

## Autovalores e Autovetores

Considere uma matriz quadrada  $A_m$ , um escalar  $r \in \mathbb{R}$  e um vetor  $v \in \mathbb{R}^m$  com a seguinte propriedade:

$$A \cdot v = r \cdot v$$

Dizemos então que  $r$  é um *autovalor* e  $v$  é um *autovetor* da matriz  $A$ .

(Atenção:  $v$  é um vetor, e portanto não podemos 'cortar'  $v$  dos dois lados dessa equação: 'cortar' é uma operação de divisão, que na álgebra matricial corresponde a multiplicar por uma inversa, mas vetores não admitem inversa.)

Note que  $v = (I \cdot v)$ : a matriz identidade é o elemento neutro da multiplicação matricial. Logo,  $A \cdot v = r(I \cdot v)$ .

Portanto:

$$A \cdot v - r(I \cdot v) = 0$$

$$(A - r \cdot I)v = 0$$

Se  $v \neq 0$ , então a matriz  $(A - r \cdot I)$  não pode admitir inversa ( $A - rI$  deve ser portanto uma matriz *singular*). Caso contrário, poderíamos multiplicar os dois lados da equação acima pela inversa  $(A - r \cdot I)^{-1}$ , levando ao seguinte resultado absurdo:

$$0 \neq v = (A - r \cdot I)^{-1} \cdot 0 = 0$$

(A última igualdade ocorre porque qualquer matriz multiplicada por um vetor de zeros gera um vetor de zeros).

Para que a matriz  $A - rI$  não admita inversa, então necessariamente  $\det(A - r \cdot I) = 0$ . Para calcular esse determinante, construa a matriz  $A - rI$ :

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mm} \end{pmatrix}$$
$$A - r \cdot I = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mm} \end{pmatrix} - r \cdot \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & 1 \end{pmatrix}$$
$$A - r \cdot I = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mm} \end{pmatrix} - \begin{pmatrix} r & 0 & \cdots & 0 \\ 0 & r & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & r \end{pmatrix}$$

$$A - r.I = \begin{pmatrix} a_{11} - r & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} - r & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mm} - r \end{pmatrix}$$

Ou seja: o autovalor  $r \in \mathbb{R}$  é um número que quando subtraído da diagonal principal de uma matriz, a transforma em uma matriz singular.

Exemplo:

$$A = \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix}$$

$$r = 2 \rightarrow A - r.I = \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix} \Rightarrow \det = 0$$

$$r = 3 \rightarrow A - r.I = \begin{pmatrix} -1 & 0 \\ 0 & 0 \end{pmatrix} \Rightarrow \det = 0$$

Logo,  $r = 2$  e  $r = 3$  são autovalores de  $A$ .

Os elementos da diagonal principal de uma matriz *diagonal* são os próprios autovalores: isso vale para qualquer matriz diagonal. Note ainda que  $r = 0$  sempre é autovalor de uma matriz singular.

Exemplo:

$$A = \begin{pmatrix} 1 & 1 \\ 2 & 2 \end{pmatrix} \text{ singular.}$$

$$r = 0 \rightarrow A - r.I = \begin{pmatrix} 1 & 1 \\ 2 & 2 \end{pmatrix} \text{ singular}$$

Para encontrar os autovalores de uma matriz qualquer, usamos o polinômio característico dessa matriz. Considere uma matriz genérica de ordem 2:

$$A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$$

$$A - r.I = \begin{pmatrix} a_{11} - r & a_{12} \\ a_{21} & a_{22} - r \end{pmatrix}$$

$\det(A - r.I) = 0$  é a condição para  $r$  ser autovalor:

$$(a_{11} - r)(a_{22} - r) - a_{12}a_{21} = 0$$

$$\underbrace{r^2 - (a_{11} + a_{22})r + (a_{11}a_{22} - a_{12}a_{21})}_{\text{polinômio característico}} = 0$$

Uma equação de 2º grau tem até duas raízes distintas; logo, uma matriz 2x2 tem até dois autovalores distintos. Uma matriz  $m \times m$  tem até  $m$  autovalores distintos: as raízes do polinômio característico de ordem  $m$ .

Para encontrar o autovetor  $v^*$  associado ao autovalor  $r^*$ , basta resolver o sistema linear  $(A - r^*I) \cdot v^* = 0$  para  $v^* \neq 0$ . Observe que esse é um sistema linear *homogêneo* com matriz de coeficientes singular (determinante é zero): logo, há infinitas soluções. Em outras palavras, há infinitos autovetores associados a um dado autovalor.

Exemplo:

$$(i) A = \begin{pmatrix} -1 & 3 \\ 2 & 0 \end{pmatrix}$$

$$\det(A - rI) = \det \begin{pmatrix} -1-r & 3 \\ 2 & -r \end{pmatrix} = r^2 + r - 6 : \text{polinômio característico.}$$

$$r^2 + r - 6 = 0 : \text{condição para } r \text{ ser autovalor.}$$

Raízes:  $r_1 = -3, r_2 = 2$  : autovalores (reais e distintos) de  $A$ .

Autovetor  $v_1$  associado a  $r_1$ :

$$(A - r_1I) = \begin{pmatrix} -1 - (-3) & 3 \\ 2 & -(-3) \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$\begin{pmatrix} 2 & 3 \\ 2 & 3 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Rightarrow 2x + 3y = 0 \Rightarrow y = -\frac{2}{3}x$ : todos os pares  $(x, y)$  que respeitem essa equação são um autovetor da matriz  $A$  associado ao autovalor  $-3$ .

Em particular,  $x = 1 \Rightarrow y = -\frac{2}{3}$  :  $v_1 = (1, -\frac{2}{3})$  é um autovetor associado a  $r_1 = -3$ . Qualquer múltiplo de  $v_1$  é um autovetor associado a  $r_1$  (há sempre infinitos autovetores associados a um dado autovalor).

Autovetor  $v_2$  associado a  $r_2$ :

$$(A - r_2I)v = \begin{pmatrix} -1-2 & 3 \\ 2 & -2 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$\begin{pmatrix} -3 & 3 \\ 2 & -2 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Rightarrow -3x + 3y = 0 \Rightarrow y = x$$

Em particular,  $x = 1 \Rightarrow y = 1$  :  $v_2 = (1, 1)$  é um autovetor associado a  $r_2 = 2$ . Qualquer múltiplo de  $v_2$  é um autovetor associado a  $r_2$ .

Conclusão: autovetor não é único.

Para concluir, defina o traço de uma matriz quadrada como a soma dos elementos da diagonal principal:

$$Tr(A) = a_{11} + a_{22} + \dots + a_{mm}$$

Teorema: Considere a matriz quadrada  $A_m$  com autovalores  $r_1, \dots, r_m$ .

$$(i) r_1 + r_2 + \dots + r_m = a_{11} + a_{22} + \dots + a_{mm} = Tr(A)$$

$$(ii) r_1 \cdot r_2 \cdot \dots \cdot r_m = \det(A)$$

## Formas Quadráticas

Formas quadráticas são uma generalização das funções quadráticas univariadas  $y = x^2$ . Permitimos agora que o domínio seja  $\mathbb{R}^n$ .

Uma forma quadrática  $Q : \mathbb{R}^n \rightarrow \mathbb{R}$  admite representação matricial. Podemos defini-la da seguinte forma:

$$Q : \mathbb{R}^n \longrightarrow \mathbb{R}$$

$$Q(x) = x^T A x$$

em que  $A$  é uma matriz quadrada de ordem  $n$ , e  $x \in \mathbb{R}^n$  (ou seja,  $x$  é um vetor coluna com  $n$  coordenadas). Há infinitas matrizes que podem ser usadas para representar uma forma quadrática; escolheremos sempre uma matriz simétrica.

Exemplo:  $Q : \mathbb{R} \longrightarrow \mathbb{R} : Q(x) = ax$ . Como o domínio é unidimensional ( $n = 1$ ), a matriz  $A$  tem ordem 1, ou seja, tem apenas uma linha e uma coluna:  $A = [a]$ . Podemos escrever  $Q(x) = ax = Ax$ . Observe que se  $a > 0$ , temos uma parábola 'virada para cima' que passa pelo ponto  $(0, 0)$ ; se  $a < 0$ , temos uma parábola 'virada para baixo'.

$$\text{Exemplo: } Q : \mathbb{R}^2 \rightarrow \mathbb{R} : Q(x_1, x_2) = a_{11}x_1^2 + bx_1x_2 + a_{22}x_2^2$$

$$Q = \begin{bmatrix} x_1 & x_2 \end{bmatrix} \begin{bmatrix} a_{11} & \frac{b}{2} \\ \frac{b}{2} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

Observe que podemos escolher outras matrizes para representar a forma quadrática acima. Considere uma matriz qualquer de ordem 2:

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$$

Obtemos então:

$$\begin{bmatrix} x_1 & x_2 \end{bmatrix} \cdot A \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = a_{11}x_1^2 + (a_{12} + a_{21})x_1 \cdot x_2 + a_{22}x_2^2$$

Logo, podemos escolher quaisquer elementos  $a_{12}$  e  $a_{21}$  tais que  $a_{12} + a_{21} = b$ . Como queremos usar uma matriz simétrica, fazemos  $a_{12} = a_{21} = \frac{b}{2}$ .

## Definição de formas quadráticas

Note que uma forma quadrática não tem termo independente de  $x$ . Logo,  $Q(0) = 0$  (observe que o 'zero' no domínio é, na verdade, a origem de  $\mathbb{R}^n$ : ou seja, é um vetor de zeros). Questão:  $x = 0$  é um ponto de máximo, de mínimo, ou nenhum dos dois?

Em uma dimensão:  $Q(x) = ax^2$ . Se  $a > 0$ ,  $x = 0$  é um ponto de mínimo, e  $Q > 0$  para todo  $x \neq 0$ . (represente graficamente essa função). Dizemos que a forma quadrática  $Q$  é positiva definida. Se  $a < 0$ ,  $x = 0$  é um ponto de máximo, e  $Q < 0$  para todo  $x \neq 0$ . Dizemos que a forma quadrática  $Q$  é, nesse caso, negativa definida.

Podemos estender o raciocínio para duas ou mais dimensões. Se  $(x_1, x_2, \dots, x_n) \neq (0, \dots, 0) \Rightarrow Q > 0$ , então  $Q$  é positiva definida. Exemplo:  $Q(x_1, x_2) = x_1^2 + x_2^2$

Se  $(x_1, x_2, \dots, x_n) \neq (0, \dots, 0) \Rightarrow Q < 0$ , então  $Q$  é negativa definida. Exemplo:  $Q(x_1, x_2) = -x_1^2 - x_2^2$

Se uma função quadrática pode assumir valores positivos ou negativos, é dita indefinida. Exemplo: Exemplo:  $Q(x_1, x_2) = x_1^2 - x_2^2$ . Note que  $Q(1, 0) > 0$  e  $Q(0, 1) < 0$ .

Se uma forma quadrática nunca assume valores negativos, mas pode ser igual a 0 para  $x \neq 0$ , é dita positiva semi-definida. Exemplo:  $Q = x_1^2 + 2x_1x_2 + x_2^2 = (x_1 + x_2)^2$ . Note que  $Q(1, -1) = 0$ .

Analogamente, a matriz negativa semi-definida nunca assume valores positivos, mas pode valer zero fora da origem. Exemplo:  $-(x_1 + x_2)^2$

Podemos definir a matriz  $A$  a partir das propriedades da forma quadrática  $Q(x) = x^T Ax$ ,  $x \in \mathbb{R}^m$ . Seja  $A_m$  simétrica. Então  $A$  é:

- a) Positiva Definida se  $x^T Ax > 0 \forall x \neq 0$ .
- b) Positiva Semi-Definida se  $x^T Ax \geq 0 \forall x \neq 0$ .
- c) Negativa Definida se  $x^T Ax < 0 \forall x \neq 0$ .
- d) Negativa Semi-Definida se  $x^T Ax \leq 0 \forall x \neq 0$ .
- e) Indefinida caso não se encaixe em nenhum dos casos anteriores.

### Teste para Definição de Matriz

Relembrando: *menores* são os determinantes de *submatrizes* formadas a partir da eliminação de determinadas linhas e colunas de uma matriz  $A$ . Se forem retiradas linhas e colunas de mesmo índice, temos um *menor principal* (por exemplo, se excluímos a linha 1 e a coluna 1).

Exemplo:  $A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$

Menor principal de ordem 2:  $\text{Det}(A)$

Menores principais de ordem 1:  $\text{Det}(a_{11}) = a_{11}$  (determinante da submatriz formada pela eliminação da linha 2 e da coluna 2) e  $\text{Det}(a_{22}) = a_{22}$  determinante da submatriz formada pela eliminação da linha 1 e da coluna 1

Exemplo:  $A = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$

Menor principal de ordem 3:  $\text{Det}(A)$ .

Menores principais de ordem 2:

$\det \left( \begin{bmatrix} a_{22} & a_{23} \\ a_{32} & a_{33} \end{bmatrix} \right)$ , obtido pela eliminação da linha 1 e da coluna 1;

$\det \left( \begin{bmatrix} a_{11} & a_{13} \\ a_{31} & a_{33} \end{bmatrix} \right)$ , obtido pela eliminação da linha 2 e da coluna 2;

$\det \left( \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \right)$ , obtido pela eliminação da linha 3 e da coluna 3.

Menores principais de ordem 1:

$\det(a_{33})$ , obtido pela eliminação das linhas/colunas 1 e 2;

$\det(a_{22})$ , obtido pela eliminação das linhas/colunas 1 e 3;

$\det(a_{11})$ , obtido pela eliminação das linhas/colunas 2 e 3.

Os menores principais mais usados , para cada ordem, são formados por eliminação das *últimas* linhas e colunas. São conhecidos como Menores Principais Líderes (MPL's):

$$a_{11}, \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}, \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

Teorema: Seja  $A$  uma matriz quadrada simétrica de ordem  $n$ . Então:

- 1 -  $A$  é positiva definida se e só se todos os MPL's são estritamente positivos.
- 2 -  $A$  é negativa definida se e só se os MPL's alterarem de sinal, começando com o sinal negativo:  $A_1 < 0, A_2 > 0, \dots$

Exemplos:

$$1 - \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \quad A_1 = 2 > 0, A_2 = 2 \times 2 - 1 \times 1 = 3 > 0 : \text{P.D}$$

$$2 - \begin{bmatrix} -1 & -2 \\ 2 & 1 \end{bmatrix} \quad A_1 = -1 < 0, A_2 = (-1) \times 1 - 2 \times (-2) = 3 > 0 : \text{N.D}$$

$$3 - \begin{bmatrix} 2 & 3 \\ 3 & 7 \end{bmatrix} \quad A_1 = 2 > 0, A_2 = 2 \times 7 - 3 \times 3 = 5 > 0 : \text{P.D}$$

$$4 - Q = x_1^2 + x_2^2 = [x_1 \ x_2] \underbrace{\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}}_A [x_1 \\ x_2] = [x_1 \ x_2] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$A_1 = 1 > 0, A_2 = 1 \times 1 - 0 \times 0 = 1 > 0 : \text{P.D.}$$

$$5 - Q = -x_1^2 - x_2^2 = [x_1 \ x_2] \underbrace{\begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix}}_A [x_1 \\ x_2] = [-x_1 \ -x_2] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$A_1 = -1 < 0, A_2 = (-1) \times (-1) - 0 \times 0 = 1 > 0 : \text{N.D}$$

Para checar se a matriz é semi-definida , são necessários todos os menores principais, não apenas os líderes.

## Matrizes Diagonais

Considere uma matriz diagonal qualquer:

$$A = \begin{bmatrix} a_1 & 0 & \cdots & 0 \\ 0 & a_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & a_n \end{bmatrix}$$

Essa matriz representa a forma quadrática  $Q = a_1x_1^2 + \cdots + a_nx_n^2$ , em que não há produtos cruzados. Observe então que  $A$  é:

- i- positiva definida se  $a_i > 0 \forall i$ .
- ii- positiva semi-definida se  $a_i \geq 0 \forall i$ .
- iii- negativa definida se  $a_i < 0 \forall i$ .
- iv- negativa semi-definida se  $a_i \leq 0 \forall i$ .
- v- indefinida se existe  $a_i > 0$  e  $a_j < 0$ .

Note que, para uma matriz positiva definida, temos:  $a_1 > 0$ ;  $a_1 \cdot a_2 > 0$ ;  $a_1 \cdot a_2 \cdot a_3 > 0$ , ...: o produto de números positivos é sempre positivo. Já para a matriz negativa definida, temos:  $a_1 < 0$ ;  $a_1 \cdot a_2 > 0$ ;  $a_1 \cdot a_2 \cdot a_3 < 0$ , ...: o produto é negativo quando multiplicamos um número ímpar de números negativos, mas é positivo quando multiplicamos um número par de termos (o produto de dois números negativos é positivo). O teorema anterior generaliza essa relação para matrizes não-diagonais.

Para uma matriz diagonal, os elementos da diagonal principal são exatamente seus autovalores. Logo, uma matriz diagonal é positiva definida se e só se todos os autovalores são estritamente positivos, e positiva semi-definida caso sejam maiores ou iguais a zero. Analogamente, será negativa definida se e só se todos os autovalores forem estritamente negativos.

É possível provar que esse resultado vale para quaisquer matrizes, e não apenas para as diagonais: podemos avaliar a definição de uma forma quadrática a partir dos autovalores da matriz que a representa.

## Equações e Sistemas de Diferença

### Equações de Diferença

Um exemplo de equação de diferença é:

$$y_{n+1} = a \cdot y_n$$

Em que  $a$  é uma constante qualquer. O valor de  $y$  em um período é igual ao seu valor no período anterior multiplicado por essa constante.

Essa equação descreve, por exemplo, o retorno de um investimento sem risco. Ao investir uma quantia  $y_n$  no período  $n$ , obtemos um valor de juros de  $\rho \cdot y_n$ . Temos então no próximo período:

$$y_{n+1} = y_n + \rho \cdot y_n = (1 + \rho)y_n \quad (1)$$

Fazendo  $1 + \rho = a$ , obtemos a equação anterior.

Para resolver essa equação, precisamos conhecer o valor inicial  $y_0$ . Então:

$$\begin{aligned} y_1 &= ay_0 \\ y_2 &= ay_1 = a(ay_0) = a^2y_0 \\ y_3 &= ay_2 = a(a^2y_0) = a^3y_0 \end{aligned} \quad (2)$$

E assim em diante. A solução geral é  $y_n = a^n y_0$ . Se  $|a| < 1$ , então o sistema é *estável*: converge para zero quando  $n$  aumenta.

### Sistema de Diferenças: Duas Equações

Considere agora o sistema formado pelas duas equações abaixo:

$$\begin{aligned} x_{n+1} &= a \cdot x_n + b \cdot y_n \\ y_{n+1} &= c \cdot x_n + d \cdot y_n \end{aligned} \quad (3)$$

Esse sistema pode ser representado em forma matricial. Defina:

$$z_n = \begin{bmatrix} x_n \\ y_n \end{bmatrix} \quad (4)$$

$$A = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \quad (5)$$

Podemos então escrever:

$$z_{n+1} = A \cdot z_n \quad (6)$$

Para verificar que essa representação está de acordo com o sistema original, basta fazer a multiplicação:

$$\begin{bmatrix} x_{n+1} \\ y_{n+1} \end{bmatrix} = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \cdot \begin{bmatrix} x_n \\ y_n \end{bmatrix} = \begin{bmatrix} ax_n + by_n \\ cx_n + dy_n \end{bmatrix} \quad (7)$$

Se  $b = c = 0$ , as equações não são relacionadas, e temos apenas:

$$\begin{aligned} x_{n+1} &= ax_n \\ y_{n+1} &= dy_n \end{aligned} \quad (8)$$

As soluções já foram estabelecidas nesse caso:  $x_n = a^n x_0$  e  $y_n = d^n y_0$ . *Esse é o caso geral para matrizes diagonais.*

Para resolver o caso geral, em que as equações podem ser relacionadas (ou seja,  $b \neq 0$  ou  $c \neq 0$ ), precisamos considerar um vetor inicial  $z_0 = \begin{bmatrix} x_0 \\ y_0 \end{bmatrix}$ .

Temos então:

$$\begin{aligned} z_1 &= Az_0 \\ z_2 &= Az_1 = A^2 z_0 \\ &\vdots \\ z_n &= A^n z_0 \end{aligned} \quad (9)$$

Precisamos então computar  $A^n$ . Se  $A = D$  é uma matriz diagonal, essa conta é fácil:

$$D \cdot D = \begin{bmatrix} r_1 & 0 \\ 0 & r_2 \end{bmatrix} \cdot \begin{bmatrix} r_1 & 0 \\ 0 & r_2 \end{bmatrix} = \begin{bmatrix} r_1^2 & 0 \\ 0 & r_2^2 \end{bmatrix} \quad (10)$$

Podemos estender esse raciocínio:

$$D^n = \begin{bmatrix} r_1^n & 0 \\ 0 & r_2^n \end{bmatrix} \quad (11)$$

Precisamos então de uma matriz não-singular  $P$  tal que  $P^{-1}AP$  seja uma matriz diagonal, que denotaremos por  $D$ . Nesse caso,  $A = PDP^{-1}$ , e portanto:

$$\begin{aligned} A^2 &= (PDP^{-1})(PDP^{-1}) = (PD)(P^{-1}P)(DP^{-1}) \\ &= (PD)I(DP^{-1}) = (PD)(DP^{-1}) = P(D^2)P^{-1} \end{aligned} \quad (12)$$

De forma geral:

$$A^n = P(D^n)P^{-1} \quad (13)$$

Ou seja:

$$A^n = P \begin{bmatrix} r_1^n & 0 \\ 0 & r_2^n \end{bmatrix} P^{-1} \quad (14)$$

A solução do sistema é portanto:

$$z_n = \underbrace{[P \begin{bmatrix} r_1^n & 0 \\ 0 & r_2^n \end{bmatrix} P^{-1}]}_{A^n} z_0 \quad (15)$$

Para obter  $P$  e  $D$ , escreva  $P = [v_1 \ v_2]$ , em que  $v_1$  e  $v_2$  representam as colunas de  $P$ .  $P^{-1}AP = D$  pode ser reescrito como  $AP = PD$ . Ou seja:

$$A[v_1 \ v_2] = [v_1 \ v_2] \begin{bmatrix} r_1 & 0 \\ 0 & r_2 \end{bmatrix} \quad (16)$$

Ou ainda:

$$[Av_1 \ Av_2] = [r_1v_1 \ r_2v_2] \quad (17)$$

Logo,  $Av_1 = r_1v_1$  e  $Av_2 = r_2v_2$ . Mas isso significa que  $r_1$  e  $r_2$  são autovalores de  $A$ , e  $v_1$  e  $v_2$  são os autovetores associados.

Para construir a solução explicitamente:

$$\begin{aligned} z_n &= A^n z_0 \\ z_n &= PD^n P^{-1} z_0 \\ P^{-1} z_n &= P^{-1} PD^n P^{-1} z_0 \\ P^{-1} z_n &= ID^n P^{-1} z_0 \\ P^{-1} z_n &= D^n P^{-1} z_0 \end{aligned} \quad (18)$$

Defina agora  $Z_n = P^{-1} z_n = P^{-1} \begin{bmatrix} x_n \\ y_n \end{bmatrix}$ . Logo,  $Z_n = D_n Z_0$ . Como  $D^n$  é diagonal, conseguimos encontrar a solução. Para tanto, defina  $X_n$  como a primeira linha de  $Z_n$ , e  $Y_n$  como a segunda linha:

$$\begin{aligned} X_n &= c_1 r_1^n \\ Y_n &= c_2 r_2^n \end{aligned} \quad (19)$$

Em que  $c_1$  e  $c_2$  são as condições iniciais das variáveis artificiais  $X_n$  e  $Y_n$ , respectivamente (se  $n = 0$ ,  $X_n = c_1$ , pois  $r_1^0 = 1$ ).

Para recuperar  $z_n$ , fazemos:

$$z_n = \begin{bmatrix} x_n \\ y_n \end{bmatrix} = P \begin{bmatrix} X_n \\ Y_n \end{bmatrix} = [v_1 \ v_2] \begin{bmatrix} c_1 r_1^n \\ c_2 r_2^n \end{bmatrix} = c_1 r_1^n v_1 + c_2 r_2^n v_2 \quad (20)$$

Ou seja, temos uma combinação linear dos autovetores de  $A$  em que os coeficientes dependem das condições iniciais e dos autovalores correspondentes.

Observe então que o sistema é estável se ambos os autovalores são menores do que um em módulo: nesse caso,  $r_i^n$  se aproxima de zero quando  $n$  aumenta.

Considere o seguinte exemplo:

$$\begin{aligned}x_{n+1} &= x_n + 4y_n \\y_{n+1} &= 0.5x_n\end{aligned}\tag{21}$$

Temos então a seguinte matriz de coeficientes:

$$A = \begin{bmatrix} 1 & 4 \\ 0.5 & 0 \end{bmatrix}$$

Os autovalores dessa matriz são 2 e  $-1$ . Os autovetores correspondentes são  $(1, \frac{1}{4})$  e  $(1, \frac{-1}{2})$ .

A solução é portanto:

$$\begin{bmatrix} x_n \\ y_n \end{bmatrix} = c_1 \cdot 2^n \cdot \begin{bmatrix} 1 \\ \frac{1}{4} \end{bmatrix} + c_2 \times (-1)^n \cdot \begin{bmatrix} 1 \\ \frac{-1}{2} \end{bmatrix}\tag{22}$$

Em que  $c_1$  e  $c_2$  dependem das condições iniciais, como veremos abaixo.

Ou seja:

$$\begin{aligned}x_n &= c_1 \cdot 2^n + c_2 \cdot (-1)^n \\y_n &= \frac{c_1 \cdot 2^n}{4} - \frac{c_2 \cdot (-1)^n}{2}\end{aligned}\tag{23}$$

Para determinar as constantes  $c_1$  e  $c_2$ , precisamos do vetor inicial  $(x_0, y_0)$ . Fazendo  $n = 0$  nas equações acima, obtemos:

$$\begin{aligned}x_0 &= c_1 + c_2 \\y_0 &= \frac{c_1}{4} - \frac{c_2}{2}\end{aligned}\tag{24}$$

Resolvendo esse sistema, obtemos:

$$\begin{aligned}c_1 &= \frac{x_0}{6} + \frac{y_0}{3} \\c_2 &= \frac{-x_0}{6} + \frac{2y_0}{3}\end{aligned}\tag{25}$$

A solução fica então inteiramente caracterizada. Se, por exemplo,  $x_0 = 2$  e  $y_0 = -\frac{1}{4}$ , encontramos  $c_1 = c_2 = 1$ , e portanto a solução do sistema é:

$$\begin{aligned}x_n &= 2^n + (-1)^n \\y_n &= \frac{2^n}{4} - \frac{(-1)^n}{2}\end{aligned}\tag{26}$$

Observe que o sistema não é estável porque os autovalores não são inferiores a 1 em módulo.

## Processos de Markov

Considere uma variável  $S$  que pode assumir  $k$  valores:  $S_1, S_2, \dots, S_k$ . Cada um desses valores é chamado *estado*. Por exemplo, um indivíduo no mercado de trabalho pode ser classificado como empregado ou desempregado.

*Definição:* um *Processo Estocástico* é uma regra que determina a probabilidade de que uma variável esteja no estado  $i$  no período  $n + 1$ , dadas as probabilidades de que estivesse em cada um dos  $k$  estados possíveis nos períodos anteriores  $(1, 2, \dots, n)$ .

*Definição:* um *Processo de Markov* é um processo estocástico em que a probabilidade de cada estado no período  $n + 1$  depende apenas do estado em  $n$ : só o passado imediato importa.

Os objetos centrais para descrever um processo de Markov são:

1- As probabilidades  $x_i(n)$  de que o estado  $i$  ocorra no período  $n$  (interpretado como a fração da população total nesse estado, nesse período);

2- Probabilidades de transição:  $m_{ij} = \text{Prob}[S_i(n+1) \text{ dado } S_j(n)]$ .

Podemos fazer uma representação matricial das probabilidades de transição:

$$M = \begin{bmatrix} m_{11} & \dots & m_{1k} \\ \vdots & & \vdots \\ m_{k1} & \dots & m_{kk} \end{bmatrix}$$

Essa é chamada matriz de transição, ou estocástica, ou ainda matriz de Markov. Observe que pela definição de  $m_{ij}$ , o primeiro subscrito indica o estado no *próximo período*, e o segundo subscrito indica o estado *no período atual*. Logo, a soma de cada coluna deve ser igual a um: há 100% de chance de estar em *algum* estado, em cada período.

As probabilidades  $m_{ij}$  são fixas, independentes do período  $n$ . São ditas estacionárias.

Se  $N$  é a população total e  $x^j(n)$  é a fração dessa população no estado  $j$  no período  $n$  (por exemplo, taxa de desemprego), o número de pessoas nesse estado, nesse período, é  $x^j(n) \cdot N$  (número de desempregados).

Por construção,  $m_{ij} \cdot x^j(n) \cdot N$  indivíduos estarão no estado  $i$ , no período  $n + 1$ . Logo, o número total de indivíduos no estado  $i$ , em  $n + 1$ , será:

$$\sum_{j=1}^k m_{ij} \cdot x^j(n) \cdot N$$

Por exemplo: o número total de desempregados no período  $n + 1$  é a soma de (i) desempregados em  $n$  que continuaram desempregados; (ii) empregados em  $n$  que perderam o emprego.

Novamente, podemos usar uma notação matricial.

$$\begin{bmatrix} x^1(n+1) \\ \vdots \\ x^k(n+1) \end{bmatrix} = \begin{bmatrix} m_{11} & \dots & m_{1k} \\ \vdots & & \vdots \\ m_{k1} & \dots & m_{kk} \end{bmatrix} \begin{bmatrix} x^1(n) \\ \vdots \\ x^k(n) \end{bmatrix}$$

Ou seja:  $x(n+1) = M \cdot x(n)$ . Trata-se de um sistema de diferenças.

Exemplos: economia do trabalho: há apenas dois estados, empregado (com fração  $x^1(n)$ ) ou desempregado (com fração  $x^2(n)$ ).

$$\begin{bmatrix} x^1(n+1) \\ x^2(n+1) \end{bmatrix} = \underbrace{\begin{bmatrix} 0.9 & 0.4 \\ 0.1 & 0.6 \end{bmatrix}}_M \begin{bmatrix} x^1(n) \\ x^2(n) \end{bmatrix}$$

Interpretação: há 90% de chance de um empregado continuar empregado, e 10% de chance de perder o emprego; há 60% de chance de um desempregado continuar desempregado, e 40% de chance de conseguir emprego.

Observe que  $r_1 = 1$  é autovalor de  $M$  (o que é sempre verdade para matrizes de Markov). Subtraindo de cada termo da diagonal principal de  $M$ , obtemos:

$$M - 1 \cdot I = \begin{bmatrix} -0.1 & 0.4 \\ 0.1 & -0.4 \end{bmatrix}$$

Essa matriz é singular (o determinante é igual a zero). Use agora a propriedade de que o traço é igual à soma dos termos da diagonal principal de  $M$ :

$$a_{11} + a_{22} = r_1 + r_2$$

$$0.9 + 0.6 = 1 + r_2$$

Logo,  $r_2 = 0.5$ .

Podemos agora obter os autovalores. Para  $r_1 = 1$ :

$$\begin{bmatrix} -0.1 & 0.4 \\ 0.1 & -0.4 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \implies 0.1 \cdot x = 0.4 \cdot y \implies x = 4y$$

Logo, o autovalor é  $(4, 1)$ . Analogamente, obtemos para  $r_2 = 0.5$ :

$$\begin{bmatrix} 0.4 & 0.4 \\ 0.1 & 0.1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \implies x = y$$

Logo, o autovetor associado a  $r_2 = 0.5$  é  $(1, -1)$ .

Podemos então escrever a solução geral do sistema de diferenças:

$$\begin{bmatrix} x^1(n) \\ x^2(n) \end{bmatrix} = c_1 \begin{bmatrix} 4 \\ 1 \end{bmatrix} \cdot 1^n + c_2 \begin{bmatrix} 1 \\ -1 \end{bmatrix} \cdot (0.5)^n$$

Como  $|0.5| < 1$ , concluímos que quando  $n \rightarrow \infty$ , o sistema converge para:

$$\begin{bmatrix} x^1(n) \\ x^2(n) \end{bmatrix} \rightarrow c_1 \cdot \begin{bmatrix} 4 \\ 1 \end{bmatrix} = \begin{bmatrix} 4c_1 \\ c_1 \end{bmatrix}$$

Como estamos trabalhando com um vetor de probabilidades, que devem somar um, podemos fazer  $4c_1 + c_1 = 1 \implies c_1 = 0.2$ . Concluímos então que o sistema converge para:

$$(0.8 \ 0.2)$$

Ou seja, o desemprego de longo prazo é 20%.

O exemplo anterior usa uma matriz de transição *positiva*: todos os elementos são estritamente positivos. De forma mais geral, dizemos que uma matriz  $M$  de Markov é *regular* se existe um número inteiro  $r$  tal que  $M^r$  é positiva. Podemos provar para matrizes regulares:

- a-  $r_1 = 1$  é autovalor de  $M$ ;
- b- os demais autovalores são menores que um em módulo;
- c- todas as entradas do autovetor  $w_1$  associado ao autovalor  $r_1 = 1$  são estritamente positivas;
- d- se  $v_1$  é o vetor  $w_1$  dividido pela soma das suas coordenadas, concluímos que  $x(n) \rightarrow v_1$  quando  $n \rightarrow \infty$ .

Se existe  $m_{ii} = 1$ , então  $S_i$  é dito estado absorvente: uma vez atingido, o sistema não muda mais.

## Matrizes Simétricas

Grande parte das matrizes em otimização e econometria (principais aplicações de Álgebra Linear em economia) são simétricas: Hessiana, matriz de variância-covariância, matriz de informação, entre outras. Temos o seguinte resultado:

*Teorema:* Se  $A$  é simétrica de ordem  $k$ , então:

- a- Todos os autovalores são reais;
- b- Autovetores associados a diferentes autovalores são ortogonais;
- c- Existe uma matriz  $P$  não-singular, cujas colunas  $w_1, \dots, w_k$  são os autovetores de  $A$ , tal que: (i)  $w_1, \dots, w_k$  são ortogonais; (ii)  $P^{-1} = P^T$ ; (iii)  $P^{-1}AP = P^TAP$  é uma matriz diagonal cujos elementos (na diagonal principal) são os autovalores de  $A$ . (Esse resultado vale mesmo que  $A$  tenha autovalores repetidos.)

Dizemos que  $P$  é uma matriz ortonormal:  $P^{-1} = P^T$ .

## Espaço Vetorial (SB 27)

O espaço euclidiano  $\mathbb{R}^n$  é um espaço vetorial porque admite duas operações naturais: soma e multiplicação por escalar, que respeitam uma série de propriedades, descritas abaixo.

Seja  $V$  um espaço vetorial qualquer. Sejam  $u, v, w$  elementos desse espaço:  $u, v, w \in V$ . Sejam  $r$  e  $s$  escalares:  $r, s \in \mathbb{R}$ . As seguintes propriedades devem valer para que  $V$  seja um E.V:

- (i)  $u + v \in V$ :  $V$  é fechado para adição vetorial.
- (ii)  $u + v = v + u$
- (iii)  $u + (v + w) = (u + v) + w$
- (iv) Existe um elemento nulo  $0$  /  $v + 0 = v$
- (v) Para todo  $v$ , existe um elemento  $-v \in V$  /  $v + (-v) = 0$
- (vi) Para todo escalar  $r$ ,  $r \cdot v \in V$ :  $V$  é fechado para multiplicação por escalar.
- (vii)  $r \cdot (u + v) = r \cdot u + r \cdot v$
- (viii)  $(r + s) \cdot u = r \cdot u + s \cdot u$
- (ix)  $r \cdot (s \cdot u) = (r \cdot s) \cdot u$
- (x)  $1 \cdot u = u$

Exemplos de espaços vetoriais (além de  $\mathbb{R}^n$ ):

- Conjunto das sequências infinitas de números reais, com as operações de soma e multiplicação por escalar iguais às definidas para vetores com um número qualquer (finito) de elementos;

- Conjunto  $M(m, n)$  de todas as matrizes com  $m$  linhas e  $n$  colunas, com as operações já definidas de soma e de multiplicação por escalar;

Um sub-espaço vetorial é um subconjunto  $V_0 \subset V$  que também possui as mesmas propriedades acima.

Na prática: considere um conjunto  $V_0 \subset V$ , em que  $V$  é espaço vetorial. Se  $V_0$  for fechado para adição e para multiplicação por escalar, e contiver a origem, então é um subespaço vetorial de  $V$ .

Ou seja: se  $V_0 \subset V$  for tal que todas as combinações lineares  $r \cdot v + s \cdot u \in V_0$  para quaisquer  $v, u \in V_0$ , então  $V_0$  é subespaço vetorial de  $V$ .

Exemplos:

i- Seja  $w \in V$ . O conjunto de todos os múltiplos de  $w$  - ou seja, a reta que passa pela origem e contém  $w$  - é subespaço vetorial:  $\mathcal{L}(w) = \{\alpha \cdot w, \alpha \in \mathbb{R}\}$ .

ii- (Caso particular do item i.) Considere o vetor  $w = (1, 1, 1) \in \mathbb{R}^3$ . O conjunto  $V_0 = \mathcal{L}(w) = \{r \cdot (1, 1, 1), r \in \mathbb{R}\} = \{(r, r, r), r \in \mathbb{R}\}$  é subespaço vetorial de  $\mathbb{R}^3$ .

iii- (Generalização do item i.) Sejam  $w_1, \dots, w_k$  vetores em  $\mathbb{R}^n$ .  $V_0 = \mathcal{L}(w_1, \dots, w_k) = \{r_1 w_1, \dots, r_k w_k : r_1, \dots, r_k \in \mathbb{R}\}$ : o conjunto de combinações lineares de  $w_1, \dots, w_k$  é subespaço vetorial.

iv-  $V_0 = \{(x_1, x_2, 0), x_1, x_2 \in \mathbb{R}\}$ ,  $V = \mathbb{R}^3$

v-  $V_0 = \{(x_1, x_2, 1) : x_1, x_2 \in \mathbb{R}\}$  não é subespaço, pois não passa pela origem: não inclui o ponto  $(0, 0, 0)$ , já que a terceira coordenada é sempre igual a 1.

vi-  $V_0 = \{0\}$  é subespaço vetorial de  $V$ .

vii-  $V_0 = V$  é subespaço vetorial de  $V$ .

Os dois últimos exemplos são os chamados subespaços triviais de  $V$ : o conjunto formado apenas pela origem, e o espaço inteiro.

Se  $m$  vetores  $u_1, \dots, u_m$  formam base do subespaço vetorial  $V_0$ , então qualquer subconjunto com mais de  $m$  vetores é linearmente dependente (LD). Qualquer base de  $V_0$  tem o mesmo número  $m$  de vetores, e esse número é a dimensão do sub-espaço  $V$ .

### Espaço-linha de uma matriz

Considere uma matriz  $A_{(n \times m)}$ . Cada uma das  $n$  linhas de  $A$  pode ser vista como um vetor em  $\mathbb{R}^m$ .

Considere o espaço gerado por esses vetores (ou seja, pelas  $n$  as linhas de  $A$ ):  $\text{Row}(A) = \mathcal{L}(a_1, \dots, a_n)$

$a_1, \dots, a_n$  são as linhas de  $A$ .  $\mathcal{L}(a_1, \dots, a_n)$  é o conjunto de C.L's dessas linhas. Operações elementares com linhas mudam as linhas  $a_1, \dots, a_n$ , mas não mudam o espaço gerado por elas!

Se  $\tilde{a}_1, \dots, \tilde{a}_n$  são linhas da matriz  $\tilde{A}$  gerada a partir de operações elementares sobre  $A$ , então:  $\mathcal{L}(a_1, \dots, a_n) = \mathcal{L}(\tilde{a}_1, \dots, \tilde{a}_n)$ . Em particular, isso vale para a forma escalonada de  $A$ .

Se os espaços gerados são os mesmos, então a dimensão deles é sempre a mesma. A dimensão não depende das operações elementares efetivadas sobre as linhas de  $A$ .

O posto de  $A$  é a dimensão do espaço gerado pelas linhas de  $A$ , e portanto é invariante a operações elementares com linhas.

### Espaço Coluna

$A_{(n \times m)}$ :  $m$  vetores em  $\mathbb{R}^n$ :  $a_1, \dots, a_m$ .

Espaço coluna de  $A$ :  $\mathcal{L}(a_1, \dots, a_m)$

Definição: uma coluna é dita *básica* se a coluna correspondente na matriz escalonada tiver um pivô.

Resultado: as colunas básicas de  $A$  forma um subespaço para o espaço coluna de  $A$ .

Então:

$$\begin{aligned} \dim(E.L) &= \# \text{linhas} \neq 0 \text{ na forma escalonada} \\ &= \# \text{pivôs na forma escalonada} \\ &= \dim(E.C) \end{aligned}$$

Então:  $\dim(E.C) = \dim(E.L) = \text{posto}$

Sabemos que  $Ax = b$  possui solução se e somente se  $b \in E.C(A)$ :

$$\begin{pmatrix} a_{11} & \cdots & a_{1m} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{mm} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_m \end{pmatrix} = x_1 \begin{pmatrix} a_{11} \\ \vdots \\ a_{m1} \end{pmatrix} + \cdots + x_m \begin{pmatrix} a_{1m} \\ \vdots \\ a_{mm} \end{pmatrix}$$

De forma equivalente:

$$x_1 a_1 + \cdots + x_m a_m = b$$

O lado esquerdo dessa equação é uma combinação linear das colunas da matriz  $A$ .

Logo,  $Ax = b$  possui solução  $\forall b \in \mathbb{R}^m$  se e somente se  $E.C(A) = \mathbb{R}^m$ ; i.e, a dimensão de  $E.C(A)$  é  $m$ .

### Espaço Nulo

O conjunto  $V$  de todas as soluções do S.L  $Ax = b$  é um espaço vetorial. É chamado espaço nulo de  $A$ :  $N(A)$ .

Um *espaço afim* é um deslocamento paralelo de um E.V: ou seja, é o conjunto  $\{x \in \mathbb{R}^m : x = c + v, v \in V\}$ .

Espaços-afins são soluções para sistemas não-homogêneos  $Ax = b \neq 0$ .

### Teorema Fundamental da Álgebra Linear

Qual a relação entre  $\dim(N(A))$  e  $\text{Posto}(A)$  ?

$$\text{Posto}(A) + \dim(N(A)) = \# \text{colunas de } A$$

$$\begin{pmatrix} 1 & 1 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} : \text{Posto}(A) = 2 = \# \text{linhas} \rightarrow \dim(N(A)) = 0 : \exists! \text{ solução.}$$

$$\begin{pmatrix} 1 & 1 \\ 2 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} : \text{Posto}(A) = 1, \# \text{linhas} = 2 \rightarrow \dim(N(A)) = 1 : \text{reta.}$$

$$\begin{pmatrix} 1 & 1 & 1 \\ 2 & 2 & 2 \\ 3 & 3 & 3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} b_1 \\ b_2 \\ b_3 \end{pmatrix} : \text{Posto}(A) = 1, \#linhas = 3 \rightarrow \text{Dim}(N(A)) = 2 :$$

plano.

## Transformações Lineares

Sejam  $V$  e  $W$  espaços vetoriais. A função  $T : V \rightarrow W$  é uma transformação linear se, para quaisquer  $v_1, v_2 \in V$ , e para qualquer escalar  $c \in \mathbb{R}$ , temos:

$$1- T(v_1 + v_2) = T(v_1) + T(v_2)$$

$$2- T(c \cdot v_1) = c \cdot T(v_1)$$

De forma equivalente, podemos dizer que para quaisquer  $v_1, v_2 \in V$  e  $c_1, c_2 \in \mathbb{R}$ ,

$$T(c_1v_1 + c_2v_2) = c_1T(v_1) + c_2T(v_2)$$

Ou seja, a transformação linear de uma combinação linear é a combinação linear das transformações dos vetores individuais.

Observe que essa definição implica que uma transformação linear sempre passa pela origem:

$$T(0) = 0$$

A demonstração é simples:

$T(0) = T(0 + 0) = T(0) + T(0)$ . Subtraindo  $T(0)$  de ambos os lados, obtemos  $T(0) - T(0) = T(0) + T(0) - T(0)$ , ou  $0 = T(0)$ , o que prova o resultado.

Portanto, a função  $y = ax + b$  não é uma transformação linear se  $b \neq 0$ , pois não passa no ponto  $(0, 0)$ .

## Exemplos

1- Seja  $T : \mathbb{R} \rightarrow \mathbb{R}$  definida por  $T(x) = a \cdot x$  para algum número real  $a$ . Podemos verificar que essa função define uma transformação linear:

$$T(x_1 + x_2) = a(x_1 + x_2) = ax_1 + ax_2 = T(x_1) + T(x_2)$$

$$T(cx) = a \cdot (cx) = c \cdot (ax) = c \cdot T(x)$$

Logo, as duas condições são atendidas.

2-  $T : \mathbb{R}^2 \rightarrow \mathbb{R}$  definida por:

$$T \left( \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \right) = a_1x_1 + a_2x_2 = \begin{bmatrix} a_1 & a_2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

3-  $T : \mathbb{R}^2 \rightarrow \mathbb{R}^2$  definida por:

$$T \left( \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \right) = \begin{bmatrix} a_{11}x_1 + a_{12}x_2 \\ a_{21}x_1 + a_{22}x_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

4-  $T : \mathbb{R}^2 \rightarrow \mathbb{R}^3$  definida por:

$$T \left( \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \right) = \begin{bmatrix} a_{11}x_1 + a_{12}x_2 \\ a_{21}x_1 + a_{22}x_2 \\ a_{31}x_1 + a_{32}x_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{32} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

5-  $T : \mathbb{R}^n \rightarrow \mathbb{R}^m$  definida por:

$$T \left( \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \right) = \begin{bmatrix} a_{11}x_1 + \dots + a_{1n}x_n \\ \vdots \\ a_{m1}x_1 + \dots + a_{mn}x_n \end{bmatrix} = \underbrace{\begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix}}_{A_{m \times n}} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

Ou seja:

$$T \left( \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \right) = A \cdot \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

Toda transformação linear (finita) pode ser representada dessa forma.

## Complemento e Projeção Ortogonal

### Complemento Ortogonal

Considere um subespaço  $V \subseteq E$ . Considere  $E = \mathbb{R}^n$ . Defina o complemento ortogonal de  $V$ :

$$V^\perp = \{x \in \mathbb{R}^n : \langle x, v \rangle = 0 \forall v \in V\}$$

Qualquer elemento de  $V^\perp$  é perpendicular a qualquer elemento de  $V$ . Como exemplo, podemos tomar  $E = \mathbb{R}^2$ ,  $V$  como o conjunto de múltiplos de  $(1, 0)$  (eixo horizontal), e portanto  $V^\perp$  como o conjunto de múltiplos de  $(0, 1)$  (eixo vertical).

É possível provar os seguintes resultados.

**Resultado 1.**  $V^\perp$  também é subespaço vetorial de  $E$ .

**Prova.** Vamos provar inicialmente que  $V^\perp$  é fechado para soma. Sejam  $a, b \in V^\perp$ . Precisamos mostrar que  $a + b \in V^\perp$ , ou seja, precisamos provar que  $a + b$  é perpendicular a qualquer elemento  $v \in V^\perp$ . Mas isso equivale a provar que o produto interno  $\langle a + b, v \rangle$  é igual a zero para todo  $v \in V^\perp$ . Pelas propriedades do produto interno,  $\langle a + b, v \rangle = \langle a, v \rangle + \langle b, v \rangle$ . Como  $a \in V^\perp$ ,  $a$  é perpendicular a qualquer elemento  $v \in V^\perp$ , e portanto  $\langle a, v \rangle = 0$ . Analogamente,  $\langle b, v \rangle = 0$ , e portanto  $\langle a + b, v \rangle = 0$ , e que conclui a prova de que  $V^\perp$  é fechado para soma.

Para provar que  $V^\perp$  é fechado para multiplicação por escalar, precisamos mostrar que para todo  $a \in V^\perp$  e para todo  $\alpha \in \mathbb{R}$ ,  $\alpha \cdot a \in V^\perp$ . Ou seja, temos de provar que  $\langle \alpha a, v \rangle = 0$  para todo  $v \in V$ . Usamos então novamente as propriedades do produto interno:  $\langle \alpha a, v \rangle = \alpha \langle a, v \rangle = 0$ , em que a última igualdade decorre do fato de que  $a \in V^\perp$ , e portanto

$\alpha < a, v \rangle = 0$ . Por último, podemos fazer  $\alpha = 0$ , e portanto  $\alpha a = 0$ : a origem também pertence ao conjunto  $V^\perp$ . Isso conclui a demonstração:  $V^\perp$  é fechado para soma de vetores e para multiplicação por escalar, e contém a origem.

**Resultado 2.** O núcleo de uma matriz  $A$  (ou seja, seu espaço-nulo) é igual ao conjunto ortogonal ao espaço-linha dessa matriz:  $N(A) = (E.L.(A))^\perp$ .

Analogamente, podemos escrever o segundo resultado como  $N(A) = (E.C.(A^T))^\perp$ , pois espaço-linha de  $A$  é por definição o espaço-coluna de  $A^T$ , a transposta de  $A$ . Podemos ainda escrever:

$$N(A^T) = (E.L.(A^T))^\perp$$

## Dimensão do Complemento Ortogonal

Podemos então determinar a dimensão de  $V^\perp$ , o complemento ortogonal de  $V$ .

**Resultado 3.** Seja  $V$  subespaço vetorial de  $E$ , com  $\dim(V) = k$  e  $\dim(E) = n \geq k$ . Então  $\dim^\perp = n - k$ .

**Prova.** Seja  $\{v_1, \dots, v_k\}$  uma base para  $V$ , que tem portanto dimensão  $\dim(V) = k$  (lembrando: dimensão é o número de vetores em uma base).

Construa uma matriz em que cada coluna é um vetor dessa base de  $V$ :

$$A_{n,k} = \begin{bmatrix} | & \dots & | \\ v_1 & \dots & v_k \\ | & \dots & | \end{bmatrix}$$

Logo,  $V = \text{Span}(v_1, \dots, v_k) = E.C.(A)$ . Lembrando:  $V$  é por definição o espaço gerado (span) dos vetores de uma base de  $V$ . Pela disposição desses vetores na matriz acima, isso é por definição o espaço-coluna de  $A$ .

Podemos então concluir que  $N(A^\perp) = (E.C.(A))^\perp = V^\perp$ . Logo, a dimensão de  $V^\perp$  é igual à de  $N(A^T)$ . Escreva agora a transposta de  $A$ :

$$A_{k,n}^T = \begin{bmatrix} \text{---}v_1\text{---} \\ \vdots \\ \text{---}v_k\text{---} \end{bmatrix}$$

O teorema fundamental da álgebra linear diz que:

$$\text{Posto}(A^T) + \dim(\text{Nucleo}(A^T)) = \# \text{ colunas } (A)$$

Mas o número de colunas de  $A^T$  é  $n$ . Além disso, o posto de  $A^T$  é igual à dimensão do espaço-linha de  $A^T$ , e o espaço-linha de  $A^T$  é o espaço-coluna de  $A$ . Logo,  $\text{posto}(A^T) = \dim(E.C.(A))$ .

$$\dim(E.C.(A)) + \dim(\text{Nucleo}(A^T)) = n$$

Mas o espaço-coluna de  $A$  é por definição o subespaço  $V$  (os vetores da base de  $V$  foram dispostos como colunas da matriz  $A$ ). E, como visto acima,  $\dim(V^\perp) = \dim(N(A^T))$ . Reescrevemos então a equação acima como:

$$\dim(V) + \dim(V^\perp) = n$$

Ou ainda:

$$\dim(V^\perp) = n - \dim(V)$$

É possível provar que qualquer vetor em  $\mathbb{R}^n$  pode ser representado, *de forma única*, como a soma de um vetor  $v \in V$  com um vetor  $w \in V^\perp$ . Por exemplo, qualquer vetor  $(x, y)$  em  $\mathbb{R}^2$  pode ser escrito como a soma do vetor  $(x, 0)$  no eixo horizontal com o vetor  $(0, y)$  no eixo vertical (ou seja, o complemento ortogonal do eixo horizontal).

## Decomposição de um vetor em $\mathbb{R}^n$ como uma soma de elementos em $V$ e em $V^\perp$

Seja  $\tilde{v} \in \mathbb{R}^n$ . Queremos escrever  $\tilde{v} = v + w$ , com  $v \in V$  e  $w \in V^\perp$ . Vamos provar inicialmente dois resultados.

**Resultado 4.**  $V \cap V^\perp = \{0\}$ .

**Prova.** Seja  $x = (x_1, \dots, x_k) \in V \cap V^\perp$ . Como  $x$  pertence a um subespaço e ao seu complemento ortogonal, deve ser perpendicular a si mesmo. Logo,  $\langle x, x \rangle = x_1^2 + \dots + x_k^2 = 0$ . Segue então que  $x_1 = \dots = x_k = 0$ .

Se  $\{v_1, \dots, v_k\}$  é base de  $V \in \text{subset} \mathbb{R}^n$ , a dimensão de  $V$  é igual a  $k$  (a dimensão é o número de vetores em uma base). Segue então pelo Resultado 3 que a dimensão de  $V^\perp$  é igual a  $n - k$ , ou seja,  $V^\perp$  tem  $n - k$  vetores em uma base. Seja então  $\{v_{k+1}, \dots, v_n\}$  uma base de  $V^\perp$ . Temos o seguinte resultado:

**Resultado 5.** Seja  $\{v_1, \dots, v_k\}$  uma base de  $V$  e  $\{v_{k+1}, \dots, v_n\}$  uma base de  $V^\perp$ . Então  $\{v_1, \dots, v_k, v_{k+1}, \dots, v_n\}$  é uma base de  $\mathbb{R}^n$ .

**Prova.** Precisamos provar que o conjunto  $\{v_1, \dots, v_k, v_{k+1}, \dots, v_n\}$  atende a duas condições: é linearmente independente (LI), e gera  $\mathbb{R}^n$ .

Vamos provar inicialmente que esse conjunto de vetores é LI. Isso significa que precisamos provar que se  $c_1 v_1 + \dots + c_n v_n = 0$ , então  $c_1 = \dots = c_n = 0$ . Para tanto, observe que:

$$\begin{aligned} c_1 v_1 + \dots + c_k v_k + c_{k+1} v_{k+1} + \dots + c_n v_n &= 0 \\ \Rightarrow c_1 v_1 + \dots + c_k v_k &= -(c_{k+1} v_{k+1} + \dots + c_n v_n) \end{aligned}$$

O lado esquerdo dessa equação é uma combinação linear de vetores em  $V$ , e portanto pertence a  $V$  (um subespaço é fechado para combinações lineares de seus elementos). Analogamente, o lado direito é uma combinação linear de vetores em  $V^\perp$ , e portanto pertence a  $V^\perp$ . Logo, o vetor  $c_1 v_1 + \dots + c_k v_k = -(c_{k+1} v_{k+1} + \dots + c_n v_n)$  pertence à interseção  $V \cap V^\perp$ . Pelo resultado 4, segue que esse vetor é igual à origem. Então:

$$c_1v_1 + \dots + c_kv_k = 0$$

$$-(c_{k+1}v_{k+1} + \dots + c_nv_n) = 0$$

Como  $\{v_1, \dots, v_k\}$  é base de  $V$ , segue que  $c_1 = \dots = c_k = 0$ . Analogamente, como  $\{v_{k+1}, \dots, v_n\}$  é base de  $V^\perp$ , segue que  $c_{k+1} = \dots = c_n = 0$ . Em suma, concluímos que  $c_1 = \dots = c_n = 0$ , e concluímos que  $\{v_1, \dots, v_n\}$  é LI.

Como  $n$  vetores LI em  $\mathbb{R}^n$  geram  $\mathbb{R}^n$ , concluímos que  $\{v_1, \dots, v_n\}$  é base para  $\mathbb{R}^n$ .

Concluímos então que para todo  $a \in \mathbb{R}^n$ , existe  $(c_1, \dots, c_n)$  tal que:

$$a = \underbrace{c_1v_1 + \dots + c_kv_k}_v + \underbrace{c_{k+1}v_{k+1} + \dots + c_nv_n}_w$$

tal que  $v \in V$  e  $w \in V^\perp$ . Ou seja, todo elemento de  $\mathbb{R}^n$  pode ser decomposto como a soma de um elemento em um subespaço  $V$  qualquer com um elemento no complemento ortogonal  $V^\perp$ .

Usaremos a seguinte definição: um conjunto  $X$  é a *soma direta* dos conjuntos  $Y$  e  $W$  se: (i) todo elemento em  $X$  por ser representado como a soma de um elemento em  $Y$  com um elemento em  $W$ ; e (ii) a interseção de  $Y$  e  $W$  é vazia.

Temos então o seguinte corolário:

**Resultado 6.**  $\mathbb{R}^n$  é igual à soma direta de um subespaço  $V$  com seu complemento ortogonal  $V^\perp$ :  $\mathbb{R}^n = V \oplus V^\perp$

**Prova.** Pelo resultado 5, qualquer elemento de  $\mathbb{R}^n$  pode ser escrito como a soma de um elemento em  $V$  com um elemento em  $V^\perp$ . Pelo resultado 4, a interseção dos conjuntos  $V$  e  $V^\perp$  é apenas a origem. Essas duas condições são exatamente a definição de soma direta.

**Resultado 7.** Essa representação é única.

**Prova.** Considere um vetor  $a \in \mathbb{R}^n$  tal que  $a = v_1 + x_1 = v_2 + x_2$ , como  $v_i \in V$  e  $x_i \in V^\perp$ ,  $i = 1, 2$ . Segue então que  $v_1 - v_2 = x_1 - x_2$ . O lado esquerdo pertence a  $V$  (é uma combinação linear de vetores de  $V$ ), e, analogamente, o lado direito pertence a  $V^\perp$ . Logo,  $v_1 - v_2 = x_1 - x_2 \in V \cap V^\perp = \{0\}$ , em que a última igualdade vem do resultado 4. Logo,  $v_1 - v_2 = x_1 - x_2 = 0$ , e portanto  $v_1 = v_2$  e  $x_1 = x_2$ .

Podemos provar ainda os seguintes resultados:

**Resultado 8.** Seja  $V$  um subespaço qualquer.  $(V^\perp)^\perp = V$ .

**Resultado 9.** Seja  $N(A)$  o núcleo associado a uma matriz  $A$ .

$$(N(A))^\perp = ((\text{Col}(A^T))^\perp)^\perp = E.C.(A^T = E.L.(A))$$

$$(N(A^T))^\perp = (E.C.(A)^\perp)^\perp = E.C.(A)$$

## Solução para um sistema linear no espaço-linha de uma matriz

Considere uma matriz  $A_{m,n} = [a_1 a_2 \dots a_n]$ , em que  $a_i$  a  $i$ -ésima coluna da matriz  $A$ , para  $i = 1, \dots, n$ . Suponha que  $b \in E.C.(A)$ . Como já visto, existem escalares  $x_1, \dots, x_n$  tal que  $x_1 a_1 + \dots + x_n a_n = b$ . (Um sistema linear tem solução quando o vetor  $b$  de termos livres pertence à combinação linear das colunas da matriz de coeficientes  $A$ ). Ou seja, existe  $x = (x_1, \dots, x_n) \in \mathbb{R}^n$  tal que:

$$[a_1 \dots a_n] \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} = b$$

Esse vetor  $x \in \mathbb{R}^n$  é a solução do sistema  $Ax = b$ . Como já visto,  $N(A) = \{x \in \mathbb{R}^n : Ax = 0\}$  e  $(N(A))^\perp = E.C.(A^T) = E.L.(A)$ . Temos então o seguinte resultado.

**Resultado 10.** *Para todo  $b$  no espaço coluna de  $A$ , existe um vetor  $r_0$  no espaço-linha de  $A$  que soluciona o sistema linear  $Ax = b$ . (Ou seja, existe  $r_0 \in E.C.(A^T)$  tal que  $Ar_0 = b$ .)*

**Prova.** *Uma solução  $x$  do sistema linear  $Ax = b$  é um vetor em  $\mathbb{R}^n$ , que pode ser decomposto como a soma direta de um subespaço vetorial qualquer com seu complemento ortogonal. Vamos escolher  $\mathbb{R}^n = N(A) \oplus N(A)^\perp = N(A) \oplus E.L.(A) = N(A) \oplus E.C.(A^T)$ .*

*Logo, qualquer vetor  $x \in \mathbb{R}^n$ , e em particular a solução do sistema linear  $Ax = b$ , pode ser escrito como:*

$$x = r_0 + n_0$$

*Em que  $r_0 \in E.L.(A) = E.C.(A^T)$  e  $n_0 \in N(A)$ . Podemos então escrever  $r_0 = x - n_0$ . Pré-multiplique ambos os lados para obter:*

$$Ar_0 = A(x - n_0) = Ax - An_0$$

*Como  $n_0$  está no espaço-nulo de  $A$ , segue que  $An_0 = 0$ , e portanto  $Ar_0 = Ax = b$ , em que a última igualdade vale porque estamos trabalhando com um vetor  $x$  que soluciona o sistema  $Ax = b$ . Em suma,  $Ar_0 = b$ , e portanto  $r_0 \in E.C.(A^T)$  soluciona o sistema linear  $Ax = b$ .*

É possível provar ainda que essa solução  $r_0$  é única no espaço-linha de  $A$ .

**Resultado 11.**  *$r_0$  é único.*

**Prova.** *Suponha que existam  $r_0, r_1 \in E.C.(A^T)$  tal que  $Ar_0 = Ar_1 = b$ . Então  $r_1 - r_0 \in E.C.(A^T)$ , pois o espaço-coluna é um subespaço vetorial e portanto é fechado para combinações lineares; e além disso  $A(r_1 - r_0) = b - b = 0$ , e portanto  $(r_1 - r_0) \in N(A) = (E.C.(A^T))^\perp$ . Logo,  $r_1 - r_0 \in E.C.(A^T) \cap (E.C.(A^T))^\perp$ . Pelo resultado 4, segue que  $r_1 - r_0 = 0$ , e portanto  $r_1 = r_0$ .*

Dessa forma, qualquer solução  $x$  do sistema linear  $Ax = b$  pode ser escrita como uma soma  $r_0 + n_0$ , em que  $r_0$  é fixo e  $n_0$  varia. É um resultado já visto: as soluções de um sistema linear não-homogêneo podem ser escritas como a soma de uma solução particular  $r_0$  como uma solução  $n_0$  do sistema linear homogêneo associado.

A solução  $r_0$  do sistema linear  $Ax = b$  tem uma propriedade relevante: ela é a mais próxima da origem dentre todos os vetores  $x$  que solucionam  $Ax = b$ .

**Resultado 12.** *Sejam  $x$  e  $r_0$  duas soluções do sistema linear  $Ax = b$ , e  $r_0 \in E.C.(A^T)$ . Então  $\|x\| \geq \|r_0\|$ .*

**Prova.** *Como visto, todo  $x$  que soluciona  $Ax = b$  pode ser escrito como  $r_0 + n_0$ . Então:*

$$\begin{aligned} \|x\|^2 &= \langle x, x \rangle = \langle r_0 + n_0, r_0 + n_0 \rangle = \langle r_0, r_0 \rangle + \underbrace{2 \langle r_0, n_0 \rangle}_0 + \langle n_0, n_0 \rangle \\ &= \|r_0\|^2 + \|n_0\|^2 \end{aligned}$$

*Usamos  $\langle r_0, n_0 \rangle = 0$  pois  $r_0$  e  $n_0$  são ortogonais. Para concluir, observamos que  $\|r_0\|^2$  é não negativo, e portanto  $\|x\|^2 \geq \|r_0\|^2$ . Logo,  $\|x\| \geq \|r_0\|$ .*

## Projeção em Subespaços

Como visto, para todo vetor  $x \in \mathbb{R}^n$ ,  $\exists!(v, w) \in V \times V^\perp$  tal que  $x = v + w$ . (Lembrando: o símbolo  $\exists!$  significa "existe um único").

Definimos então a projeção ortogonal de  $x$  no subespaço  $V$  como:

$$Proj_V(x) = v$$

Analogamente, definimos:

$$Proj_{V^\perp}(x) = w$$

Podemos encontrar uma expressão para  $Proj_V(x) = v \in V$ . Seja  $\{b_1, \dots, b_k\}$  uma base para  $V$ . Logo, para todo  $a \in V$ , existe  $(y_1, \dots, y_k)$  tal que:

$$a = y_1 b_1 + \dots + y_k b_k$$

(Todo elemento do subespaço pode ser escrito como combinação linear de uma base desse subespaço.) Forme então uma matriz  $A_{n,k}$  cujas colunas são os vetores da base acima:

$$A_{n,k} = \begin{bmatrix} | & \dots & | \\ b_1 & \dots & b_k \\ | & \dots & | \end{bmatrix}$$

**Resultado 13.** *Seja  $A$  uma matriz cujas colunas são os vetores de uma base do subespaço vetorial  $V$ . Seja  $Ay$  a projeção de  $x \in \mathbb{R}^n$  no subespaço  $V$ . O vetor  $y$  é dado pela seguinte expressão:*

$$y = (A^T A)^{(-1)} A^T x$$

**Prova.** *Por definição,  $V = E.C.(A)$ . Podemos então escrever  $a = Ay = b_1 y_1 + \dots + b_k y_k$ : qualquer elemento  $a \in V$  pode ser escrito como  $Ay$ , ou seja, como combinação linear dos vetores da base de  $A$ .*

*Mas vimos acima que  $Proj_V(x) \in V$ . Logo,  $Proj_V(x)$  também pode ser escrito dessa forma: para algum  $y \in \mathbb{R}^n$ , é verdade que:*

$$Proj_V(x) = Ay$$

Também vimos que podemos escrever  $x \in \mathbb{R}^n$  como uma soma:  $x = Proj_V(x) + w$ , em que  $w$  é um vetor (único) de  $V^\perp$ . Então:

$$x - Proj_V(x) = w$$

Como  $w \in V^\perp$ , segue que  $x - Proj_V(x) \in V^\perp$ . Sabemos também que  $V = E.C.(A)$ , e portanto  $V^\perp = E.C.(A)^\perp = N(A^T)$ , e portanto  $x - Proj_V(x) \in V^\perp = N(A^T)$ . Então:

$$A^T(x - Proj_V(x)) = 0$$

$$A^T x - \underbrace{A^T \left( Proj_V(x) \right)}_{Ay} = 0$$

$$A^T x - A^T Ay = 0$$

$$A^T x = (A^T A)y$$

Como as colunas de  $A$  são linearmente independentes, é possível provar que  $(A^T A)$  admite inversa. Então:

$$(A^T A)^{(-1)} A^T x = y$$

Podemos então escrever:

$$Proj_V(x) = Ay = A(A^T A)^{(-1)} A^T x$$

Essa é a expressão da projeção de  $x \in \mathbb{R}^n$  no subespaço vetorial  $V$ . Como  $A(A^T A)^{(-1)} A^T$  é apenas um produto de várias matrizes, essa expressão representa uma transformação linear - ou seja, a projeção ortogonal é uma transformação linear.