

Exemplos de normas induzidas:

1)  $\|A\|_1 \triangleq \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|$  → não das funções antes, causa confusão. (máxima soma de colunas)

esta norma é induzida pela norma vetorial  $l_1$ :

Seja  $A = [a_1 \ a_2 \ \dots \ a_n] \in \mathbb{C}^{n \times n}$  e  $x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$ . Então

$$\|Ax\|_1 = \|x_1 a_1 + \dots + x_n a_n\|_1 \leq \sum_{i=1}^n \|x_i a_i\|_1 = \sum_{i=1}^n |x_i| \|a_i\|_1$$

$$\leq \left[ \sum_{i=1}^n |x_i| \right] \left[ \max_{1 \leq k \leq n} \|a_k\|_1 \right] = \sum_{i=1}^n |x_i| \|A\|_1 = \|x\|_1 \cdot \|A\|_1$$

e portanto,  $\max_{\|x\|_1=1} \|Ax\|_1 \leq \|A\|_1$ . Por outro lado, se

escolhermos  $x = e_k$  onde  $k$  é tal que  $\|a_k\|_1 = \max_{1 \leq i \leq n} \|a_i\|_1$

então  $\|Ax\|_1 = \|Ae_k\|_1 = \|a_k\|_1 = \|A\|_1$ . Com isto, provamos

que  $\|A\|_1 \triangleq \max_{\|x\|_1=1} \|Ax\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| = \max_{1 \leq j \leq n} \|a_j\|_1$

2)  $\|A\|_\infty \triangleq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$ . Esta norma é induzida pela

norma vetorial  $l_\infty$ , o que pode ser provado de forma semelhante ao resultado anterior.

3)  $\|A\|_2$  ou norma espectral:

$$\|A\|_2 \triangleq \max \{ \sqrt{\lambda} : \lambda \text{ é um autovalor de } A^H A \}$$

(note que se  $A^H A x = \lambda x$  e  $x \neq 0$ , então  $x^H A^H A x = \lambda \|x\|^2 = \|Ax\|^2 \geq 0$ , e portanto  $\lambda \in \mathbb{R}, \lambda \geq 0$ .)

Vamos provar nas próximas aulas que a norma espectral é induzida pela norma vetorial Euclidiana:

$$\|A\|_2 = \max_{\|x\|_2=1} \|Ax\|_2$$

4) Construindo novas normas: Teorema: Se  $\|\cdot\|$  é uma norma matricial em  $\mathbb{C}^{n \times n}$  e  $S \in \mathbb{C}^{n \times n}$  é não-singular, então  $\|A\|_S = \|S^{-1} A S\|$  é uma norma matricial.

Prova: Exercício.

Como vimos, existe uma grande variedade de normas matriciais. Como escolher qual usar em cada situação? Dentre as normas que podem ser usadas com matrizes, aquelas que satisfazem o axioma submultiplicativo (e que chamamos de "normas matriciais") satisfazem

$\|I\| \geq 1$ , o que é uma espécie de normalização (note que se  $\|\cdot\|$  é uma norma matricial, a função  $\|\cdot\|_\alpha = \alpha \|\cdot\|$  não satisfaz necessariamente ao axioma submultiplicativo). Existiria então, dentre todos as normas submultiplicativas, uma norma mínima, tal que  $\|A\| \leq \|A\|_\alpha$  para todo  $A \in \mathbb{C}^{n \times n}$  e todas as outras normas matriciais  $\|\cdot\|_\alpha$ ? (nota: o índice  $\alpha$  representa aqui apenas "uma outra norma", trata-se somente de uma forma de diferenciar os símbolos  $\|\cdot\|$  e  $\|\cdot\|_\alpha$  para normas diferentes).

Vemos agora que existe entre as normas matriciais uma classe de normas ótimas, num certo sentido. Dentro desta classe, não há normas melhores ou piores consistentemente. Para este estudo, vamos precisar da seguinte definição:

Definição: Denomina-se raio espectral de uma matriz  $A \in \mathbb{C}^{n \times n}$  a quantidade

$$\rho(A) \triangleq \max_{1 \leq i \leq n} |\lambda_i(A)|.$$

Teorema: Se  $\|\cdot\|$  é uma norma matricial, então

$$\|A\| \geq \rho(A) \quad \text{para todo } A \in \mathbb{C}^{n \times n}.$$

Prova: Seja  $\lambda$  o autovalor de  $A$  tal que  $|\lambda| = \rho(A)$ , e  $\underline{x}$  um autovetor correspondente a  $\lambda$ . Defina

$$X = [\underline{x} \quad \underline{x} \quad \dots \quad \underline{x}] \in \mathbb{C}^{n \times n}.$$

Então,

$$|\lambda| \cdot \|X\| = \|\lambda X\| = \|AX\| \leq \|A\| \cdot \|X\|.$$

Como  $\underline{x} \neq 0$ ,  $\|X\| \neq 0$  e o resultado segue.  $\square$

Note que a propriedade submultiplicativa é essencial para a demonstração do teorema!

Na verdade, o raio espectral não é apenas um limite inferior para todas as normas possíveis de uma matriz;  $\rho(A)$  é o maior desses limites inferiores. Ou seja,

$$\rho(A) = \inf \|A\|_\alpha, \text{ para todo } A \in \mathbb{C}^{n \times n}$$

$\|\cdot\|_\alpha$  é uma norma matricial

Teorema: Sejam  $A \in \mathbb{C}^{n \times n}$  e  $\varepsilon > 0$  dados. Então existe uma norma matricial  $\|\cdot\|$  tal que

$$\rho(A) \leq \|A\| \leq \rho(A) + \varepsilon.$$

Prova: Seja  $S$  uma transformação de similaridade que coloca  $A$  na forma de Jordan:

$$S^{-1}AS = \begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ 0 & & & \lambda_n \end{bmatrix},$$

onde  $a(i) = 0$  ou  $1$ , dependendo da estrutura dos blocos de Jordan que compõe  $S^{-1}AS$ .

Seja  $D = \begin{bmatrix} \varepsilon & & 0 \\ & \varepsilon^2 & \\ & & \ddots \\ 0 & & & \varepsilon^n \end{bmatrix}$ , e defina  $\|B\| = \|D^{-1}SD\|_1$ .

Então  $\|A\| = \left\| \begin{bmatrix} \lambda_1 & \varepsilon a(1) & & \\ & \lambda_2 & \varepsilon a(2) & \\ & & \ddots & \varepsilon a(n-1) \\ & & & \lambda_n \end{bmatrix} \right\|_1 \leq \rho(A) + \varepsilon.$

Note no entanto que  $\rho(A)$  não é uma norma matricial (nem se relaxarmos a definição de norma matricial eliminando o axioma submultiplicativo), pois  $\rho(A)$  não obedece à desigualdade triangular, e  $\rho(A)$  pode ser igual a zero para  $A \neq 0$ :

$$\underbrace{\begin{bmatrix} a & 1 \\ 0 & a \end{bmatrix}}_{\rho(A)=|a|} + \underbrace{\begin{bmatrix} -a & 1 \\ 0 & -a \end{bmatrix}}_{\rho(B)=|a|} = \underbrace{\begin{bmatrix} 0 & 2 \\ 0 & 0 \end{bmatrix}}_{\rho(A+B)=0}.$$

Como veremos em breve ao estudar convergência de séries de matrizes, é conveniente, em muitas situações, usar uma norma tal que  $\|A\|$  seja o menor possível. Vamos mostrar agora que não existe uma tal norma uniformemente melhor que as outras, mas que as normas induzidas se aproximam deste ideal o melhor possível.

Teorema: Seja  $\|\cdot\|$  uma norma matricial em  $\mathbb{C}^{n \times n}$ , e seja  $\|\cdot\|_\alpha$  uma dada norma induzida, também em  $\mathbb{C}^{n \times n}$ . Então

- a) Existe uma norma induzida  $N(\cdot)$  em  $\mathbb{C}^{n \times n}$  tal que  $N(A) \leq \|A\|$  para todo  $A \in \mathbb{C}^{n \times n}$ , e
- b)  $\|A\| \leq \|A\|_\alpha$  para todo  $A \in \mathbb{C}^{n \times n}$  se e somente se  $\|A\| = \|A\|_\alpha$  para todo  $A \in \mathbb{C}^{n \times n}$ .

Prova: Defina a norma vetorial  $\|\cdot\|$  em  $\mathbb{C}^n$  por  $\|\underline{x}\| = \|X\|$ , onde  $X = [\underline{x} \ \underline{x} \ \dots \ \underline{x}] \in \mathbb{C}^{n \times n}$ ,

e defina  $N(\cdot)$  como a norma matricial induzida por  $\|\cdot\|$ . Então, para qualquer  $A \in \mathbb{C}^{n \times n}$ , temos

$$N(A) = \max_{\|\underline{x}\| \neq 0} \frac{\|A\underline{x}\|}{\|\underline{x}\|} = \max_{\underline{x} \neq 0} \frac{\| [A\underline{x} \ A\underline{x} \ \dots \ A\underline{x}] \|}{\| [\underline{x} \ \underline{x} \ \dots \ \underline{x}] \|} = \max_{\underline{x} \neq 0} \frac{\|AX\|}{\|X\|} \leq \|A\|$$

Para provar (b), note que  $N(A) \leq \|A\| \leq \|A\|_\alpha$  para todo  $A \in \mathbb{C}^{n \times n}$ , e use o teorema e o corolário abaixo.

Teorema: Sejam  $\|\cdot\|_\alpha$  e  $\|\cdot\|_\beta$  duas normas vetoriais em  $\mathbb{C}^n$ , e sejam  $\|\cdot\|_\alpha$  e  $\|\cdot\|_\beta$  as respectivas normas induzidas em  $\mathbb{C}^{n \times n}$ . Defina

$$R_{\alpha\beta} = \max_{\underline{x} \neq 0} \frac{\|\underline{x}\|_\alpha}{\|\underline{x}\|_\beta}, \quad R_{\beta\alpha} = \max_{\underline{x} \neq 0} \frac{\|\underline{x}\|_\beta}{\|\underline{x}\|_\alpha}$$

$$\text{Então, } \max_{A \neq 0} \frac{\|A\|_\alpha}{\|A\|_\beta} = R_{\alpha\beta} R_{\beta\alpha} = \max_{A \neq 0} \frac{\|A\|_\beta}{\|A\|_\alpha}$$

Prova: Sejam  $A \in \mathbb{C}^{n \times n}$  e  $\underline{x} \in \mathbb{C}^n$  dados, e assumamos  $\underline{x} \neq 0$  e  $A\underline{x} \neq 0$ . Então

$$\frac{\|A\underline{x}\|_\alpha}{\|\underline{x}\|_\alpha} = \frac{\|A\underline{x}\|_\alpha}{\|A\underline{x}\|_\beta} \cdot \frac{\|A\underline{x}\|_\beta}{\|\underline{x}\|_\beta} \cdot \frac{\|\underline{x}\|_\beta}{\|\underline{x}\|_\alpha} \leq R_{\alpha\beta} \cdot \frac{\|A\underline{x}\|_\beta}{\|\underline{x}\|_\beta} \cdot R_{\beta\alpha} \quad (2)$$

(note que a desigualdade <sup>final</sup> também vale se  $A\underline{x} = 0$ ).

Então

$$\|A\|_\alpha = \max_{\underline{x} \neq 0} \frac{\|A\underline{x}\|_\alpha}{\|\underline{x}\|_\alpha} \leq \max_{\underline{x} \neq 0} \frac{\|A\underline{x}\|_\beta}{\|\underline{x}\|_\beta} \cdot R_{\alpha\beta} \cdot R_{\beta\alpha} = R_{\alpha\beta} R_{\beta\alpha} \|A\|_\beta$$

Ou seja: mostramos que  $\frac{\|A\|_\alpha}{\|A\|_\beta} \leq R_{\alpha\beta} R_{\beta\alpha}$ . Faltava agora mostrar que existe  $A_0$  para o qual a desigualdade se torna igualdade.

Os dois máximos em (2) não atingidos para certos vetores em  $\mathbb{C}^n$ .  
 Sejam  $\underline{y}, \underline{z}$  tais que  $\|\underline{y}\|_2 = \|\underline{z}\|_2 = 1$ ,  $\|\underline{y}\|_\alpha = R_{\alpha\beta} \|\underline{y}\|_\beta$ , e  
 $\|\underline{z}\|_\beta = R_{\beta\alpha} \|\underline{z}\|_\alpha$ .

Como vimos ao estudar normas duais, existe um vetor  $\underline{z}_0 \in \mathbb{C}^n$  tal que

- (a)  $|\underline{z}_0^H \underline{z}| \leq \|\underline{z}\|_\beta$  para todo  $\underline{z} \in \mathbb{C}^n$
- (b)  $\underline{z}_0^H \underline{z}_0 = \|\underline{z}_0\|_\beta$ .

Defina a matriz  $A_0 = \underline{y} \underline{z}_0^H$ . Usando (b), temos

$$\frac{\|A_0 \underline{z}\|_\alpha}{\|\underline{z}\|_\alpha} = \frac{\|\underline{y} \underline{z}_0^H \underline{z}\|_\alpha}{\|\underline{z}\|_\alpha} = \frac{\|\underline{y}\|_\alpha |\underline{z}_0^H \underline{z}|}{\|\underline{z}\|_\alpha} = \frac{\|\underline{y}\|_\alpha}{\|\underline{z}\|_\alpha} \|\underline{z}\|_\beta,$$

e portanto,  $\|A_0\|_\alpha \geq \frac{\|\underline{y}\|_\alpha \|\underline{z}_0\|_\beta}{\|\underline{z}_0\|_\alpha} \cdot \|\underline{z}_0\|_\beta = R_{\alpha\beta} R_{\beta\alpha} \|\underline{y}\|_\beta$ .

Por outro lado,

$$\frac{\|A_0 \underline{x}\|_\beta}{\|\underline{x}\|_\beta} = \frac{\|\underline{y} \underline{z}_0^H \underline{x}\|_\beta}{\|\underline{x}\|_\beta} = \frac{\|\underline{y}\|_\beta |\underline{z}_0^H \underline{x}|}{\|\underline{x}\|_\beta} \leq \frac{\|\underline{y}\|_\beta \|\underline{x}\|_\beta}{\|\underline{x}\|_\beta} = \|\underline{y}\|_\beta,$$

e portanto,  $\|A_0\|_\beta \leq \|\underline{y}\|_\beta$ .

Combinando as duas desigualdades, vem

$$\frac{\|A_0\|_\alpha}{\|A_0\|_\beta} \geq R_{\alpha\beta} \cdot R_{\beta\alpha}.$$

Pelo resultado anterior, <sup>para todo  $A \in \mathbb{C}^{n \times n}$</sup>  temos a desigualdade no sentido inverso. A conclusão é que

$$\frac{\|A_0\|_\alpha}{\|A_0\|_\beta} = R_{\alpha\beta} R_{\beta\alpha}.$$

Corolário: Sejam  $\|\cdot\|_\alpha$  e  $\|\cdot\|_\beta$  duas normas vetoriais em  $\mathbb{C}^n$ , com as respectivas normas matriciais induzidas  $\|\cdot\|_\alpha$  e  $\|\cdot\|_\beta$ . Então  $\|A\|_\alpha \leq \|A\|_\beta$  para todo  $A \in \mathbb{C}^{n \times n}$  se e somente se  $\|A\|_\alpha = \|A\|_\beta$  para todo  $A \in \mathbb{C}^{n \times n}$ .

Prova: Observe que

$$R_{\alpha\beta} = \max_{\underline{x} \neq 0} \frac{\|\underline{x}\|_\alpha}{\|\underline{x}\|_\beta} = \left[ \min_{\underline{x} \neq 0} \frac{\|\underline{x}\|_\beta}{\|\underline{x}\|_\alpha} \right]^{-1} \geq \left[ \max_{\underline{x} \neq 0} \frac{\|\underline{x}\|_\beta}{\|\underline{x}\|_\alpha} \right]^{-1} = \frac{1}{R_{\beta\alpha}}$$

$$\Rightarrow \boxed{R_{\alpha\beta} R_{\beta\alpha} \geq 1}$$

Definições: Seja  $A \in \mathbb{C}^{n \times n}$ . Um autovvalor de  $A$  é um escalar  $\lambda$  tal que existe  $\underline{x} \in \mathbb{C}^n$ ,  $\underline{x} \neq 0$  satisfazendo

$$A\underline{x} = \lambda \underline{x}.$$

$\underline{x}$  é denominado autovetor de  $A$ , relativo ao autovvalor  $\lambda$ .  
O conjunto dos autovvalores de uma matriz é o seu espectro:

$$\sigma(A) = \{ \lambda \in \mathbb{C} : \lambda \text{ é um autovvalor de } A \}.$$

O raio espectral de  $A$  é o máximo módulo dos autovvalores de  $A$ :

$$\rho(A) = \max \{ |\lambda| : \lambda \in \sigma(A) \}$$

Se  $(\lambda, \underline{x})$  é um par autovvalor / autovetor de  $A$ ,  
então

$$(\lambda I - A)\underline{x} = \lambda \underline{x} - A\underline{x} = \underline{0}$$

$\Rightarrow \lambda$  é autovvalor de  $A$  se e somente se  $\lambda I - A$  é singular, ou seja, se  $\det(\lambda I - A) = 0$ .

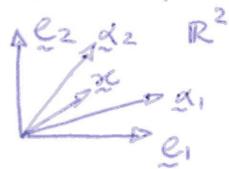
Define-se polinômio característico de  $A$  como o polinômio (de grau  $n$ )

$$p_A(s) = \det(sI - A).$$

Claramente,  $\lambda \in \sigma(A)$  se e somente se é uma raiz de  $p_A(s)$ . Como  $p_A(s)$  tem grau  $n$ , existem exatamente  $n$  autovvalores de  $A$  (possivelmente com algumas repetições).

### SIMILARIDADE E MUDANÇA DE BASE

Recordação: mudança de base



$$B_1 = \{ \underline{e}_1, \underline{e}_2 \}$$

$$[\underline{x}]_{B_1} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$\underline{x} = x_1 \underline{e}_1 + x_2 \underline{e}_2$$

$$\text{outra base: } B_2 = \{ \underline{\alpha}_1, \underline{\alpha}_2 \}$$

Como escrever  $\underline{x}$  em função de  $\underline{\alpha}_1, \underline{\alpha}_2$ ?  $\underline{x} = x_1' \underline{\alpha}_1 + x_2' \underline{\alpha}_2$

Matriz de mudança de base

$$\begin{aligned} \underline{\alpha}_1 &= \alpha_{11} \underline{e}_1 + \alpha_{21} \underline{e}_2 \\ \underline{\alpha}_2 &= \alpha_{12} \underline{e}_1 + \alpha_{22} \underline{e}_2 \end{aligned} \Rightarrow \underline{x} = x_1' (\alpha_{11} \underline{e}_1 + \alpha_{21} \underline{e}_2) + x_2' (\alpha_{12} \underline{e}_1 + \alpha_{22} \underline{e}_2)$$

Por outro lado, se existir  $S$  invertível tal que  $S^{-1}AS = \Lambda$ , então  $AS = SA \Rightarrow$  as colunas de  $S$  são os autovetores de  $A$ , e formam um conjunto l.i. porque  $S$  é invertível. ■

Falta saber quando os autovetores de uma matriz formam uma base para o espaço todo. Um caso que é relativamente fácil de verificar é dado no seguinte teorema.

Teorema: Se  $\lambda_1, \dots, \lambda_k$  forem autovalores de  $A \in \mathbb{C}^{n \times n}$ , dois a dois distintos, então os autovetores correspondentes  $\{x^{(1)}, \dots, x^{(k)}\}$  formam um conjunto l.i.

Prova: Suponha que  $\{x^{(1)}, \dots, x^{(k)}\}$  sejam l.d. Então existem  $\alpha_1, \dots, \alpha_k$  tais que  $\sum_{i=1}^k \alpha_i x^{(i)} = 0$ .

Em geral, haverá mais de uma sequência  $\{\alpha_1, \dots, \alpha_k\}$  como acima, e haverá também uma com o menor número de elementos,  $\{\beta_i\}_{i=1}^r$  (que vamos assumir, sem perda de generalidade, correspondentes a  $x^{(1)} \dots x^{(r)}$ ):  $\sum_{i=1}^r \beta_i x^{(i)} = 0, r \leq k, r \geq 1$ .

(todos não-nulos) Então, vale também  $0 = A \cdot \sum_{i=1}^r \beta_i x^{(i)} = \sum_{i=1}^r \beta_i \lambda_i x^{(i)}$ ,

$$\begin{aligned} \text{e portanto, } 0 &= \sum_{i=1}^r \beta_i \lambda_i x^{(i)} - \lambda_r \sum_{i=1}^r \beta_i x^{(i)} = \\ &= \sum_{i=1}^r \beta_i (\lambda_i - \lambda_r) x^{(i)} = \sum_{i=1}^{r-1} \beta_i (\lambda_i - \lambda_r) x^{(i)} \end{aligned}$$

Portanto,  $\{\beta_i (\lambda_i - \lambda_r)\}_{i=1}^{r-1}$  é outra sequência com menos elementos  $\beta_i \neq 0$ , que  $\{\beta_i\}_{i=1}^r$ , e que também satisfaz  $\sum_{i=1}^{r-1} (\lambda_i - \lambda_r) \beta_i x^{(i)} = 0$ , contradizendo nossa hipótese.

Concluímos que os autovalores  $\{x^{(1)} \dots x^{(k)}\}$  devem ser linearmente independentes. ■

$$\therefore \underline{x} = (x_1^\alpha \alpha_{11} + x_2^\alpha \alpha_{12}) \underline{e}_1 + (x_1^\alpha \alpha_{21} + x_2^\alpha \alpha_{22}) \underline{e}_2 \quad (2)$$

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \underbrace{\begin{bmatrix} \alpha_{11} & \alpha_{12} \\ \alpha_{21} & \alpha_{22} \end{bmatrix}}_S \begin{bmatrix} x_1^\alpha \\ x_2^\alpha \end{bmatrix} \rightarrow [x]_{B_2} = S^{-1} [x]_{B_1}$$

$S =$  matriz de mudança de base.

Transformação linear  $T: \mathbb{C}^n \rightarrow \mathbb{C}^n$

$$\underline{y} = T \underline{x} \Rightarrow \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = [y]_{B_1} = T \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = T \cdot [x]_{B_1}$$

Como escrever a transformação acima com  $y$  e  $x$  na base  $B_2$ ?

$$S^{-1} [y]_{B_1} = S^{-1} T S \cdot \underbrace{S^{-1} S}_{=I} [x]_{B_1} \Rightarrow [y]_{B_2} = S^{-1} T S \cdot [x]_{B_2}$$

A transformação  $S^{-1} T S$  é chamada transformação de similaridade; diz-se que  $T$  e  $S^{-1} T S$  são matrizes similares.

Uma transformação de similaridade não altera os autovalores de uma matriz:

$$\begin{aligned} \det(sI - A) &= \det(sI - A) \cdot \det(S^{-1} S) = \det(S^{-1} (sI - A) S) \\ &= \det(sI - S^{-1} A S) \end{aligned}$$

Definição: A matriz  $A$  é dita diagonalizável se existir  $S$  invertível tal que

$$S^{-1} A S = \Lambda = \begin{bmatrix} \lambda_1 & & 0 \\ & \lambda_2 & \\ 0 & & \lambda_n \end{bmatrix} = \text{diag}(\lambda_1, \dots, \lambda_n).$$

Teorema: Seja  $A \in \mathbb{C}^{n \times n}$ .  $A$  é diagonalizável se e somente se existir um conjunto de  $n$  autovetores l.i.

Prova: Se  $Ax^{(i)} = \lambda_i x^{(i)}$ , e  $\{x^{(1)}, \dots, x^{(n)}\}$  for l.i.,

a matriz  $S = [x^{(1)} \dots x^{(n)}]$  é não singular (pois tem colunas l.i.), e

$$\begin{aligned} AS &= [Ax^{(1)} \quad Ax^{(2)} \quad \dots \quad Ax^{(n)}] = [\lambda_1 x^{(1)} \quad \lambda_2 x^{(2)} \quad \dots \quad \lambda_n x^{(n)}] \\ &= [x^{(1)} \quad x^{(2)} \quad \dots \quad x^{(n)}] \begin{bmatrix} \lambda_1 & & 0 \\ & \lambda_2 & \\ 0 & & \lambda_n \end{bmatrix} = S \cdot \Lambda \\ \Rightarrow S^{-1} AS &= \Lambda = \text{diag}(\lambda_i) \end{aligned}$$

Segue destes resultados o seguinte teorema:

④

Teorema: Se  $A \in \mathbb{C}^{n \times n}$  tiver  $n$  autovalores distintos, então  $A$  é diagonalizável.

### Multiplicidade de autovalores

Alguns autovalores de uma matriz podem ser repetidos, se o polinômio característico tiver raízes múltiplas.

$$p(s) = (s - \lambda_1)^{k_1} (s - \lambda_2)^{k_2} \dots (s - \lambda_r)^{k_r}$$

$$k_1 + k_2 + \dots + k_r = n$$

$k_i$  é a multiplicidade algébrica do autovalor  $\lambda_i$

Define-se também a multiplicidade geométrica de  $\lambda_i$  como o número de autovetores independentes relacionados a  $\lambda_i$ .

A multiplicidade geométrica é sempre menor ou igual à algébrica. Por exemplo,

$$A = \begin{bmatrix} 0,5 & 1 \\ 0 & 0,5 \end{bmatrix} \rightarrow p(s) = (s - 0,5)^2; \text{ mult. algébrica de } \lambda = 0,5 \text{ é } 2.$$

Os autovetores relativos a  $\lambda = 0,5$  devem satisfazer

$$(0,5I - A)\underline{x} = \underline{0}$$

$$\begin{bmatrix} 0 & -1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \underline{0} \Rightarrow \begin{aligned} x_2 &= 0 \\ x_1 &= \text{qualquer} \end{aligned}$$

$\therefore \underline{x} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$ , não há outro autovetor independente.

Por outro lado,  $A_2 = \begin{bmatrix} 0,5 & 0 \\ 0 & 0,5 \end{bmatrix}$  tem 2 autovetores

l.i.:  $\begin{bmatrix} 1 \\ 0 \end{bmatrix}$  e  $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$ .

## Formas Canônicas (Forma de Jordan)

⑤

Definição: Um bloco de Jordan  $J_k(\lambda)$  é uma matriz triangular superior de dimensão  $k$

$$J_k(\lambda) = \begin{bmatrix} \lambda & 1 & & 0 \\ & \lambda & 1 & \\ & & \ddots & \ddots \\ 0 & & & \lambda \end{bmatrix}$$

Uma matriz de Jordan  $J \in \mathbb{C}^{n \times n}$  é uma soma direta de blocos de Jordan:

$$J = \begin{bmatrix} J_{n_1}(\lambda_1) & & \\ & J_{n_2}(\lambda_2) & \\ & & \ddots \\ & & & J_{n_k}(\lambda_k) \end{bmatrix}$$

(alguns  $\lambda_i$  podem ser repetidos)

Teorema: Toda matriz  $A \in \mathbb{C}^{n \times n}$  é similar a uma matriz de Jordan. Esta última é única no sentido que os blocos de Jordan que a compõe são únicos, apesar da ordem não ser pré-fixada.

Prova: Horn, Matrix Analysis, pp. 122-128. ■

Este resultado é extremamente importante. Apesar de ser quase impossível se calcular na prática a forma de Jordan de uma matriz (trata-se de um problema mal condicionado, como veremos a seguir), a forma de Jordan é muito útil para análises teóricas. Muitas vezes, para se determinar se uma certa hipótese (ideia) vale para todas as matrizes  $A \in \mathbb{C}^{n \times n}$ , é mais fácil pensar se a ideia funciona para qualquer possível matriz na forma de Jordan.

(6)  
A forma de Jordan não é uma "função" contínua dos elementos de uma matriz (daí a dificuldade de calcular numericamente a forma de Jordan). Por exemplo, considere

$$A_\varepsilon = \begin{bmatrix} \varepsilon & 0 \\ 1 & 0 \end{bmatrix}. \quad \text{Para } \varepsilon \neq 0, \text{ então}$$

$$A_\varepsilon = \underbrace{\begin{bmatrix} 0 & \varepsilon \\ 1 & 1 \end{bmatrix}}_{= S_\varepsilon} \underbrace{\begin{bmatrix} 0 & 0 \\ 0 & \varepsilon \end{bmatrix}}_{= J_\varepsilon} \underbrace{\begin{bmatrix} -1/\varepsilon & +1 \\ +1/\varepsilon & 0 \end{bmatrix}}_{= S_\varepsilon^{-1}}$$

$J_\varepsilon$  tem dois blocos:  $J_1(0)$  e  $J_1(\varepsilon)$  ( $A_\varepsilon$  é diagonalizável).

No entanto, para  $\varepsilon = 0$   $A_0 = \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}$ , que tem forma de Jordan  $J_0 = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}$  (use  $S_0 = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ ).  $J_0$

possui apenas um bloco de Jordan,  $J_2(0)$ .

Fato: Os autovalores de uma matriz  $A \in \mathbb{C}^{n \times n}$  são funções contínuas dos elementos de  $A$ . (A prova requer análise complexa - não é tão difícil ver que os coeficientes do polinômio característico são funções contínuas dos elementos da matriz).

→ Veja o exemplo anterior para notar que o mesmo não vale para os autovetores da matriz.

