

⑥ Determinação numérica de auto-valores

①

* Autovalores e autovetores:

$$A \vec{n} = \lambda \vec{n} \quad \begin{cases} \vec{n} \rightarrow \text{autovetores} \\ \lambda \rightarrow \text{autovalores} \end{cases}$$

$$\underbrace{(A - \lambda I) \vec{n} = \vec{0}} \longrightarrow \text{se } \vec{n} \neq \vec{0}, \quad \underbrace{\det(A - \lambda I) = 0}$$

② para cada λ , acha \vec{n} .

③ resolve e acha λ 's
(polinômios característicos)

ex) $A = \begin{bmatrix} 8 & 3 \\ 2 & 7 \end{bmatrix} \quad \det(A - \lambda I) = \begin{vmatrix} 8-\lambda & 3 \\ 2 & 7-\lambda \end{vmatrix} = 0$

$$(8-\lambda)(7-\lambda) - 6 = 0$$

$$\lambda^2 - 7\lambda - 8\lambda + 56 - 6 = 0$$

$$\lambda^2 - 15\lambda + 50 = 0 \quad \begin{cases} \lambda_1 = 10 \\ \lambda_2 = 5 \end{cases}$$

$$\lambda_1 = 10: \quad \begin{bmatrix} 8-10 & 3 \\ 2 & 7-10 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad \begin{bmatrix} -2 & 3 \\ 2 & -3 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$-2x_1 + 3x_2 = 0, \quad x_1 = \alpha, \quad x_2 = \frac{2}{3}\alpha, \quad \vec{n} = \alpha \begin{bmatrix} 1 \\ 2/3 \end{bmatrix}$$

$$\lambda_2 = 5: \quad \begin{bmatrix} 8-5 & 3 \\ 2 & 7-5 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad \begin{bmatrix} 3 & 3 \\ 2 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$3x_1 + 3x_2 = 0, \quad x_1 = \beta, \quad x_2 = -\beta, \quad \vec{n} = \beta \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

obs: $\text{traco}(A) = \sum_{i=1}^m \lambda_i(A)$, $A_{m \times m}$

$A_{m \times m}$ possui m autovalores (complexos, repetidos)

$\det(A) = \prod_{i=1}^m \lambda_i(A) \rightarrow A \text{ singular} \leftrightarrow \lambda_i = 0$

se $\lambda_i = \lambda_j$, \vec{n}_i e \vec{n}_j são L.I.

* se A é diagonal ou triangular (sup. ou inf.), os autovalores são os elementos da diagonal.

* Base de um espaço vetorial:

interp. 1)

$A \vec{n} = \vec{b}$


$$\begin{bmatrix} \vec{a}_1 & \vec{a}_2 & \dots & \vec{a}_m \end{bmatrix} \begin{bmatrix} n_1 \\ n_2 \\ \vdots \\ n_m \end{bmatrix} = \vec{b}$$

$\vec{b} = \vec{a}_1 n_1 + \vec{a}_2 n_2 + \dots + \vec{a}_m n_m$


$\vec{b} = I \vec{b} = \hat{e}_1 b_1 + \hat{e}_2 b_2 + \dots + \hat{e}_m b_m$

$$\begin{bmatrix} \hat{e}_1 & \hat{e}_2 & \dots & \hat{e}_m \\ 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix} = \vec{b}$$

$\underbrace{\hspace{10em}}_I \quad \underbrace{\hspace{2em}}_{\vec{b}}$



$\vec{b} \rightarrow$ coeficientes da base canônica
 $\vec{n} \rightarrow$ coeficientes da base A



similamente: $\vec{x} = P [\vec{x}]_P$

- $P_{m \times n}$ não-singular: matriz mudança de base
- $[\vec{x}]_P \rightarrow$ vetor \vec{x} na base P .
- vetores colunas de $P \rightarrow \vec{p}_1, \vec{p}_2, \dots, \vec{p}_m \rightarrow$ base.

$$[\vec{x}]_P = P^{-1} \vec{x}$$

interp. 2)

$$A \vec{x} = \vec{b}$$

A é matriz que representa uma transformação linear

- rotação: 
- reflexão: 
- cisalhamento: 
- estiramento/ contração: 

\rightarrow transf. lineares preservam a origem, o paralelismo e a colinearidade (retas permanecem)

\rightarrow os vetores que sofrem apenas reflexão e/ou estiramento/contração (permanecem na mesma "linha" após a transformação) são os autovetores de A . (reflexão: autovalor -1 , estiramento/contração autovalor $\neq 0$ e a taxa).

mesma transf. em outra base

$$\left\{ \begin{array}{l} B [\vec{x}]_P = [\vec{b}]_P \qquad \underbrace{B P^{-1} \vec{x}}_{[\vec{x}]_P} = \underbrace{P^{-1} \vec{b}}_{[\vec{b}]_P} \\ \underbrace{P B P^{-1}}_A \vec{x} = \vec{b} \end{array} \right.$$

A na base P .

$$\begin{array}{ccc}
 \vec{x} & \xleftarrow{A} & = \vec{b} \\
 P^{-1} \uparrow & & \downarrow P \\
 [\vec{x}]_P & \xleftarrow{B} & = [\vec{b}]_B
 \end{array}$$

$$A = P B P^{-1}$$

- Se $A = P B P^{-1}$, dizemos que B é semelhante à A .
- B e A representam a mesma transformação em bases diferentes.
- A e B possuem os mesmos autovalores

$$\begin{aligned}
 \det(A - \lambda I) &= \det(P B P^{-1} - \lambda I) = \det(P B P^{-1} - \lambda I P P^{-1}) \\
 &= \det(P B P^{-1} - P \lambda I P^{-1}) = \det(P (B - \lambda I) P^{-1}) = \\
 &= \det(P) \det(B - \lambda I) \det(P^{-1}) = \cancel{\det(P)} \det(B - \lambda I) \frac{1}{\cancel{\det(P)}} = \\
 &= \det(B - \lambda I) \rightarrow \text{mesma eq. característica.}
 \end{aligned}$$

- A e B possuem o mesmo determinante:

$$\begin{aligned}
 \det(A) &= \det(P B P^{-1}) = \det(P) \det(B) \det(P^{-1}) \\
 &= \cancel{\det(P)} \det(B) \frac{1}{\cancel{\det(P)}} = \det(B)
 \end{aligned}$$

- autovalor e determinante são propriedades da transf. linear independente da base utilizada.

• autovetores:

$$\begin{aligned}
 P^{-1} A \vec{x} &= P^{-1} \lambda \vec{x} & P^{-1} A P P^{-1} \vec{x} &= \lambda P^{-1} \vec{x} \\
 (P^{-1} A P) P^{-1} \vec{x} &= \lambda (P^{-1} \vec{x}) & B (P^{-1} \vec{x}) &= \lambda (P^{-1} \vec{x}) \\
 B [\vec{x}]_P &= \lambda [\vec{x}]_P
 \end{aligned}$$

* Decomposições de Schur:

• Teorema: toda matriz $A_{m \times m}$ é similar a uma matriz triangular superior. Além disso, a matriz mudança de base P pode ser escolhida como uma matriz ortogonal (unitária no caso complexo), cujos vetores coluna formam uma base ortonormal.

• matriz ortogonal: $Q = [\vec{q}_1 \ \vec{q}_2 \ \dots \ \vec{q}_m]$

$$\vec{q}_i^T \vec{q}_j = \begin{cases} 0, & \text{se } i \neq j \\ 1, & \text{se } i = j \end{cases}$$

$$\begin{cases} \text{se } Q \in \mathbb{R}^{m \times m}: & Q^T Q = Q Q^T = I, \quad Q^{-1} = Q^T \\ \text{se } Q \in \mathbb{C}^{m \times m}: & Q^H Q = Q Q^H = I, \quad Q^{-1} = Q^H \end{cases}$$

↳ hermitiano transposto

↳ matriz unitária

• $A = Q T Q^T$ ou $A = Q T Q^H$

• a decomposição de Schur não é única.

• se A é matriz normal (simétrica, anti-simétrica, unitária...)

$$A = Q \Lambda Q^T$$

onde Λ é matriz diagonal. Dizemos que A é diagonalizável.

• A é diagonalizável se e somente se A possui n autovetores L.I.

* Cálculo numérico de autovetores: Quateroni: 6.5 ⑥
 Franco: 7.7

⇒ transformar A em T (triangular ou diagonal), autovalores "aparecerão" na diagonal principal.

⇒ Para $A \in \mathbb{R}^{m \times m}$ não-singular: decomposição QR.

⇒ Decomposição QR: Quateroni: 5.7

$$A = QR \quad \left\{ \begin{array}{l} Q \rightarrow \text{ortogonal (vetores coluna ortogonais)} \\ R \rightarrow \text{triangular superior.} \end{array} \right.$$

• método de Gram-Schmidt:

$$A = [\vec{a}_1 \quad \vec{a}_2 \quad \dots \quad \vec{a}_m] \quad Q = [\underbrace{\vec{q}_1 \quad \vec{q}_2 \quad \dots \quad \vec{q}_m}_{\text{ortogonais}}]$$

mesmo espaço vetorial

① $\vec{q}_1 = \frac{\vec{a}_1}{\|\vec{a}_1\|} r_{11}$

② $\vec{n}_2 = \vec{a}_2 - \underbrace{(\vec{q}_1^T \vec{a}_2)}_{r_{12}} \vec{q}_1$

$\vec{q}_2 = \frac{\vec{n}_2}{\|\vec{n}_2\|} r_{22}$



③ $\vec{n}_3 = \vec{a}_3 - \underbrace{(\vec{q}_1^T \vec{a}_3)}_{r_{13}} \vec{q}_1 - \underbrace{(\vec{q}_2^T \vec{a}_3)}_{r_{23}} \vec{q}_2$

$\vec{q}_3 = \frac{\vec{n}_3}{\|\vec{n}_3\|} r_{33}$

⋮

④ $\vec{n}_m = \vec{a}_m - \underbrace{(\vec{q}_1^T \vec{a}_m)}_{r_{1m}} \vec{q}_1 - \underbrace{(\vec{q}_2^T \vec{a}_m)}_{r_{2m}} \vec{q}_2 - \dots - \underbrace{(\vec{q}_{m-1}^T \vec{a}_m)}_{r_{m-1,m}} \vec{q}_{m-1}$

$\vec{q}_m = \frac{\vec{n}_m}{\|\vec{n}_m\|} r_{mm}$



$$\begin{aligned} \|\vec{a}_1\| &= (\vec{q}_1^T \vec{a}_1) \\ \|\vec{n}_2\| &= (\vec{q}_2^T \vec{a}_2) \\ &\vdots \\ \|\vec{n}_m\| &= (\vec{q}_m^T \vec{a}_m) \end{aligned}$$

→ a cada passo, a projeção do vetor \vec{a}_k nos vetores ortogonais já definidos $\{\vec{q}_1, \vec{q}_2, \dots, \vec{q}_{k-1}\}$ e removida de \vec{a}_k , restando um vetor ortogonal \vec{v}_k .

→ se $\vec{v}_n = 0$, \vec{a}_n não é L.I., não há parte ortogonal em \vec{a}_n , utiliza outro método.

componentes de \vec{a}_k na base Q


$$\begin{cases} \vec{a}_1 = (\vec{q}_1^T \vec{a}_1) \vec{q}_1 \\ \vec{a}_2 = (\vec{q}_1^T \vec{a}_2) \vec{q}_1 + (\vec{q}_2^T \vec{a}_2) \vec{q}_2 \\ \vdots \\ \vec{a}_m = \sum_{j=1}^m (\vec{q}_j^T \vec{a}_m) \vec{q}_j \end{cases}$$

$$A = QR$$

$$[\vec{a}_1 \ \vec{a}_2 \ \dots \ \vec{a}_m] = [\vec{q}_1 \ \vec{q}_2 \ \dots \ \vec{q}_m] \underbrace{\begin{bmatrix} (\vec{q}_1^T \vec{a}_1) & (\vec{q}_1^T \vec{a}_2) & \dots & (\vec{q}_1^T \vec{a}_m) \\ 0 & (\vec{q}_2^T \vec{a}_2) & \dots & (\vec{q}_2^T \vec{a}_m) \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & (\vec{q}_m^T \vec{a}_m) \end{bmatrix}}_R$$

$\vec{a}_j = Q \vec{r}_j$
 ↳ coef. da comb. linear dos vetores coluna de Q.

ex) $A = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}$



$$\vec{q}_1 = \frac{\vec{a}_1}{\|\vec{a}_1\|} = \begin{bmatrix} 1/\sqrt{3} \\ 1/\sqrt{3} \\ 1/\sqrt{3} \end{bmatrix}$$

$$r_{11} = \|\vec{a}_1\| = \sqrt{3}$$

algoritmo:

$$\vec{q}_1 = \frac{\vec{a}_1}{\|\vec{a}_1\|}$$

for $j = 2 : n$

$$\vec{v}_j = \vec{a}_j$$

for $i = 1 : j-1$

$$\vec{v}_j = \vec{v}_j - (\vec{q}_i^T \vec{a}_j) \vec{q}_i$$

$$r_{ij} = (\vec{q}_i^T \vec{a}_j)$$

end

$$\vec{q}_j = \vec{v}_j / \|\vec{v}_j\|$$

$$r_{jj} = \|\vec{v}_j\|$$

$$\vec{v}_2 = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} - \underbrace{\begin{bmatrix} 1/\sqrt{3} & 1/\sqrt{3} & 1/\sqrt{3} \end{bmatrix}}_{\mu_{12} = 1/\sqrt{3}} \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \begin{bmatrix} 1/\sqrt{3} \\ 1/\sqrt{3} \\ 1/\sqrt{3} \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} - \begin{bmatrix} 1/3 \\ 1/3 \\ 1/3 \end{bmatrix} = \begin{bmatrix} 2/3 \\ -1/3 \\ -1/3 \end{bmatrix}$$

$$\vec{q}_2 = \frac{\vec{v}_2}{\|\vec{v}_2\|} = \frac{1}{\sqrt{6}/3} \begin{bmatrix} 2/3 \\ -1/3 \\ -1/3 \end{bmatrix} = \begin{bmatrix} 2/\sqrt{6} \\ -1/\sqrt{6} \\ -1/\sqrt{6} \end{bmatrix} \quad \mu_{22} = \frac{\sqrt{6}}{3}$$

$$\vec{v}_3 = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} - \underbrace{\begin{bmatrix} 1/\sqrt{3} & 1/\sqrt{3} & 1/\sqrt{3} \end{bmatrix}}_{\mu_{13} = 2/\sqrt{3}} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} \begin{bmatrix} 1/\sqrt{3} \\ 1/\sqrt{3} \\ 1/\sqrt{3} \end{bmatrix} - \underbrace{\begin{bmatrix} 2/\sqrt{6} & -1/\sqrt{6} & -1/\sqrt{6} \end{bmatrix}}_{\mu_{23} = 1/\sqrt{6}} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} \begin{bmatrix} 2/\sqrt{6} \\ -1/\sqrt{6} \\ -1/\sqrt{6} \end{bmatrix}$$

$$= \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} - \begin{bmatrix} 2/3 \\ 2/3 \\ 2/3 \end{bmatrix} - \begin{bmatrix} 1/3 \\ -1/6 \\ -1/6 \end{bmatrix} = \begin{bmatrix} 0 \\ 1/2 \\ -1/2 \end{bmatrix}$$

$$\vec{q}_3 = \frac{\vec{v}_3}{\|\vec{v}_3\|} = \frac{1}{\sqrt{2}/2} \begin{bmatrix} 0 \\ 1/2 \\ -1/2 \end{bmatrix} = \begin{bmatrix} 0 \\ 1/\sqrt{2} \\ -1/\sqrt{2} \end{bmatrix} \quad \mu_{33} = \frac{\sqrt{2}}{2}$$

$$Q = \begin{bmatrix} 1/\sqrt{3} & 2/\sqrt{6} & 0 \\ 1/\sqrt{3} & -1/\sqrt{6} & 1/\sqrt{2} \\ 1/\sqrt{3} & -1/\sqrt{6} & -1/\sqrt{2} \end{bmatrix} \quad R = \begin{bmatrix} \sqrt{3} & 1/\sqrt{3} & 2/\sqrt{3} \\ 0 & \sqrt{6}/3 & 1/\sqrt{6} \\ 0 & 0 & \sqrt{2}/2 \end{bmatrix}$$

A = QR ✓ (cheque no MATLAB)

• no MATLAB/OCTAVE: [Q,R] = qr(A)

• método de Gram - Schmidt modificado: (mais estável numericamente): a cada iteração k, remove as projeções de todos os \vec{a}_i 's de uma dada direção \vec{q}_k , criando vetores temporários $\vec{v}_i^{(k)}$.

V = A

for j = 1 : n

$\vec{q}_j = \frac{\vec{v}_j}{\|\vec{v}_j\|}$ (define \vec{q}_j)

for k = j+1 : n

$\vec{v}_k = \vec{v}_k - (\vec{q}_j^T \vec{v}_k) \vec{q}_j$ (remove projeções em \vec{q}_j)

end

end.

⇒ Cálculo de autovalores: para $A \in \mathbb{R}^{n \times n}$ não-singular

* Método QR (de Francis)

$A^{(0)} = A$

while (erro > tol)

$[Q^{(k)}, R^{(k)}] = qr(A^{(k)})$

$A^{(k+1)} = R^{(k)} Q^{(k)}$

erro = $\max_{i > j} |a_{ij}^{(k+1)}|$ →

end

elementos abaixo da diag. principal.

calcula enquanto os valores abaixo da diag. principal são maiores que a tolerância.

$A^{(k+1)} = RQ = Q^{-1} \underbrace{QR}_{A^{(k)}} = Q^{-1} A^{(k)} Q$

logo $A^{(k+1)}$ é similar a $A^{(k)}$ (mesmos autovalores).

Como Q é matriz ortogonal:

$A^{(k+1)} = Q^T A^{(k)} Q$

matriz triangular. (Dec. Schur).

- obs:
- se $|\lambda_i| = |\lambda_j|$, o método não converge.
 - a taxa de convergência decai com a proximidade de $|\lambda_i|$ e $|\lambda_j|$.
 - para A singular ou $A \in \mathbb{C}^{m \times m}$: modificações no método QR.

* Método da potência: $\left\{ \begin{array}{l} \text{Quarteroni: 6.2} \\ \text{Francos: 7.4} \end{array} \right.$

- se $A \in \mathbb{R}^{m \times n}$ com n autovetores L.I. (diagonalizável).
- se somente o maior autovalor é necessário.

$$\underline{|\lambda_1|} > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n|$$

Quociente de Rayleigh: $\mu(\vec{x}) = \frac{\vec{x}^T (A\vec{x})}{\|\vec{x}\|^2}$

se \vec{x} é autovetor:

- $\mu(\vec{x}) = \frac{\vec{x}^T (\lambda \vec{x})}{\|\vec{x}\|^2} = \frac{\lambda \vec{x}^T \vec{x}}{\|\vec{x}\|^2} = \lambda \frac{\|\vec{x}\|^2}{\|\vec{x}\|^2} = \lambda$

- $\vec{y} = \frac{\vec{x}}{\|\vec{x}\|}$ também é autovetor

$$A\vec{y} = \lambda \vec{y} \qquad \vec{y}^T (A\vec{y}) = \lambda \vec{y}^T \vec{y}$$

$$\lambda = \vec{y}^T (A\vec{y})$$

- se A é não-singular, $\lambda_i \neq 0$ e $A\vec{x} = \lambda \vec{x}$ $AA^{-1}\vec{x} = \lambda A^{-1}\vec{x}$
 $A^{-1}\vec{x} = 1/\lambda \vec{x}$


algoritmo: $\vec{n}^{(0)}$ = chute inicial

iterações em K $\left\{ \begin{array}{l} \vec{y}^{(K)} = \frac{\vec{n}^{(K)}}{\|\vec{n}^{(K)}\|} \quad (\text{normaliza o vetor}) \\ \lambda^{(K)} = \vec{y}^{(K)T} (A \vec{y}^{(K)}) \quad (\text{autovalor correspondente}) \\ \vec{n}^{(K+1)} = A \vec{y}^{(K)} \quad (\text{novo vetor é a transf. linear do vetor anterior}) \end{array} \right.$

para $K \rightarrow \infty$: $\left\{ \begin{array}{l} \lambda^{(K)} \rightarrow \text{maior autovalor em módulo} \\ \vec{y}^{(K)} \rightarrow \text{autovetor correspondente} \end{array} \right.$

• ao multiplicar um vetor \vec{n} normalizado por A à esquerda (transformar \vec{n}), nos aproximamos do autovetor de maior autovalor em módulo \rightarrow potências de A .

• Critério de parada: $|\lambda^{(K+1)} - \lambda^{(K)}| < \epsilon$

 $\cdot \left| \left| \vec{y}^{(k+1)T} \vec{y}^{(k)} \right| - 1 \right| < \epsilon$

* Método da potência inversa:

- se $A \in \mathbb{R}^{m \times m}$ com m autovetores l.i. e não-singular
- se somente o menor autovalor é necessário.

$\lambda_i(A^{-1}) = \frac{1}{\lambda_i(A)} \rightarrow$ menor autovalor de A é o inverso do maior autovalor de A^{-1} .

algoritmo: $\vec{x}^{(0)}$ = chute inicial $B = \text{inv}(A)$

$$\vec{y}^{(k)} = \frac{\vec{x}^{(k)}}{\|\vec{x}^{(k)}\|}$$

$$\lambda^{(k)} = \vec{y}^{(k)T} \underbrace{(A^{-1} \vec{y}^{(k)})}_B$$

$$\vec{x}^{(k+1)} = \underbrace{A^{-1}}_B \vec{y}^{(k)} \rightarrow \underbrace{A \vec{x}^{(k+1)}} = \vec{y}^{(k)}$$

solução de um sistema de eq. linear. K vezes \Rightarrow decomposição LU.

para $k \rightarrow \infty$ $\left\{ \begin{array}{l} 1/\lambda^{(k)} \rightarrow \text{maior autovvalor em módulo} \\ \vec{y}^{(k)} \rightarrow \text{autovector correspondente.} \end{array} \right.$

* Método da potência com shift (deslocamento):

autovvalores $\left\{ \begin{array}{l} A : \{ \lambda_1, \lambda_2, \dots, \lambda_n \} \\ (A + \alpha I) : \{ \lambda_1 + \alpha, \lambda_2 + \alpha, \dots, \lambda_n + \alpha \} \end{array} \right.$

se $B = (A - \alpha I)^{-1}$ $\mu_j = \frac{1}{\lambda_j - \alpha}$ são autovvalores de B.

logo, se α está próximo de λ_j , μ_j está próximo do maior autovvalor de B.

$\alpha \Rightarrow$ deslocamento.

para achar o autovvalor mais próximo de α , aplica o método das Potências em $B = (A - \alpha I)^{-1}$. $\lambda = \frac{1}{\mu} + \alpha$

* Convergência do método da potência:

• $A \in \mathbb{R}^{m \times n}$ com n autovetores L.I. (diagonalizável) (\vec{v}_i)

• podemos usar os autovetores como base e escrever qualquer $\vec{n} \in \mathbb{R}^m$ como: $A \vec{v}_i = \lambda_i \vec{v}_i$

$$\vec{n} = \alpha_1 \vec{v}_1 + \alpha_2 \vec{v}_2 + \dots + \alpha_m \vec{v}_m$$

$$A \vec{n} = \alpha_1 \underbrace{A \vec{v}_1}_{\lambda_1 \vec{v}_1} + \alpha_2 \underbrace{A \vec{v}_2}_{\lambda_2 \vec{v}_2} + \dots + \alpha_m \underbrace{A \vec{v}_m}_{\lambda_m \vec{v}_m}$$

$$A \vec{n} = \alpha_1 \lambda_1 \vec{v}_1 + \alpha_2 \lambda_2 \vec{v}_2 + \dots + \alpha_m \lambda_m \vec{v}_m$$

similarmente

$$\begin{aligned} A^k \vec{n} &= \alpha_1 \lambda_1^k \vec{v}_1 + \alpha_2 \lambda_2^k \vec{v}_2 + \dots + \alpha_m \lambda_m^k \vec{v}_m \\ &= \lambda_1^k \left(\alpha_1 \vec{v}_1 + \alpha_2 \left(\frac{\lambda_2}{\lambda_1}\right)^k \vec{v}_2 + \dots + \left(\frac{\lambda_m}{\lambda_1}\right)^k \vec{v}_m \right) \end{aligned}$$

se $|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_m|$

$$\lim_{k \rightarrow \infty} \left(\frac{\lambda_i}{\lambda_1}\right)^k \rightarrow 0, \quad i \neq 1$$

$$A^k \vec{n} = \lambda_1^k \alpha_1 \vec{v}_1$$

$\vec{n} = \alpha_1 \vec{v}_1$ é autovetor da maior autovalor λ_1 .

* Matrizes simétricas: $S = S^T \in \underline{\underline{\mathbb{R}^{n \times n}}}$

- todos os n autovalores são números reais
- todos os n autovetores podem ser escolhidos ortogonais (ortonormais)
- Teorema espectral:

$$S = Q \Lambda Q^T, \begin{cases} \Lambda \rightarrow \text{diagonal} \\ Q \rightarrow \text{ortogonal} \end{cases}$$

- para qualquer matriz $A \in \mathbb{R}^{n \times n}$,

$$AA^T = S_1 \quad A^T A = S_2$$

- caso complexo: matriz Hermitiana:

$$S = \overline{S^T} = S^H$$

(mesma propriedade de autovalores/vetores)

* Matrizes anti-simétricas: $R = -R^T \in \underline{\underline{\mathbb{R}^{n \times n}}}$

- todos os elementos da diagonal principal são zero
- todos os autovalores são imaginários puros (ou zero)
- autovetores ortogonais (complexos)
- Teorema espectral:

$$R = U \Lambda U^H \begin{cases} \Lambda \rightarrow \text{diagonal} \\ U \rightarrow \text{unitária} \end{cases}$$

- Caso complexo: matriz anti-Hermitiana:


$$R = -\overline{R^T} = -R^H$$

(mesma propriedade de autovalores/vetores)


* Matrizes ortogonais: $Q^T Q = Q Q^T = I$, $Q^T = Q^{-1}$

- $|\lambda| = 1$ (rotações)
- autovalores ortogonais (imaginários)
- complexo: unitária: $V^H V = V V^H = I$


plano complexo:
autovalores



* Decomposição SVD: (singular value decomp.)



$A = U \Sigma V^T$ $\left\{ \begin{array}{l} U \text{ e } V \rightarrow \text{ortogonais (rotações)} \\ \Sigma \rightarrow \text{diagonal (contração/estiramento dos eixos principais)} \end{array} \right.$



como calcular:

$$\bullet A^T A = (U \Sigma V^T)^T (U \Sigma V^T) = V \Sigma \underbrace{U^T U}_{I} \Sigma V^T = V \Sigma^2 V^T$$

$$\bullet A A^T = (U \Sigma V^T) (U \Sigma V^T)^T = U \Sigma \underbrace{V^T V}_{I} \Sigma U^T = U \Sigma^2 U^T$$

simétricas

*teorema
espectral
(Schur)*

⇒ método QR em $\underbrace{A^T A}_{S_1}$, $\underbrace{A A^T}_{S_2}$: autovalores são Σ^2 (iguais)

obs.: se S é simétrica: algoritmo:

$$A^{(0)} = S, V = I$$

while (erro > tol):

$$A^{(k)} = Q \cdot R \rightarrow [Q, R] = q_n(A)$$

$$A^{(k+1)} = R \cdot Q$$

$$V = V \cdot Q$$

$$\text{erro} = \dots$$

end

$A \rightarrow$ diagonal (autovalores)

$V \rightarrow$ autovetores ortogonais (colunas).

em MATLAB:

$$\begin{cases} A^{(0)} = A^T A \rightarrow \Sigma^2, V \\ A^{(0)} = A A^T \rightarrow \Sigma^2, U \\ [U, S, V] = \text{svd}(A) \end{cases}$$

porque é importante: $K = \text{posto}(A)$

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_K > 0$$

$$A = U \Sigma V^T = \underbrace{\sigma_1 \vec{u}_1 \vec{v}_1^T + \sigma_2 \vec{u}_2 \vec{v}_2^T + \dots + \sigma_K \vec{u}_K \vec{v}_K^T}_{K \text{ matrizes de posto } 1 \checkmark}$$

1 + 2 · m × 1 *1 + 2 · m × 1*

melhor aproximação de A com posto 1

melhor aproximação de A com posto m

$$\left\{ \sigma_1 \vec{u}_1 \vec{v}_1^T + \sigma_2 \vec{u}_2 \vec{v}_2^T + \dots + \sigma_m \vec{u}_m \vec{v}_m^T \right\}$$

usado p/ reduzir o posto da matriz mantendo a melhor informação possível.

ex) $A = \begin{bmatrix} 3 & 0 \\ 4 & 5 \end{bmatrix}$

$$A^T A = \begin{bmatrix} 3 & 4 \\ 0 & 5 \end{bmatrix} \begin{bmatrix} 3 & 0 \\ 4 & 5 \end{bmatrix} = \begin{bmatrix} 25 & 20 \\ 20 & 25 \end{bmatrix} \begin{cases} \lambda_1 = 5, \lambda_2 = 45 \checkmark \\ \vec{x}_1 = \frac{1}{\sqrt{2}} \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \vec{x}_2 = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 \\ 1 \end{bmatrix} \checkmark \end{cases}$$

$$A A^T = \begin{bmatrix} 3 & 0 \\ 4 & 5 \end{bmatrix} \begin{bmatrix} 3 & 4 \\ 0 & 5 \end{bmatrix} = \begin{bmatrix} 9 & 12 \\ 12 & 41 \end{bmatrix} \begin{cases} \lambda_1 = 5, \lambda_2 = 45 \checkmark \\ \vec{x}_1 = \frac{1}{\sqrt{10}} \begin{bmatrix} -3 \\ 1 \end{bmatrix} \quad \vec{x}_2 = \frac{1}{\sqrt{10}} \begin{bmatrix} 1 \\ +3 \end{bmatrix} \checkmark \end{cases}$$

$$\Sigma = \begin{bmatrix} \sqrt{45} & 0 \\ 0 & \sqrt{5} \end{bmatrix} \quad V = \begin{bmatrix} 1/\sqrt{2} & -1/\sqrt{2} \\ 1/\sqrt{2} & +1/\sqrt{2} \end{bmatrix} \quad U = \begin{bmatrix} 1/\sqrt{10} & -3/\sqrt{10} \\ 3/\sqrt{10} & 1/\sqrt{10} \end{bmatrix}$$

$$A = \begin{bmatrix} 1/\sqrt{10} & -3/\sqrt{10} \\ 3/\sqrt{10} & 1/\sqrt{10} \end{bmatrix} \begin{bmatrix} \sqrt{45} & 0 \\ 0 & \sqrt{5} \end{bmatrix} \begin{bmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ -1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix} = U \Sigma V^T \checkmark$$

melhor aproximação de A de posto 1:

$$A_1 = \sigma_1 \vec{u}_1 \vec{v}_1^T = \sqrt{45} \begin{bmatrix} 1/\sqrt{10} \\ 3/\sqrt{10} \end{bmatrix} \begin{bmatrix} 1/\sqrt{2} & -1/\sqrt{2} \end{bmatrix}$$

$$= \sqrt{45} \begin{bmatrix} 1/\sqrt{20} & -1/\sqrt{20} \\ 3/\sqrt{20} & -3/\sqrt{20} \end{bmatrix}$$

exemplo 6.9 \rightarrow quantização

$$\begin{cases} A = \text{escala de linha de pixels de imagem jpeg.} \\ A_{20} \rightarrow \text{compressão, perda de imagem.} \end{cases}$$