

## 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  $\lambda$ , acha  $\vec{n}$ .

① resolve e acha  $\lambda$ 's  
(polinômio característico)

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)


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

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


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

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

I                       $\vec{b}$



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



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

- $P_{m \times m}$  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  $\neq 1$  e  $\neq -1$ ).

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  $P$ .



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

- 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:

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

### \* Decomposiço de Schur:

• Teorema: toda matriz  $A_{n \times n}$  e similar a uma matriz triangular superior. Alem disso, a matriz mudana de base  $P$  pode ser escolhida como uma matriz ortogonal (unitaria no caso complexo), cujos vetores coluna formam uma base ortonormal.

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

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

$\left\{ \begin{array}{l} \text{se } Q \in \mathbb{R}^{n \times n}: \quad Q^T Q = Q Q^T = I, \quad Q^{-1} = Q^T \\ \text{se } Q \in \mathbb{C}^{n \times n}: \quad Q^H Q = Q Q^H = I \quad Q^{-1} = Q^H \end{array} \right.$   
 $\quad \quad \quad \hookrightarrow$  hermitiano transposto  
 $\quad \quad \quad \hookrightarrow$  matriz unitaria

•  $A = Q^T Q^{-1}$  ou  $A = Q^T Q^H$

• a decomposio de Schur nao e unica.

• se  $A$  e matriz normal (simetrica, anti-simetrica, unitaria...)

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

onde  $\Lambda$  e matriz diagonal. Dizemos que  $A$  e diagonalizavel.

•  $A$  e diagonalizavel se e somente se  $A$  possui  $n$  autovetores l.i.

\* Cálculo numérico de autovalores: 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


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

• método de Gram-Schmidt:

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

mesmo espaço vetorial

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



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

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


③  $\vec{n}_3 = \vec{a}_3 - (\vec{q}_1^T \vec{a}_3) \vec{q}_1 - (\vec{q}_2^T \vec{a}_3) \vec{q}_2$

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

⋮

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

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



$\|\vec{a}_1\| = (\vec{q}_1^T \vec{a}_1)$

$\|\vec{n}_2\| = (\vec{q}_2^T \vec{a}_2)$

⋮

$\|\vec{n}_m\| = (\vec{q}_m^T \vec{a}_m)$

→ a cada passo, a projeção do vetor  $\vec{a}_k$  nos vetores ortogonais já definidos  $\{\vec{q}_1, \vec{q}_2, \dots, \vec{q}_{k-1}\}$  é 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


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

$$A = QR$$

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

$\vec{a}_j = Q \vec{r}_j$   
 ↳ 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  $j = 2 : m$

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

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

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

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

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

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

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

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

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

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

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

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  $\vec{n}_i^{(k)}$ .

$$V = A$$

for  $j = 1 : n$

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

for  $k = j+1 : n$

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

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)

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

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

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

end

elementos abaixo da diag. principal.

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

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

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

Como  $Q$  é matriz ortogonal:

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

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:  $\left\{ \begin{array}{l} \text{Quarteroni: 6.2} \\ \text{Franco: 7.4} \end{array} \right.$

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

• se somente o maior autovalor é real e positivo.

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

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

$$A\vec{y} = \lambda \vec{y}$$

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

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

• 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  $A \in \mathbb{R}^{n \times n}$  com  $n$  autovetores l.i. e mão-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  $B = \text{inv}(A)$

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

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

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

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

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

\* Método da potência com shift (deslocamento):

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

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

logo, se  $\alpha$  está próximo de  $\lambda_j$ ,  $\mu_j$  está próximo do maior autovalor de B.

$\alpha \Rightarrow$  deslocamento.

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

\* Convergência do método da potência:

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

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

$$\vec{x} = \alpha_1 \vec{v}_1 + \alpha_2 \vec{v}_2 + \dots + \alpha_n \vec{v}_n$$

$$A \vec{x} = \alpha_1 \underbrace{A \vec{v}_1}_{\lambda_1 \vec{v}_1} + \alpha_2 \underbrace{A \vec{v}_2}_{\lambda_2 \vec{v}_2} + \dots + \alpha_n \underbrace{A \vec{v}_n}_{\lambda_n \vec{v}_n}$$

$$A \vec{x} = \alpha_1 \lambda_1 \vec{v}_1 + \alpha_2 \lambda_2 \vec{v}_2 + \dots + \alpha_n \lambda_n \vec{v}_n$$

similarmente

$$\begin{aligned} A^k \vec{x} &= \alpha_1 \lambda_1^k \vec{v}_1 + \alpha_2 \lambda_2^k \vec{v}_2 + \dots + \alpha_n \lambda_n^k \vec{v}_n \\ &= \lambda_1^k \left( \alpha_1 \vec{v}_1 + \alpha_2 \left(\frac{\lambda_2}{\lambda_1}\right)^k \vec{v}_2 + \dots + \left(\frac{\lambda_n}{\lambda_1}\right)^k \vec{v}_n \right) \end{aligned}$$

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

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

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

$\vec{x} = \alpha_1 \vec{v}_1$  é autovetor da maior autovalor  $\lambda_1$ .