 \cdot (v_1^1 \cdot m_1 + v_1^2 \cdot m_2) + u_2^1 \cdot \sigma_2 \cdot (v_2^1 \cdot m_1 + v_2^2 \cdot m_2)$$


$$y_2 = u_1^2 \cdot \sigma_1 \cdot (v_1^1 \cdot m_1 + v_1^2 \cdot m_2) + u_2^2 \cdot \sigma_2 \cdot (v_2^1 \cdot m_1 + v_2^2 \cdot m_2)$$

Neste caso observa-se que a saída " y_i ", no estado estacionário, está formada pela soma de termos contendo um valor singular " σ_k ". As colunas de \mathbf{U} indicam como o valor singular se distribui nas diferentes saídas. As colunas de \mathbf{V} indicam o efeito das entradas sobre cada valor singular. De um modo geral:

$$y_i = \sum_{k=1}^r u_k^i \cdot \sigma_k \cdot (v_k)^T \cdot \mathbf{m}$$

É importante ter presente que os valores singulares são ordenados de maior a menor.

Sejam as variáveis de entrada normalizadas tal que $m_1^2 + m_2^2 = 1$



Para

$$1) \mathbf{m} = \begin{bmatrix} m_1 \\ m_2 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

$$y_1 = \mathbf{u}_1^1 \cdot \boldsymbol{\sigma}_1 \cdot \mathbf{v}_1^1 + \mathbf{u}_2^1 \cdot \boldsymbol{\sigma}_2 \cdot \mathbf{v}_2^1$$

$$y_2 = \mathbf{u}_1^2 \cdot \boldsymbol{\sigma}_1 \cdot \mathbf{v}_1^1 + \mathbf{u}_2^2 \cdot \boldsymbol{\sigma}_2 \cdot \mathbf{v}_2^1$$

$$2) \mathbf{m} = \mathbf{v}_1 = \begin{bmatrix} v_1^1 \\ v_1^2 \end{bmatrix}$$

$$y_1 = \mathbf{u}_1^1 \cdot \boldsymbol{\sigma}_1$$

$$\Rightarrow \mathbf{y} = \boldsymbol{\sigma}_1 \cdot \mathbf{u}_1$$

$$y_2 = \mathbf{u}_1^2 \cdot \boldsymbol{\sigma}_1$$


$$3) \mathbf{m} = \mathbf{v}_2 = \begin{bmatrix} v_2^1 \\ v_2^2 \end{bmatrix}$$

$$y_1 = \mathbf{u}_2^1 \cdot \boldsymbol{\sigma}_2$$

$$\Rightarrow \mathbf{y} = \boldsymbol{\sigma}_2 \cdot \mathbf{u}_2$$


$$y_2 = \mathbf{u}_2^2 \cdot \boldsymbol{\sigma}_2$$

Os resultados de (2) e (3) são consequência da ortonormalidade dos vetores de \mathbf{U} e \mathbf{V} .



A entrada com a direção \mathbf{v}_1 sai na direção de \mathbf{u}_1 multiplicada por $\boldsymbol{\sigma}_1$.

Exemplo



Os dados deste sistema no estado estacionário são:

$$F1 = 10 \text{ gpm}$$

$$F2 = 20 \text{ gpm}$$

$$Th = 100 \text{ }^\circ\text{F}$$

$$Tc = 65 \text{ }^\circ\text{F}$$

Para calcular a matriz de ganhos estáticos

$$\mathbf{K} = \begin{bmatrix} \frac{\partial T_m}{\partial F1} & \frac{\partial T_m}{\partial F2} \\ \frac{\partial F_m}{\partial F1} & \frac{\partial F_m}{\partial F2} \end{bmatrix}$$

são estabelecidos os balanços globais de massa e energia no estado estacionário.

$$F_m = F1 + F2$$

$$F1 Th + F2 Tc = F_m T_m$$

Então



$$\begin{aligned} \frac{\partial T_m}{\partial F1} &= \frac{\partial}{\partial F1} \left[\frac{F1 \cdot Th + F2 \cdot Tc}{F1 + F2} \right] = \frac{Th \cdot (F1 + F2) - F1 \cdot Th - F2 \cdot Tc}{(F1 + F2)^2} \\ &= \frac{F2(Th - Tc)}{(F1 + F2)^2} = \frac{20(100 - 65)}{(10 + 20)^2} = 0,7778 \end{aligned}$$

Seguindo o mesmo procedimento chega-se a

$$\mathbf{K} = \begin{bmatrix} 0,7778 & -0,3889 \\ 1 & 1 \end{bmatrix} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T =$$

$$= \begin{bmatrix} 0,2758 & -0,9612 \\ 0,9612 & 0,2758 \end{bmatrix} \cdot \begin{bmatrix} 1,4531 & 0 \\ 0 & 0,8029 \end{bmatrix} \cdot \begin{bmatrix} 0,8091 & 0,5877 \\ -0,5877 & 0,8091 \end{bmatrix}$$

CN=1,7



Interpretação física dos elementos na decomposição em valores singulares

K: é matriz de ganhos estáticos do processo

$$K_{ij} = \left. \frac{\partial y_i}{\partial m_j} \right|_{m_k}$$

Os elementos desta matriz refletem a sensibilidade da variável de saída a uma variação na variável de entrada. Os ganhos estáticos dependem das unidades utilizadas.

U: é uma matriz cujas colunas, \mathbf{u}^i , são os vetores singulares à esquerda da matriz **K**.

\mathbf{u}_1 : indica a direção em que as variáveis de saída mudam mais, frente a variações nas variáveis de entrada.

$\mathbf{u}_2, \mathbf{u}_3, \dots, \mathbf{u}_n$: indicam, nessa ordem, direções cada vez menos sensíveis.

\mathbf{V} : é uma matriz cujas colunas, \mathbf{v}_i , são os vetores singulares à direita da matriz \mathbf{K} .

\mathbf{v}_1 : indica a combinação de variáveis de entrada cuja variação afeta as saídas de forma mais significativa.

$\mathbf{\Sigma}$: é uma matriz diagonal cujos elementos, os valores singulares, fornecem os ganhos estáticos do sistema "desacoplado" (em termos de variáveis estruturadas).

$$\mathbf{y} = \mathbf{K} \cdot \mathbf{u}$$

$$\mathbf{y} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T \cdot \mathbf{u}$$

$$\mathbf{U}^T \cdot \mathbf{y} = \mathbf{U}^T \cdot \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T \cdot \mathbf{u} = \mathbf{\Sigma} \cdot \mathbf{V}^T \cdot \mathbf{u}$$

$$\mathbf{y}' = \mathbf{\Sigma} \cdot \mathbf{u}'$$

$CN = \gamma = \frac{\sigma_1}{\sigma_r}$: é o número de condicionamento; mede o grau de dificuldade para se

operar o sistema multivariável; CN grande indica que há direções de variação muito altas e muito baixas; dependendo da qualidade da instrumentação utilizada deverá se abrir mão de certos objetivos; há menos graus de liberdade para resolver problemas operacionais; não podem ser satisfeitos simultaneamente todos os objetivos almejados.

Exemplo

Se no exemplo anterior forem mudadas as condições de estado estacionário:

$$F1 = 100 \text{ gpm}$$

$$F2 = 150 \text{ gpm}$$

$$Th = 100 \text{ }^\circ\text{F}$$

$$Tc = 65 \text{ }^\circ\text{F}$$

resulta

$$\mathbf{K} = \begin{bmatrix} 0,084 & -0,056 \\ 1,000 & 1,000 \end{bmatrix}$$

Os valores singulares são $\sigma_1 = 1,414$ e $\sigma_2 = 0,0990$, gerando um número de condicionamento:

$$CN = 14,28$$

O sistema responde 14 vezes mais na direção mais forte. Apesar de haver dois graus de liberdade, um deles é pouco útil.

Apêndice (Notas do Nivelamento)

Transformação linear: Sejam U e V espaços vetoriais sobre \mathfrak{R} . Uma aplicação $F: U \rightarrow V$ é chamada transformação linear de U em V se, e somente se,

$$(a) F(u_1 + u_2) = F(u_1) + F(u_2), \forall u_1, u_2 \in U, \text{ e}$$

$$(b) F(\alpha u) = \alpha F(u), \forall \alpha \in \mathfrak{R} \text{ e } \forall u \in U.$$

No caso em que $U = V$, uma transformação linear $F: U \rightarrow U$ é chamada também de **operador linear**.

Exemplo: Para verificar se a aplicação $F: \mathfrak{R}^3 \rightarrow \mathfrak{R}^2$ definida por $F(x, y, z) = (x, 2x - z)$, $\forall (x, y, z) \in \mathfrak{R}^3$, é uma transformação linear, sejam $\mathbf{u}_1 = (x_1, y_1, z_1)$ e $\mathbf{u}_2 = (x_2, y_2, z_2)$ em \mathfrak{R}^3 e:

$$(a) F(\mathbf{u}_1 + \mathbf{u}_2) = F(x_1 + x_2, y_1 + y_2, z_1 + z_2) = (x_1 + x_2, 2x_1 + 2x_2 - z_1 - z_2) = (x_1, 2x_1 - z_1) + (x_2, 2x_2 - z_2) = F(\mathbf{u}_1) + F(\mathbf{u}_2)$$

$$(b) F(\alpha \mathbf{u}_1) = F(\alpha x_1, \alpha y_1, \alpha z_1) = (\alpha x_1, 2\alpha x_1 - \alpha z_1) = \alpha (x_1, 2x_1 - z_1) = \alpha F(\mathbf{u}_1), \forall \alpha \in \mathfrak{R}.$$

logo, a aplicação é uma transformação linear.

Verifica-se prontamente que a multiplicação de uma matriz $\mathbf{A} \in \mathfrak{R}^{m \times n}$ por um vetor $\mathbf{x} \in \mathfrak{R}^n$ é uma transformação linear, pois $\mathbf{A} \cdot (\mathbf{x}_1 + \mathbf{x}_2) = \mathbf{A} \cdot \mathbf{x}_1 + \mathbf{A} \cdot \mathbf{x}_2$ e $\mathbf{A} \cdot \alpha \mathbf{x} = \alpha \mathbf{A} \cdot \mathbf{x}$.

Núcleo ou espaço nulo: Sejam U e V espaços vetoriais sobre \mathfrak{R} e $F: U \rightarrow V$ uma transformação linear. Indica-se por $\text{Ker}(F)$ ou $\text{null}(F)$ e denomina-se núcleo ou espaço nulo de F o seguinte subconjunto de U :

$$\text{Ker}(F) = \text{null}(F) = \{u \in U \mid F(u) = 0\} \subseteq U$$

Exemplo: Seja $F: \mathfrak{R}^2 \rightarrow \mathfrak{R}^3$ a transformação linear dada por $F(x, y) = (0, x + y, 0)$, $\forall (x, y) \in \mathfrak{R}^2$, o núcleo de F é obtido fazendo $F(x, y) = (0, 0, 0) = (0, x + y, 0)$. Logo, $x = -y$ e $\text{Ker}(F) = \{(x, -x) \mid x \in \mathfrak{R}\}$, como ilustra a figura abaixo:




Figura 1: Núcleo de uma transformação linear

O espaço nulo de uma matriz $\mathbf{A} \in \mathfrak{R}^{m \times n}$ é o subespaço $\text{Ker}(\mathbf{A}) = \text{null}(\mathbf{A}) = \{\mathbf{x} \in \mathfrak{R}^n \mid \mathbf{A} \cdot \mathbf{x} = \mathbf{0}\} \subseteq \mathfrak{R}^n$, ou seja, é o conjunto de todas as soluções do sistema homogêneo $\mathbf{A} \cdot \mathbf{x} = \mathbf{0}$. No caso de uma matriz regular (invertível), $\text{Ker}(\mathbf{A}) = \{\mathbf{0}\}$.

Imagem ou espaço gerado: Sejam U e V espaços vetoriais sobre \mathfrak{R} e $F: U \rightarrow V$ uma transformação linear. Indica-se por $\text{Im}(F)$ ou $\text{range}(F)$ e denomina-se imagem ou espaço gerado de F o seguinte subconjunto de V :

$$\text{Im}(F) = \text{range}(F) = \{F(u) \mid u \in U\} \subseteq V$$

A imagem ou espaço gerado por uma matriz $\mathbf{A} \in \mathfrak{R}^{m \times n}$ é o subespaço $\text{Im}(\mathbf{A}) \subseteq \mathfrak{R}^m$ gerado pela transformação linear $F(\mathbf{x}) = \mathbf{A} \cdot \mathbf{x}$, isto é,

$$\text{Im}(\mathbf{A}) = \text{range}(\mathbf{A}) = \{\mathbf{A} \cdot \mathbf{x} \mid \mathbf{x} \in \mathfrak{R}^n\} \subseteq \mathfrak{R}^m$$

Da mesma forma, a imagem ou espaço gerado pela transposta de uma matriz $\mathbf{A} \in \mathfrak{R}^{m \times n}$ é o subespaço $\text{Im}(\mathbf{A}^T) \subseteq \mathfrak{R}^n$ gerado pela transformação linear $F(\mathbf{y}) = \mathbf{A}^T \cdot \mathbf{y}$, isto é,

$$\text{Im}(\mathbf{A}^T) = \text{range}(\mathbf{A}^T) = \{\mathbf{A}^T \cdot \mathbf{y} \mid \mathbf{y} \in \mathfrak{R}^m\} \subseteq \mathfrak{R}^n$$

Um resultado importante é sobre a dimensão destes subespaços. Sejam U e V espaços vetoriais de dimensão finita sobre \mathfrak{R} . Dada uma transformação linear $F: U \rightarrow V$, então

$$\dim U = \dim \text{Ker}(F) + \dim \text{Im}(F)$$

Conjunto gerador: para um conjunto de vetores $S = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_r\}$ o subespaço:

$$\text{span}(S) = \alpha_1 \mathbf{v}_1 + \alpha_2 \mathbf{v}_2 + \dots + \alpha_r \mathbf{v}_r$$

gerado por todas as combinações lineares dos vetores de S é chamado espaço gerado por S , denominado conjunto gerador.

Com o uso deste conceito, pode-se dizer que $\text{range}(\mathbf{A})$ é o espaço gerado pelos vetores coluna de \mathbf{A} e $\text{range}(\mathbf{A}^T)$ é o espaço gerado pelos vetores linha de \mathbf{A} .

Posto ou rank: o posto ou rank de uma matriz $\mathbf{A} \in \mathfrak{R}^{m \times n}$ é o número máximo de linhas ou colunas linearmente independentes. Observe que $\dim \text{Im}(\mathbf{A}) = \text{rank}(\mathbf{A})$ e, portanto, se $\text{Ker}(\mathbf{A}) = \{\mathbf{0}\}$, então $\text{rank}(\mathbf{A}) = n$, pois $\dim \mathfrak{R}^n = n = \dim \text{Ker}(\mathbf{A}) + \dim \text{Im}(\mathbf{A})$. Da mesma forma, se $\text{Ker}(\mathbf{A}^T) = \{\mathbf{0}\}$, então $\text{rank}(\mathbf{A}) = m$.

Matriz simétrica: $\mathbf{A} = \mathbf{A}^T$

Matriz hermitiana (ou auto-adjunta): $\mathbf{A} = \mathbf{A}^H$, ou seja, matriz complexa igual a sua transposta conjugada ($a_{ij} = \bar{a}_{ji}$).

Exemplo de matriz hermitiana: $A = \begin{bmatrix} 1 & 3+i \\ 3-i & 4 \end{bmatrix}$

Matriz ortogonal (Q): $\mathbf{Q}^{-1} = \mathbf{Q}^T$

Matriz unitária (U): $\mathbf{U}^{-1} = \mathbf{U}^H$

As matrizes hermitiana e unitária em \mathbb{C} (campo complexo) estão, respectivamente, para as matrizes simétrica e ortogonal em \mathbb{R} . Por isso, as descrições a seguir serão limitadas ao campo dos números reais, podendo ser estendidas para \mathbb{C} substituindo as matrizes ortogonais por matrizes unitárias e as matrizes simétricas por matrizes hermitianas.

Dada uma matriz $\mathbf{A} \in \mathbb{R}^{m \times n}$ e lembrando dos conceitos básicos que o $\text{range}(\mathbf{A})$ é o espaço gerado pelos vetores coluna de \mathbf{A} e $\text{range}(\mathbf{A}^T)$ é o espaço gerado pelos vetores linha de \mathbf{A} , a decomposição SVD é capaz de obter simultaneamente as bases ortonormais destes subespaços.

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

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

onde $\mathbf{U} \in \mathbb{R}^{m \times m}$ é uma matriz ortogonal cujas colunas são os vetores característicos de $\mathbf{A} \cdot \mathbf{A}^T$, $\mathbf{V} \in \mathbb{R}^{n \times n}$ é uma matriz ortogonal cujas colunas são os vetores característicos de $\mathbf{A}^T \cdot \mathbf{A}$, $\mathbf{\Sigma} \in \mathbb{R}^{m \times n}$ é uma matriz diagonal contendo a raiz quadrada dos valores característicos de $\mathbf{A} \cdot \mathbf{A}^T$ (que são equivalentes aos valores característicos de $\mathbf{A}^T \cdot \mathbf{A}$), arranjados em ordem decrescente. Os vetores característicos de $\mathbf{A} \cdot \mathbf{A}^T$ e $\mathbf{A}^T \cdot \mathbf{A}$ estão arranjados nas colunas de \mathbf{U} e \mathbf{V} , respectivamente, na ordem de seus valores característicos na matriz $\mathbf{\Sigma}$. Os elementos, σ_i , da diagonal de $\mathbf{\Sigma}$ são denominados de valores singulares de \mathbf{A} , sendo todos não-negativos. Além disso, o número de valores singulares positivos é igual ao $\text{rank}(\mathbf{A})$. Os vetores coluna de \mathbf{U} são denominados de vetores singulares à esquerda de \mathbf{A} e os vetores coluna de \mathbf{V} são denominados de vetores singulares à direita de \mathbf{A} , e as relações entre estes vetores são:

$$\mathbf{A} \cdot \mathbf{v}_i = \sigma_i \mathbf{u}_i \quad \text{e} \quad \mathbf{A}^T \cdot \mathbf{u}_i = \sigma_i \mathbf{v}_i$$

A decomposição SVD revela várias propriedades intrínsecas da matriz \mathbf{A} e é numericamente estável para os cálculos. Algumas propriedades são listadas abaixo para uma matriz com r valores singulares positivos:

- 1) $\text{rank}(\mathbf{A}) = r$
- 2) $\text{null}(\mathbf{A}) = \text{span}(\mathbf{v}_{r+1}, \mathbf{v}_{r+2}, \dots, \mathbf{v}_n)$
- 3) $\text{range}(\mathbf{A}) = \text{span}(\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_r)$

$$4) \text{range}(\mathbf{A}^T) = \text{span}(\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_r)$$

$$5) \mathbf{A} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \cdot \mathbf{v}_i^T$$

$$6) \|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^r \sigma_i^2} \text{ (norma de Frobenius)}$$

$$7) \|\mathbf{A}\|_2 = \sigma_1$$

A matriz:

$$\mathbf{A}^\dagger = \mathbf{V} \cdot \mathbf{\Sigma}^\dagger \cdot \mathbf{U}^T = (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T$$

é chamada de pseudo-inversa de \mathbf{A} , onde os elementos da diagonal de $\mathbf{\Sigma}^\dagger$ consistem no recíproco dos valores singulares positivos de $\mathbf{\Sigma}$, na mesma ordem. A pseudo-inversa tem a propriedade $\mathbf{A}^\dagger \cdot \mathbf{A} = \mathbf{A} \cdot \mathbf{A}^\dagger = \mathbf{I}$.

A solução do problema de valores singulares para o sistema linear, $\mathbf{y} = \mathbf{A} \cdot \mathbf{x}$, corresponde resolver o seguinte problema de otimização:

$$\begin{aligned} & \max_{\mathbf{x}} \|\mathbf{y}\|_2^2 \\ & \text{sujeito a } \|\mathbf{x}\|_2^2 = 1 \end{aligned}$$

onde $\|\mathbf{y}\|_2^2 = \mathbf{y}^T \cdot \mathbf{y}$. Usando o conceito dos multiplicadores de Lagrange, o problema acima pode ser reescrito como:

$$\max_{\mathbf{x}, \lambda} \left\{ S(\mathbf{x}) = \mathbf{x}^T \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{x} - \lambda (\mathbf{x}^T \cdot \mathbf{x} - 1) \right\}$$

cuja primeira condição de otimalidade é $\nabla S(\mathbf{x}, \lambda) = 2(\mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{x} - \lambda \mathbf{x}) = 0$ e $\|\mathbf{x}\|_2 = 1$, ou seja, a solução é equivalente ao problema de valor característico $\mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{x} = \lambda \mathbf{x}$, cujos \mathbf{x} ótimos locais correspondem aos vetores característicos de $\mathbf{A}^T \cdot \mathbf{A}$ ou os vetores singulares de \mathbf{A} (também chamados de **componentes principais** de variação, pois indicam as direções de máxima variação de \mathbf{y} em função das variações em \mathbf{x} com mesma energia, isto é, $\|\mathbf{x}\|_2 = 1$) e os respectivos multiplicadores de Lagrange são os valores característicos de $\mathbf{A}^T \cdot \mathbf{A}$ ou o quadrado dos valores singulares de \mathbf{A} . A matriz Hessiana em relação a \mathbf{x} deste problema de otimização, $H(\mathbf{x}, \lambda) = 2(\mathbf{A}^T \cdot \mathbf{A} - \lambda \mathbf{I})$, é negativa semi-definida (máximo) para o maior valor singular e positiva semi-definida (mínimo) para o menor valor singular, sendo indefinida para os demais valores intermediários.

Observe que para uma matriz de $\text{rank}(\mathbf{A}) = r$, $\mathbf{A} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T = \sum_{i=1}^r \sigma_i \mathbf{u}_i \cdot \mathbf{v}_i^T$ e,

portanto, $\mathbf{y} = \mathbf{A} \cdot \mathbf{x} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T \cdot \mathbf{x} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \cdot \mathbf{v}_i^T \cdot \mathbf{x}$, indicando que a projeção do vetor \mathbf{x}

na direção do vetor \mathbf{v}_i (ou seja, $\mathbf{v}_i^T \cdot \mathbf{x}$) é amplificada por σ_i na direção \mathbf{u}_i do vetor \mathbf{y} , sendo $i = 1$ a direção de maior amplificação e $i = r$ a direção de menor amplificação. Dependendo do valor de σ_i , uma pequena mudança em \mathbf{x} pode causar uma grande mudança em \mathbf{y} , mas isto vai depender do ângulo entre os vetores \mathbf{x} e \mathbf{v}_i .

Exemplo: usando a função demonstrativa **eigshow(A)** do MATLAB, que apresenta de forma gráfica um vetor unitário \mathbf{x} e sua transformação linear $\mathbf{A}\cdot\mathbf{x}$ para uma matriz de dimensão 2×2 e valores de \mathbf{x} , com $\|\mathbf{x}\| = 1$, é possível pela movimentação do mouse sobre a figura localizar as direções características da matriz. As Figuras 2a, 2b e 2c ilustram esta movimentação para a matriz

$$\mathbf{A} = \begin{bmatrix} 1/4 & 3/4 \\ 1 & 1/2 \end{bmatrix}$$

onde os valores característicos, λ , e os vetores característicos, \mathbf{x} , resultantes das soluções não-triviais do sistema de equações lineares

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

$$\lambda_1 = 5/4 \quad \text{e} \quad \mathbf{x}_1 = [3/5 \quad 4/5]^T \quad ; \quad \lambda_2 = -1/2 \quad \text{e} \quad \mathbf{x}_2 = [\sqrt{2}/2 \quad -\sqrt{2}/2]^T$$

são visualizados quando os dois vetores (\mathbf{x} e $\mathbf{A}\cdot\mathbf{x}$) estão na mesma direção (Figuras 2b e 2c). Mostrando que o operador \mathbf{A} , na direção de \mathbf{x} , corresponde a uma redução ou ampliação por um fator λ . Quando os sentidos dos dois vetores são opostos tem-se um valor característico negativo.

Pode-se observar que os dois vetores característicos não são os eixos maior e menor da elipse formada pelas transformações lineares. Seriam para o caso particular de matrizes simétricas. Matrizes 2×2 com um par de valores característicos complexo não possuem vetores característicos reais.

Movendo dois vetores unitários, \mathbf{x} e \mathbf{y} , perpendiculares e suas correspondentes transformações lineares, $\mathbf{A}\cdot\mathbf{x}$ e $\mathbf{A}\cdot\mathbf{y}$, pode-se visualizar os valores e vetores singulares, resultantes das soluções não-triviais dos sistemas de equações lineares

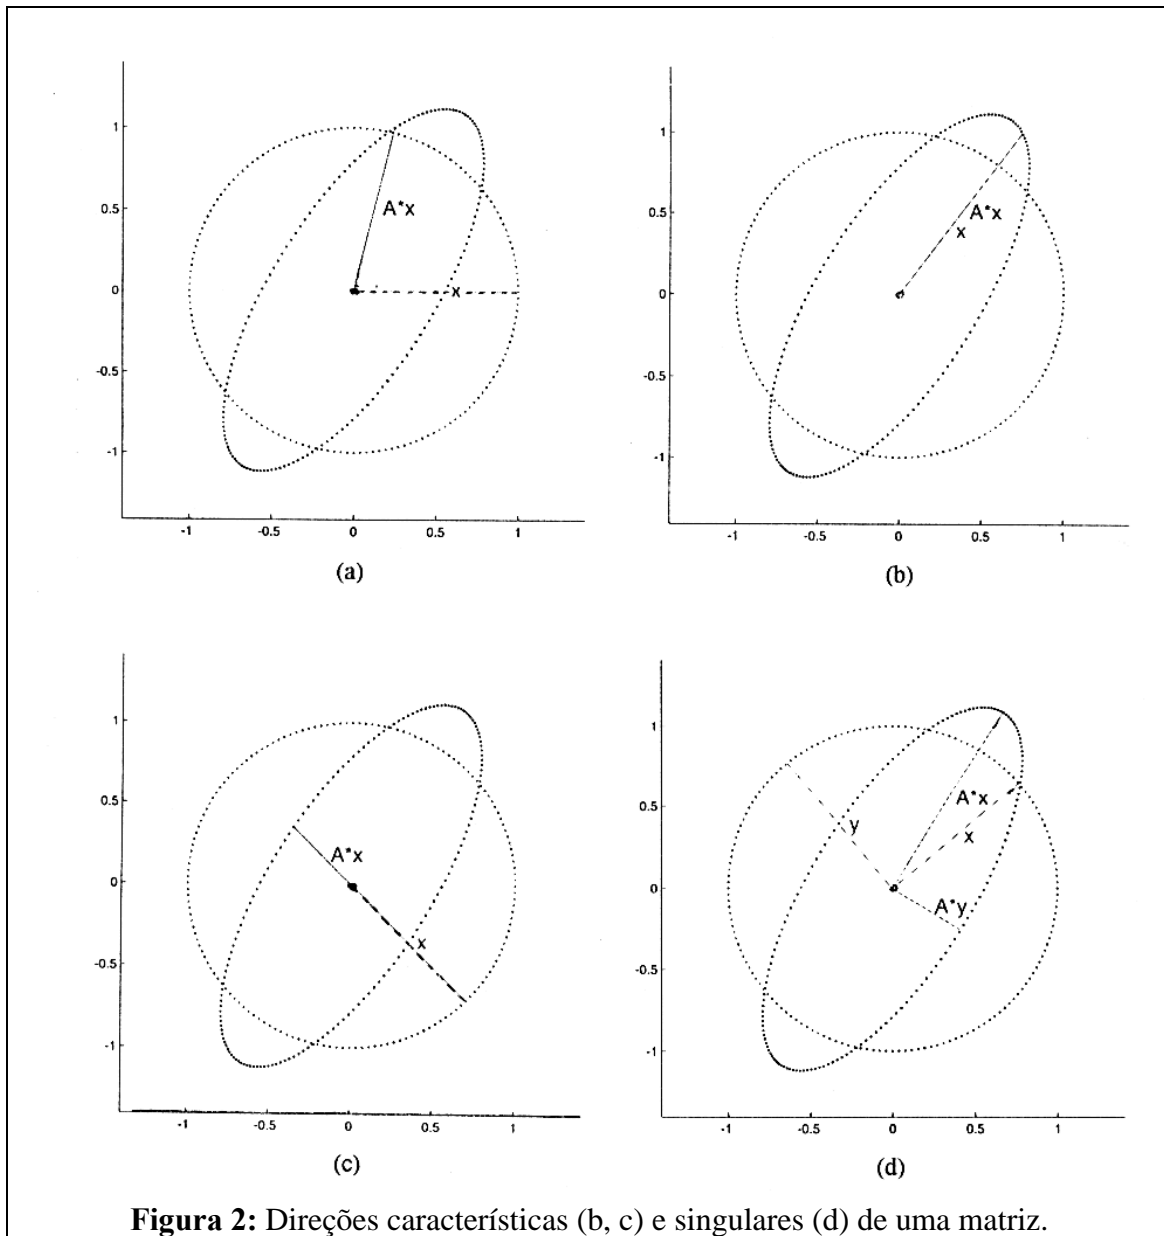
$$\mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{v} = \sigma^2 \mathbf{v}$$

$$\mathbf{A} \cdot \mathbf{A}^T \cdot \mathbf{u} = \sigma^2 \mathbf{u}$$

$$\sigma_1 = 1,2792, \quad \mathbf{x} = \mathbf{v}_1 = [0,7678 \quad 0,6407]^T \quad \text{e} \quad \mathbf{A}\cdot\mathbf{x} = \sigma_1 \mathbf{u}_1 = [0,6725 \quad 1,0881]^T$$

$$\sigma_2 = 0,4886, \quad \mathbf{y} = \mathbf{v}_2 = [-0,6407 \quad 0,7678]^T \quad \text{e} \quad \mathbf{A}\cdot\mathbf{y} = \sigma_2 \mathbf{u}_2 = [0,4156 \quad -0,2569]^T$$

onde σ são os valores singulares, \mathbf{v} e \mathbf{u} são os vetores singulares à direita e à esquerda, respectivamente. Eles surgem no momento em que as transformações são perpendiculares entre si, conforme mostra a Figura 2d. Observa-se que isto acontece quando os vetores das transformações são os eixos maior e menor da elipse, mostrando, por exemplo, as direções de máxima e mínima amplificação de sinais, respectivamente. Para o caso particular de uma matriz quadrada, simétrica e positiva definida, as decomposições em valores característicos e em valores singulares são equivalentes.



Para determinar se o sistema linear, $y = A \cdot x$, está bem escalonado deve-se verificar o condicionamento da matriz A , que na norma 2 é dado por:

$$\gamma(A) = \bar{\sigma}(A) / \underline{\sigma}(A)$$

onde $\bar{\sigma}(A)$ é o maior valor singular de A e $\underline{\sigma}(A)$ é o menor valor singular não-nulo de A .

A melhor maneira de escalonar um sistema é atacando a origem do problema, ou seja, um apropriado adimensionamento das variáveis dependentes e das equações do problema. Uma maneira de determinar quais as variáveis devem ser re-escalonadas é através do cálculo do condicionamento mínimo, isto é, determinar as matrizes que pré- e pós-multiplicadas pela matriz A resultam em um γ mínimo (γ^*), isto é:

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

Considerando \mathbf{L} e \mathbf{R} matrizes diagonais, tem-se como resultado do problema de otimização acima quais as saídas e entradas que devem ser re-escaloadas, respectivamente, pois:

$$\mathbf{y}_e = \mathbf{L} \cdot \mathbf{y} \quad \text{e} \quad \mathbf{x}_e = \mathbf{R}^{-1} \cdot \mathbf{x}$$

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

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

onde n é a ordem da matriz \mathbf{A} , $\mathbf{H} = \begin{bmatrix} 0 & \mathbf{A}^{-1} \\ \mathbf{A} & 0 \end{bmatrix}$, $\gamma^*(\mathbf{A}) = \left(\frac{ub(1)}{ub(2)} \right)^2$,

$\mathbf{L} = \text{diag}(\mathbf{D}(n+1:2*n))$ e $\mathbf{R} = \text{inv}(\text{diag}(\mathbf{D}(1:n)))$. Para verificar se os cálculos estão corretos, basta calcular o $\text{cond}(\mathbf{L}*\mathbf{A}*\mathbf{R})$, que deve ser igual a $\gamma^*(\mathbf{A})$.