

ALC: Fundamentos de Álgebra Linear

Profs. Alexandre Salles da Cunha e Ana Paula Couto

Universidade Federal de Minas Gerais
Departamento de Ciência da Computação
Belo Horizonte, Brasil

acunha@dcc.ufmg.br
ana.coutosilva@dcc.ufmg.br



UNIVERSIDADE FEDERAL
DE MINAS GERAIS





Definição

Lista ordenada de n números reais.

- Cada número da lista é chamado de **coordenada** do vetor.
- Todo vetor será representado como um vetor coluna $\in \mathbb{R}^{n \times 1}$.

- Exemplos: $\begin{bmatrix} 1 \\ 2 \end{bmatrix} \in \mathbb{R}^2$; $\begin{bmatrix} -\pi \\ 2 \\ \sqrt{3} \end{bmatrix} \in \mathbb{R}^3$; $\begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \end{bmatrix} \neq \begin{bmatrix} 2 \\ 1 \\ 3 \\ 4 \end{bmatrix} \in \mathbb{R}^4$



Soma

Associa a todo par $\{u, v\}$ de vetores um novo vetor $z \in \mathbb{R}^n$:

$$z = u + v = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix} = \begin{bmatrix} u_1 + v_1 \\ u_2 + v_2 \\ \vdots \\ u_n + v_n \end{bmatrix}$$

Soma

Associa a todo par $\{u, v\}$ de vetores um novo vetor $z \in \mathbb{R}^n$:

$$z = u + v = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix} = \begin{bmatrix} u_1 + v_1 \\ u_2 + v_2 \\ \vdots \\ u_n + v_n \end{bmatrix}$$

Elemento neutro ou origem ou vetor nulo

$$0_n = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \text{ que satisfaz } u + 0_n = u; \forall u \in \mathbb{R}^n$$

Multiplicação por escalar

Dado um escalar $d \in \mathbb{R}$ e um vetor $u \in \mathbb{R}^n$:

$$du = d \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} = \begin{bmatrix} du_1 \\ du_2 \\ \vdots \\ du_n \end{bmatrix}$$

Definição

O produto interno dos vetores u e v no \mathbb{R}^n é conhecido como **produto linha-coluna de dois vetores ou produto escalar**:

$$\langle u, v \rangle = u^T v = \sum_{i=1}^n u_i v_i$$

Definição

O produto interno dos vetores u e v no \mathbb{R}^n é conhecido como **produto linha-coluna de dois vetores ou produto escalar**:

$$\langle u, v \rangle = u^T v = \sum_{i=1}^n u_i v_i$$

- Vetores u e v tais que $\langle u, v \rangle = 0$ são perpendiculares entre si.
- A norma Euclidiana de um vetor é dada por $\|u\|_2 = \sqrt{(u^T u)}$.
- O vetor u é um vetor unitário quando $u^T u = 1$.

Definição

x é a combinação linear de uma coleção de vetores $\{x^1, x^2, \dots, x^m\}$, se pode ser escrito como:


$$x = \sum_{i=1}^m \alpha_i x^i, \text{ para } \alpha_i \in \mathbb{R}.$$

Quatro combinações lineares “especiais”:


- $1v + 1w$: soma de vetores.
- $1v - 1w$: diferença entre vetores.
- $0v + 0w$: vetor nulo.
- $cv + 0w$: vetor cv na direção de v .

Quatro combinações lineares “especiais”:

- $1v + 1w$: soma de vetores.
- $1v - 1w$: diferença entre vetores.
- $0v + 0w$: vetor nulo.
- $cv + 0w$: vetor αv na direção de v .



$$v + w = \begin{bmatrix} 4 \\ 2 \end{bmatrix} + \begin{bmatrix} -1 \\ 2 \end{bmatrix} = \begin{bmatrix} 3 \\ 4 \end{bmatrix}$$



$$v - w = \begin{bmatrix} 4 \\ 2 \end{bmatrix} - \begin{bmatrix} -1 \\ 2 \end{bmatrix} = \begin{bmatrix} 5 \\ 0 \end{bmatrix}$$


Introduction to Linear Algebra - Gilbert Strang

Dados os vetores $u, v, w \in \mathbb{R}^3$ e os escalares $c, d, f \in \mathbb{R}$:

- Qual a representação geométrica de todas as combinações cu ?
- Qual a representação geométrica de todas as combinações $cu + dv$?
- Qual a representação geométrica de todas as combinações $cu + dv + fw$?

Dados os vetores $u, v, w \in \mathbb{R}^3$ e os escalares $c, d, f \in \mathbb{R}$:

- Qual a representação geométrica de todas as combinações cu ?
- Qual a representação geométrica de todas as combinações $cu + dv$?
- Qual a representação geométrica de todas as combinações $cu + dv + fw$?



Independência linear

Uma coleção de vetores $\{x^1, \dots, x^m\}$ de um espaço vetorial \mathcal{X} é linearmente independente se a igualdade



$$\sum_{i=1}^m \alpha_i x^i = 0$$

somente é verdadeira para $\alpha_i = 0; i = 1, \dots, m$

Se existem $\alpha_i : i = 1, \dots, m$, nem todos nulos tais que $\sum_{i=1}^m \alpha_i x^i = 0$, estes vetores são denominados **linearmente dependentes**.

Dimensão

A dimensão do espaço vetorial associado a um conjunto $\{x^1, \dots, x^m\}$ é a cardinalidade do maior subconjunto linearmente independente de $\{x^1, \dots, x^m\}$.



Introduction to Linear Algebra - Gilbert Strang

- **Espaço vetorial:** Conjunto não vazio \mathcal{X} , cujos elementos são denominados vetores, fechado nas operações de:
 - **soma**, que associa a todo par u, v de vetores de \mathcal{X} um novo vetor $u + v \in \mathcal{X}$
 - **multiplicação por escalar**, para todo par $\alpha \in \mathbb{R}$ e $v \in \mathcal{X}$: $\alpha v \in \mathcal{X}$.
- **Propriedades no espaço vetorial**, para todo $u, v, w \in \mathcal{X}$:
 - Associatividade da adição: $u + (v + w) = (u + v) + w$
 - Comutabilidade da adição: $u + v = v + u$
 - Existência de um elemento nulo: $0 + v = v + 0 = v$
 - Existência do inverso aditivo: para todo $v \in \mathcal{X}$ existe $-v \in \mathcal{X}$ tal que $v + (-v) = (-v) + v = 0$
 - Propriedades da multiplicação por escalar: $\alpha(u + v) = \alpha u + \alpha v$, $(\alpha + \beta)u = \alpha u + \beta u$, $(\alpha\beta)u = \alpha(\beta u)$, $1u = u$.

Definição

Um subconjunto \mathcal{V} não vazio de um espaço vetorial é um subespaço vetorial se e somente se \mathcal{V} é **fechado na soma de seus elementos e na multiplicação por escalar**. Isto é, dados $u, v \in \mathcal{V}$ e $\alpha, \beta \in \mathbb{R}$, $\alpha u + \beta v \in \mathcal{V}$.

- Observação: se \mathcal{V} é um subespaço vetorial, o vetor nulo $0 \in \mathcal{V}$.

Span

O span ou subespaço gerado pelo conjunto $S = \{x^1, \dots, x^m\}$, $\text{span}(S)$, corresponde a todas as possíveis combinações lineares $\sum_{i=1}^m \alpha_i x^i$ (os pesos são $\alpha_i : i = 1, \dots, m$).

Base de um subespaço (espaço) vetorial


Uma base para um subespaço \mathcal{V} (espaço \mathcal{X}) é um conjunto de vetores $S' = \{x^1, \dots, x^d\}$ linearmente independentes tais que $\mathcal{V} = \text{span}(S')$. Neste caso, a dimensão do subespaço é a dimensão deste conjunto, d .

- Espaços gerados por vetores linearmente independentes.


1 vetor



2 vetores



3 vetores




- Espaços gerados por vetores linearmente dependentes.

2 vetores



3 vetores



Curso de Álgebra Linear - Fundamentos e Aplicações - Marco Cabral e Paulo Goldfeld

- $v = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$ e $w = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$: geram todo o espaço \mathbb{R}^2 .
- $v = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$, $w = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$ e $u = \begin{bmatrix} 4 \\ 7 \end{bmatrix}$: também geram todo o espaço \mathbb{R}^2 .
- $v = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ e $w = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$: geram somente uma linha em \mathbb{R}^2 .
- $v = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$ e $w = \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}$ e $u = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$: geram todo o espaço \mathbb{R}^3 .

Norma

Uma norma em um espaço vetorial é uma função real que associa a todo elemento $x \in \mathcal{X}$ um valor $\|x\|$ satisfazendo:

- $\|x\| \geq 0$ para todo $x \in \mathcal{X}$ e $\|x\| = 0 \iff x = 0$.
- $\|x + y\| \leq \|x\| + \|y\|$ para todo $x, y \in \mathcal{X}$.
- $\|\alpha x\| = |\alpha| \|x\|$ para todo $\alpha \in \mathbb{R}, x \in \mathcal{X}$.

Exemplos de normas para $\mathcal{X} = \mathbb{R}^n$:

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}, \quad 1 \leq p \leq \infty$$

Casos particulares: $p = 2$ (norma Euclideana), $p = 1$ (norma soma de valores absolutos) e $p = \infty$ (máximo módulo).

$$u = \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix}, v = \begin{bmatrix} 0 \\ 1 \\ -1 \end{bmatrix}, w = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$$

- Combinação linear: $x_1 u + x_2 v + x_3 w$:

$$x_1 \begin{bmatrix} 1 \\ -1 \\ 0 \end{bmatrix} + x_2 \begin{bmatrix} 0 \\ 1 \\ -1 \end{bmatrix} + x_3 \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 - x_1 \\ x_3 - x_2 \end{bmatrix}$$


- Representação Matricial:

$$Ax = \begin{bmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 - x_1 \\ x_3 - x_2 \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix} = b$$


- b é a combinação linear das colunas de A .

Transformação linear $Ax = b$

Para $A = \begin{bmatrix} 1.2 & 0.4 \\ 0.6 & 1 \end{bmatrix}$, tomado alguns pontos aleatoriamente escolhidos $x \in \mathbb{R}^2 : \|x\|_2 = 1$ temos a seguinte transformação do disco:




Transformação do quadrado unitário



Área do quadrado = 1, área do losango $|a_{11}a_{22} - a_{21}a_{12}| = |\det(A)|$

$$A = \begin{pmatrix} 1.5 & 0.8 \\ -0.75 & -0.4 \end{pmatrix}$$



- Visão elemento a elemento: $A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ \vdots & \vdots & \vdots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix}$

- Visão por linhas: $A = \begin{bmatrix} a_1^T \\ a_2^T \\ \vdots \\ a_m^T \end{bmatrix}, a_i = \begin{bmatrix} a_{i1} \\ a_{i2} \\ \vdots \\ a_{in} \end{bmatrix}$

- a_i : vetor coluna associado a i -ésima linha de A .
- a_i^T : i -ésima linha de A .

- Visão por colunas: $A = [A_1 \ A_2 \ \dots \ A_n]$

Produto Escalar:

$$b = Ax = \begin{bmatrix} a_1^T \\ a_2^T \\ \vdots \\ a_m^T \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} a_1^T x \\ a_2^T x \\ \vdots \\ a_m^T x \end{bmatrix} = \begin{bmatrix} \sum_{j=1}^n a_{1j} x_j \\ \sum_{j=1}^n a_{2j} x_j \\ \vdots \\ \sum_{j=1}^n a_{mj} x_j \end{bmatrix}$$

Combinação linear das colunas de A :

$$b = Ax = [\begin{array}{cccc} A_1 & A_2 & \dots & A_n \end{array}] \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = [A_1x_1 + A_2x_2 + \dots + A_nx_n]$$

Combinação linear das colunas de A :

$$b = \begin{bmatrix} 1 & 1 & 2 \\ 0 & 2 & 3 \\ 3 & 1 & -1 \end{bmatrix} \begin{bmatrix} 1 \\ 4 \\ -2 \end{bmatrix} = 1 \begin{bmatrix} 1 \\ 0 \\ 3 \end{bmatrix} + 4 \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} - 2 \begin{bmatrix} 2 \\ 3 \\ -1 \end{bmatrix} = \begin{bmatrix} 1 \\ 2 \\ 9 \end{bmatrix}$$

Produto $C = AB$, $A \in \mathbb{R}^{m \times n}$, $B \in \mathbb{R}^{n \times p}$

Produto interno:

$$c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}, \quad i = 1, \dots, m; \quad j = 1, \dots, p$$

$$C = \begin{bmatrix} a_1^T \\ a_2^T \\ \vdots \\ a_m^T \end{bmatrix} \begin{bmatrix} B_1 & B_2 & \dots & B_p \end{bmatrix} = \begin{bmatrix} a_1^T B_1 & \dots & a_1^T B_p \\ a_2^T B_1 & \dots & a_2^T B_p \\ \vdots & & \vdots \\ a_m^T B_1 & \dots & a_m^T B_p \end{bmatrix}$$

Colunas de C como uma combinação linear das colunas de A:

$$\begin{aligned} C = AB &= A \begin{bmatrix} B_1 & B_2 & \dots & B_p \end{bmatrix} = \begin{bmatrix} AB_1 & AB_2 & \dots & AB_p \end{bmatrix} = \\ &= \begin{bmatrix} \sum_{k=1}^n A_k b_{k1} & \sum_{k=1}^n A_k b_{k2} & \dots & \sum_{k=1}^n A_k b_{kp} \end{bmatrix} \end{aligned}$$

Colunas de C como uma combinação linear das colunas de A :

$$\begin{aligned} C = AB &= \begin{bmatrix} 2 & 3 \\ 4 & 5 \end{bmatrix} \begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} = \left[\begin{bmatrix} 2 & 3 \\ 4 & 5 \end{bmatrix} \begin{bmatrix} 1 \\ 3 \end{bmatrix} \quad \begin{bmatrix} 2 & 3 \\ 4 & 5 \end{bmatrix} \begin{bmatrix} 2 \\ 4 \end{bmatrix} \right] = \\ &= \left[1 \begin{bmatrix} 2 \\ 4 \end{bmatrix} + 3 \begin{bmatrix} 3 \\ 5 \end{bmatrix} \quad 2 \begin{bmatrix} 2 \\ 4 \end{bmatrix} + 4 \begin{bmatrix} 3 \\ 5 \end{bmatrix} \right] = \begin{bmatrix} 11 & 16 \\ 19 & 28 \end{bmatrix} \end{aligned}$$

Linhas de C como uma combinação linear das linhas de B :

$$C = AB = \begin{bmatrix} a_1^T \\ a_2^T \\ \dots \\ a_m^T \end{bmatrix} B = \begin{bmatrix} a_1^T B \\ a_2^T B \\ \dots \\ a_m^T B \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^n b_k^T a_{1k} \\ \sum_{k=1}^n b_k^T a_{2k} \\ \vdots \\ \sum_{k=1}^n b_k^T a_{mk} \end{bmatrix}$$

Linhas de C como uma combinação linear das linhas de B :

$$C = \begin{bmatrix} 2 & 3 \\ 4 & 5 \end{bmatrix} \begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} = \begin{bmatrix} [2 & 3] \begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \\ [4 & 5] \begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \end{bmatrix} =$$
$$\begin{bmatrix} 2 \begin{bmatrix} 1 & 2 \\ 1 & 2 \end{bmatrix} + 3 \begin{bmatrix} 3 & 4 \\ 3 & 4 \end{bmatrix} \\ 4 \begin{bmatrix} 1 & 2 \\ 1 & 2 \end{bmatrix} + 5 \begin{bmatrix} 3 & 4 \\ 3 & 4 \end{bmatrix} \end{bmatrix} = \begin{bmatrix} 11 & 16 \\ 19 & 28 \end{bmatrix}$$

$$\begin{aligned}
 A &= \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} = \begin{bmatrix} u_1 v_1 & u_1 v_2 & \cdots & u_1 v_n \\ u_2 v_1 & u_2 v_2 & \cdots & u_2 v_n \\ \vdots & \vdots & \vdots & \vdots \\ u_m v_1 & u_m v_2 & \cdots & u_m v_n \end{bmatrix} = \\
 &= \begin{bmatrix} u_1 \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} \\ u_2 \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} \\ \vdots \\ u_m \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} \end{bmatrix} = \begin{bmatrix} \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} v_1 & \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} v_2 & \cdots & \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} v_n \end{bmatrix}
 \end{aligned}$$

$$A = \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} = \begin{bmatrix} u_1 v_1 & u_1 v_2 & \cdots & u_1 v_n \\ u_2 v_1 & u_2 v_2 & \cdots & u_2 v_n \\ \vdots & \vdots & \vdots & \vdots \\ u_m v_1 & u_m v_2 & \cdots & u_m v_n \end{bmatrix} =$$

$$\begin{bmatrix} u_1 \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} \\ u_2 \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} \\ \vdots \\ u_m \begin{bmatrix} v_1 & v_2 & \cdots & v_n \end{bmatrix} \end{bmatrix} = \begin{bmatrix} \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} v_1 & \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} v_2 & \cdots & \begin{bmatrix} u_1 \\ \vdots \\ u_m \end{bmatrix} v_n \end{bmatrix}$$

Exemplo:

$$A = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} \begin{bmatrix} 1 & 2 & 5 \end{bmatrix} = \begin{bmatrix} 1 & 2 & 5 \\ 1 & 2 & 5 \\ 1 & 2 & 5 \end{bmatrix}$$

Matrizes podem ser divididas em blocos

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

- Matriz 4×6 : Blocos 2×2 resultam em uma matriz em blocos 2×3 .
- Se B é uma matriz 4×6 , com mesma divisão em blocos, $A + B$ é calculado somando cada bloco separadamente.
- Se os blocos de uma matriz A podem multiplicar blocos de uma matriz B , temos que:


$$\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \begin{bmatrix} B_{11} \\ B_{21} \end{bmatrix} = \begin{bmatrix} A_{11}B_{11} + A_{12}B_{21} \\ A_{21}B_{11} + A_{22}B_{21} \end{bmatrix}$$

Definição

- ① $\mathcal{C}(A) = \{Ax \mid x \in \mathbb{R}^n\}.$
- ② Espaço vetorial gerado pelas colunas de A .

Base de $\mathcal{C}(A)$

- ① Conjunto de vetores LI que gera $\mathcal{C}(A)$.
- ② A dimensão de $\mathcal{C}(A)$ é o total de vetores coluna LI de A .



$$A = \begin{bmatrix} 1 & 0 \\ 4 & 3 \\ 2 & 3 \end{bmatrix}$$

$$b = .4 \begin{bmatrix} 1 \\ 4 \\ 2 \end{bmatrix} + .3 \begin{bmatrix} 0 \\ 3 \\ 3 \end{bmatrix}$$

$$Ax = b \text{ has } x = \begin{bmatrix} .4 \\ .3 \end{bmatrix}$$

Plane = $\mathcal{C}(A)$ = all vectors Ax

Introduction to Linear Algebra - Gilbert Strang

- Pré-multiplicando A por y^T , onde $y \in \mathbb{R}^m$, geramos uma linha (n dimensional) que é uma *agregação* das m linhas de A .

$$\bullet y^T A = [\ y_1 \ \ y_2 \ \ \dots \ \ y_m \] \begin{bmatrix} a_1^T \\ a_2^T \\ \dots \\ a_m^T \end{bmatrix} = \sum_{i=1}^m y_i a_i^T.$$

- Ou, transpondo A , temos o conjunto dos vetores $A^T y$ para algum $y \in \mathbb{R}^m$.
- Ou seja, o espaço linha de A é o espaço coluna de A^T .

Definições

- 1 Conjunto formado pelos vetores $A^T y$, para algum y .
- 2 Espaço vetorial gerado pelas linhas linearmente independentes de A , i.e., $\mathcal{C}(A^T) = \text{span} (\{a_1^T, a_2^T, \dots, a_m^T\})$.
- 3 Conjunto de vetores v_i resultantes das combinações lineares das linhas de A .

Base de $\mathcal{C}(A^T)$

- 1 Conjunto das linhas da matriz A que são linearmente independentes.
- 2 A dimensão de $\mathcal{C}(A^T)$ ($\dim \mathcal{C}(A^T)$) será o total de linhas linearmente independentes.

Definição

$r(A) = \text{dimensão de } \mathcal{C}(A) = \text{dimensão de } \mathcal{C}(A^T)$.

Propriedades

- ① $r(A) \leq \min(m, n)$.
- ② $r(A) = r(A^T)$.
- ③ $r(A^T A) = r(A A^T) = r(A) = r(A^T)$.
- ④ $r(AB) \leq \min(r(A), r(B))$.
- ⑤ $r(A + B) \leq r(A) + r(B)$.
- ⑥ Se $A \in \mathbb{R}^{m \times r}$, $B \in \mathbb{R}^{r \times n}$, $r(A) = r(B) = n$ então $r(AB) = n$.

- Uma matriz A possui rank completo quando $r(A) = \min(m, n)$.
- Deficiência de posto ou de rank: quando $\min(m, n) - r(A) > 0$.

A matriz C é formada pelas colunas linearmente independentes de A

- ➊ Incluir coluna 1 de A em C , caso não seja o vetor nulo.
 - ➋ Incluir coluna 2 de A em C , caso não seja múltipla da coluna 1.
 - ➌ Incluir coluna 3 de A em C , caso não seja combinação linear das colunas 1 e 2. *Continue.*
-
- C é formada por r colunas de A , ($r \leq n$).
 - As colunas de C formam UMA base para $\mathcal{C}(A)$.
 - Colunas não incluídas são combinações lineares da base escolhida para $\mathcal{C}(A)$, i.e. das colunas LI de A .

$$A = \begin{bmatrix} 1 & 3 & 8 \\ 1 & 2 & 6 \\ 0 & 1 & 2 \end{bmatrix}, C = \begin{bmatrix} 1 & 3 \\ 1 & 2 \\ 0 & 1 \end{bmatrix}, r = \mathbf{2}$$

$$A = \begin{bmatrix} 1 & -1 & 3 \\ 2 & 0 & 4 \end{bmatrix}, C = \begin{bmatrix} 1 & 3 \\ 2 & 4 \end{bmatrix}, r = \mathbf{2}$$

(fatoração CR alternativa à apresentada pelo algoritmo)

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 0 & 4 & 5 \\ 0 & 0 & 6 \end{bmatrix}, C = A, r = \mathbf{3}, \mathcal{C}(A) = \mathbb{R}^3$$

$$A = \begin{bmatrix} 1 & 2 & 5 \\ 1 & 2 & 5 \\ 1 & 2 & 5 \end{bmatrix}, C = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}, r = \mathbf{1}$$

Suponha que as r primeiras colunas de A sejam as r colunas LI:

$$A = [\ A_1 \ A_2 \ \cdots \ A_r \] R = [\ A_1 \ A_2 \ \cdots \ A_r \] [\ I_r \ ? \]$$

A matriz R é a forma escada reduzida da matriz A

- ① Para as colunas em C , incluir nas colunas de R as entradas da matriz identidade.
- ② Para as demais colunas em R , incluir as combinações para obter as colunas em A que não estão em C .

$$A = \begin{bmatrix} 1 & 3 & 8 \\ 1 & 2 & 6 \\ 0 & 1 & 2 \end{bmatrix}, C = \begin{bmatrix} 1 & 3 \\ 1 & 2 \\ 0 & 1 \end{bmatrix}, R = \begin{bmatrix} 1 & 0 & 2 \\ 0 & 1 & 2 \end{bmatrix}$$

$$A = \begin{bmatrix} 1 & -1 & 3 \\ 2 & 0 & 4 \end{bmatrix}, C = \begin{bmatrix} 1 & 3 \\ 2 & 4 \end{bmatrix}, R = \begin{bmatrix} 1 & 2 & 0 \\ 0 & -1 & 1 \end{bmatrix}$$

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 0 & 4 & 5 \\ 0 & 0 & 6 \end{bmatrix}, C = A, R = I$$

$$A = \begin{bmatrix} 1 & 2 & 5 \\ 1 & 2 & 5 \\ 1 & 2 & 5 \end{bmatrix}, C = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}, R = [1 \ 2 \ 5]$$

Se $r(D) = n$ então D é igual à soma de n matrizes de rank 1
(Produto externo de 2 vetores):

$$D = AB = [\begin{array}{cccc} A_1 & A_2 & \dots & A_n \end{array}] \begin{bmatrix} b_1^T \\ b_2^T \\ \vdots \\ b_n^T \end{bmatrix} = \sum_{i=1}^n A_i b_i^T$$

Exemplo:

$$\begin{bmatrix} 1 & 3 \\ 1 & 2 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 2 \\ 0 & 1 & 2 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} \begin{bmatrix} 1 & 0 & 2 \end{bmatrix} + \begin{bmatrix} 3 \\ 2 \\ 1 \end{bmatrix} \begin{bmatrix} 0 & 1 & 2 \end{bmatrix} =$$
$$\begin{bmatrix} 1 & 3 & 8 \\ 1 & 2 & 6 \\ 0 & 1 & 2 \end{bmatrix}$$

Definição

A matrix $B \in \mathbb{R}^{n \times n}$ que satisfaz as condições

$$AB = I \text{ e } BA = I$$

é chamada matriz inversa de A , denotada por $B = A^{-1}$.

- Nem toda matriz $n \times n$ possui inversa.
- Matrizes inversíveis são chamadas de **matrizes não singulares**.
- Matrizes não inversíveis são chamadas de **matrizes singulares**.
- Quando uma matriz possui inversa, esta é única.

A inversa de A existe se:

- 1 A é não singular.
- 2 $r(A) = n$. A é uma matriz de rank completo.
- 3 $\det(A) \neq 0$.
- 4 $Ax = 0_n \implies x = 0_n$.

As afirmativas acima são equivalentes.

Toda matriz $A \in \mathbb{R}^{m \times n}$ gera 4 subespaços fundamentais



- 1 Espaço coluna $\mathcal{C}(A)$: todas as combinações das colunas de A . Subespaço de \mathbb{R}^m .
- 2 Espaço linha $\mathcal{C}(A^T)$: todas as combinações das linhas de A . Subespaço de \mathbb{R}^n .
- 3 Espaço nulo $\mathcal{N}(A)$: todas as soluções x para $Ax = 0_m$. Subespaço de \mathbb{R}^n .
- 4 Espaço nulo à esquerda $\mathcal{N}(A^T)$: todas as soluções y para $A^T y = 0_n$. Subespaço de \mathbb{R}^m .

Exemplo: $A = \begin{bmatrix} 1 & 2 \\ 3 & 6 \end{bmatrix}$, $m = 2$, $n = 2$.

Subespaços gerados pertencem ao \mathbb{R}^2 (linhas infinitas):

- ① Espaço coluna $\mathcal{C}(A)$ é a linha em $u = \begin{bmatrix} 1 \\ 3 \end{bmatrix}$
 $\mathcal{C}(A) = \{\alpha u : \alpha \in \mathbb{R}\}$.
- ② Espaço $\mathcal{C}(A^T)$ é a linha em $v = \begin{bmatrix} 1 \\ 2 \end{bmatrix}$, $\mathcal{C}(A^T) = \{\alpha v : \alpha \in \mathbb{R}\}$.
- ③ Espaço nulo $\mathcal{N}(A)$ é a linha em $x = \begin{bmatrix} 2 \\ -1 \end{bmatrix}$
 $\mathcal{N}(A) = \{\alpha x : \alpha \in \mathbb{R}\}$.
- ④ Espaço nulo à esquerda $\mathcal{N}(A^T)$ é a linha em $y = \begin{bmatrix} 3 \\ -1 \end{bmatrix}$;
 $\mathcal{N}(A^T) = \{\alpha y : \alpha \in \mathbb{R}\}$.


Exemplo: $A = \begin{bmatrix} 1 & 2 \\ 3 & 6 \end{bmatrix}$, $m = 2$, $n = 2$.



Linear Algebra and Learning from Data - Gilbert Strang

Dimensões

- 1 Dimensão de $\mathcal{C}(A)$: $r = \text{rank}(A)$.
- 2 Dimensão de $\mathcal{C}(A^T)$: $r = \text{rank}(A)$.
- 3 Dimensão de $\mathcal{N}(A)$: $n - r$.
- 4 Dimensão de $\mathcal{N}(A^T)$: $m - r$.



Introduction to Linear Algebra - Gilbert Strang

Ortogonalidade significa perpendicular.

- ① **Vetores ortogonais.** $x^T y = 0$.
- ② **Bases ortogonais de um subespaço.** $v_i^T v_j = 0, \forall \{v_i, v_j\}$.
 - **Bases ortonormais de um subespaço.** $v_i^T v_i = 1, \forall v_i$
- ③ **Subespaços ortogonais \mathcal{R} e \mathcal{N} .** Todo vetor em \mathcal{R} é ortogonal a todo vetor em \mathcal{N} .
- ④ **Matrizes esbeltas Q ($m >> n$) com colunas ortonormais.**
 - $Q^T Q = I_n$.
 - $\|Qx\|^2 = (Qx)^T (Qx) = x^T Q^T Q x = x^T x = \|x\|^2 \rightarrow \|Qx\| = \|x\|$.
- ⑤ **Matrizes ortogonais.** Matrizes ortonormais $n \times n$.
 - $Q^T = Q^{-1}$.
 - $Q^T Q = I, Q Q^T = I$.
 - $(Qx)^T (Qy) = x^T y, \forall x, y$.
 - Norma Euclideana e ângulos não são alterados pela matriz Q .
 - As colunas de uma matriz ortogonal são uma base ortonormal para \mathbb{R}^n .
 - As linhas de uma matriz ortogonal são uma base ortonormal (provavelmente diferente) para \mathbb{R}^n
 - **Computar com Q não acarreta overflow.**

- Vetores Ortogonais e Teorema de Pitágoras.

$$\text{Se } x^T y = 0 \rightarrow \|x + y\|^2 = \|x\|^2 + \|y\|^2.$$


- Bases ortogonais.

Base Canônica do \mathbb{R}^3 . $i = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$, $j = \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix}$, $k = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$

- Subespaços Ortogonais.

$Ax = 0_m$: Todas as linhas de A e suas combinações são ortogonais aos vetores $x \in \mathcal{N}(A)$.

$A^T y = 0_n$: Todas as colunas de A e suas combinações são ortogonais aos vetores $x \in \mathcal{N}(A^T)$.



Introduction to Linear Algebra - Gilbert Strang

- Matrizes *esbeltas* Q com colunas ortonormais: $Q^T Q = I$.

$$Q_1 = \frac{1}{3} \begin{bmatrix} 2 \\ 2 \\ -1 \end{bmatrix}, \quad Q_2 = \frac{1}{3} \begin{bmatrix} 2 & 2 \\ 2 & -1 \\ -1 & 2 \end{bmatrix}$$

Definição

Todo vetor x linearmente dependente com Ax é chamado de autovetor de $A \in \mathbb{R}^{n \times n}$. Ou seja: $Ax = \lambda x$.


- x é um autovetor de A .
- $\lambda \in \mathbb{C}$ é um autovalor de A (o autovalor pode ser complexo).
- (λ, x) é autopar de A .

$$\lambda = 1 \quad Ax_1 = x_1 = \begin{bmatrix} 0.6 \\ 0.4 \end{bmatrix}$$
$$\lambda = 0.5 \quad Ax_2 = \lambda_2 x_2 = \begin{bmatrix} 0.5 \\ -0.5 \end{bmatrix}$$
$$x_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

Os autovetores da matriz A também são autovetores da matriz A^k .

$$k = 2 : A(Ax) = A(\lambda x) = \lambda(Ax) = \lambda^2 x.$$

$$k = 3, \dots : A^k x = \lambda^k x.$$



Introduction to Linear Algebra - Gilbert Strang

- Os autovetores da matriz A também são autovetores da matriz A^{-1} :

$$\begin{aligned}(A^{-1}A)x &= A^{-1}(\lambda x) \\ x &= A^{-1}(\lambda x) \\ A^{-1}x &= \frac{1}{\lambda}x\end{aligned}$$

- Para matrizes com n autovetores $\mathbf{L}I, x^1, \dots, x^n$ com n autovalores $\lambda_1 > \lambda_2 > \dots > \lambda_n$:

$$\begin{aligned}\forall v \in \mathbb{R}^n, v &= c_1x^1 + c_2x^2 + \dots + c_nx^n \\ Av &= A(c_1x^1 + c_2x^2 + \dots + c_nx^n) \\ Av &= c_1Ax^1 + c_2Ax^2 + \dots + c_nAx^n \\ Av &= c_1\lambda_1x^1 + c_2\lambda_2x^2 + \dots + c_n\lambda_nx^n \\ A^k v &= c_1\lambda_1^kx^1 + c_2\lambda_2^kx^2 + \dots + c_n\lambda_n^kx^n\end{aligned}$$

Se $|\lambda_1| > 1$, o componente $c_1\lambda_1^kx^1$ crescerá com o aumento de k .

Se $|\lambda_2| < 1$ então o componente $c_2\lambda_2^kx^2 \rightarrow 0$ quando $k \rightarrow \infty$ e

$A^k v$ é dominado por $c_1\lambda_1^kx^1$.

- Se A é deslocada de $A + sI$, os autovalores de $A + sI$ são a soma dos autovalores de A com s :

$$(A + sI)x = Ax + sx = \lambda x + sx = (\lambda + s)x.$$

- Para toda matriz B inversível, os autovalores de $C = BAB^{-1}$ são iguais aos autovalores de A .

$$(BAB^{-1})(Bx) = BAx = B\lambda x = \lambda(Bx).$$

As matrizes A e $C = BAB^{-1}$ são denominadas *similares* e, como tal, tem o mesmo espectro (conjunto de autovalores).

- Se B (inversível) é a matriz que caracteriza a similaridade de A e de C , um autovetor de C é Bx , onde x é autovetor de A . A existência de B, B^{-1} satisfazendo $C = BAB^{-1}$ garante a similaridade entre A e C . A consequência é que A e C possuem os mesmos autovalores.

Exemplo:

$S = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix}$ tem como autovetores $v_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$, com autovalor $\lambda_1 = 3$ e $v_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$, com autovalor $\lambda_2 = 1$.

Propriedades

- Traço: A soma $\lambda_1 + \lambda_2 = 4$ é igual a soma dos elementos na diagonal de S ($2+2=4$).
- Determinante: O produto $\lambda_1\lambda_2 = 3$ é igual ao determinante de S ($4-1=3$).
- Matrizes simétricas $S = S^T$ possuem sempre autovalores reais.
- Matrizes com $\lambda_1 \neq \lambda_2 \neq \dots \neq \lambda_n$ possuem autovetores li.

- Os autovalores de $A + B$ normalmente diferem da soma dos autovalores de A, B . Isto é, $\lambda(A + B)$ difere de $\lambda(A) + \lambda(B)$.
- Os autovalores $\lambda(AB)$ de AB normalmente diferem de $\lambda(A)\lambda(B)$.
- Sobre autovalores com multiplicidade algébrica maior que 1 (repetidos): Autovalores $\lambda_1 = \lambda_2$ podem ou não ter autovetores independentes.
- Os autovetores de A são ortogonais se e somente se $A^T A = AA^T$.

Temos:

$$\begin{aligned} Ax &= \lambda x \\ (A - \lambda I)x &= 0_n \end{aligned}$$

- Os autovetores de A geram o espaço $\mathcal{N}(A - \lambda I)$.
- Se $(A - \lambda I)x = 0_n$ tem solução com $x \neq 0_n$, $(A - \lambda I)$ não é inversível (singular) e $\det(A - \lambda I) = 0$.
- Resolva $\det(A - \lambda I) = 0$, i.e., encontre as n raízes do polinômio característico $\det(A - \lambda I)$ que são os n autovalores de A .
- Para cada autovalor λ resolva $(A - \lambda I)x = 0_n$ ou $Ax = \lambda x$ para encontrar o autovetor correspondente.

Exemplo: Encontre os autovalores e autovetores da matriz

$$A = \begin{bmatrix} 8 & 3 \\ 2 & 7 \end{bmatrix}.$$

$$\det(A - \lambda I) = \begin{bmatrix} 8 - \lambda & 3 \\ 2 & 7 - \lambda \end{bmatrix} = \lambda^2 - 15\lambda + 50 = (\lambda - 10)(\lambda - 5) = 0$$

$$\lambda_1 = 10, x_1 = \begin{bmatrix} 3 \\ 2 \end{bmatrix} \text{ e } \lambda_2 = 5, x_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

Matrizes simétricas (i.e., $S = S^T$) possuem as seguintes propriedades:

- ① Todos os n autovalores λ são números reais.
- ② Os n autovetores q podem ser escolhidos de tal forma que sejam ortonormais.
- ③ Toda matriz simétrica S pode ser fatorada na forma de $S = Q\Lambda Q^T$ (encontrar os fatores Q, Λ consiste na diagonalização de S), onde Q é ortogonal e Λ é diagonal.
 - ⇒ Isto é, toda matriz simétrica é diagonalizável, ou seja, é similar a uma matriz diagonal.
 - ⇒ Portanto o espectro de S é o espectro de Λ .

Matrizes SPD possuem as seguintes propriedades (se uma propriedade é satisfeita, todas as demais também são):

- ① Teste 1: Todos os autovalores são positivos.
- ② Teste 2: A forma quadrática (também chamada energia) $x^T S x$ é positiva para todos os vetores $x \neq 0_n$.
- ③ Teste 3: S admite uma fatoração $S = A^T A$ (forma de Gram), para A com colunas independentes. (Obs: Em particular, S admite uma fatoração de Cholesky $S = LL^T$, onde L é triangular inferior com diagonal positiva).
- ④ Teste 4: Determinantes das submatrizes principais são positivos.
- ⑤ Teste 5: Possuem pivôs positivos (processo de Eliminação).

Teste 2: Energia

$$x^T S x = \begin{bmatrix} x_1 & x_2 \end{bmatrix} \begin{bmatrix} 2 & 4 \\ 4 & 9 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = 2x_1^2 + 8x_1x_2 + 9x_2^2.$$

- Este valor é positivo para todo x_1 e x_2 , exceto para $(x_1, x_2) = (0, 0)$? **Sim, pois é a soma de quadrados.**

$$x^T S x = 2x_1^2 + 8x_1x_2 + 9x_2^2 = 2(x_1 + 2x_2)^2 + x_2^2 > 0.$$

- Se $\lambda > 0$ então $x^T S x > 0$:

$$Sx = \lambda x \rightarrow x^T S x = \lambda x^T x. \text{ Então } \lambda > 0 \text{ resulta em } x^T S x > 0.$$

Uso do teste de Energia para definir se uma matriz é SPD:

Se S_1 e S_2 são matrizes SPD, então $S_1 + S_2$ é uma matriz SPD.

Prova:

$$x^T(S_1 + S_2)x = x^T S_1 x + x^T S_2 x > 0 + 0.$$

Os autovalores e autovetores de $S_1 + S_2$ são computacionalmente caros para serem calculados.

Teste 3: Se S é SPD então $S = A^T A$, para A com colunas independentes.

$$x^T S x = x^T A^T A x = (Ax)^T (Ax) = \|Ax\|^2.$$

- Energia é o quadrado da norma Euclideana de Ax .
- A energia é positiva se $Ax \neq 0$.
- $Ax \neq 0$ para algum $x \neq 0$ somente quando as colunas de A são linearmente independentes.

Por exemplo:

$$S = A^T A = \begin{bmatrix} 1 & 1 \\ 1 & 2 \\ 1 & 3 \end{bmatrix} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 3 \end{bmatrix} = \begin{bmatrix} 2 & 3 & 4 \\ 3 & 5 & 7 \\ 4 & 7 & 10 \end{bmatrix}.$$

não é positiva definida:

- Coluna 2 de A é combinação linear das colunas 1 e 3 (coluna 1 + coluna 3 = $2 \times$ coluna 2).
- $A^T A$ possui um autovalor com $\lambda = 0$. Neste caso $S = A^T A$ é semipositiva definida.
- Teste 3 garante que $S = A^T A$ seja, pelo menos, uma matriz simétrica semipositiva definida, pois $x^T S x = ||Ax||^2$ nunca será negativa.

Teste 4 e Teste 5: Determinantes e Pivôs.

- O teste do determinante é pouco custoso para matrizes pequenas.

$$S = \begin{bmatrix} 2 & -1 & & \\ -1 & 2 & -1 & \\ & -1 & 2 & -1 \\ & & -1 & 2 \\ & & & -1 & 2 \end{bmatrix}$$

has

1st determinant $D_1 = 2$
2nd determinant $D_2 = 3$
3rd determinant $D_3 = 4$
4th determinant $D_4 = 5$

Linear Algebra and Learning from data - Gilbert Strang

- Pivôs (valores na diagonal da matriz após o processo de eliminação) são positivos, pois o k -ésimo pivô é dado por:

$$\frac{D_k}{D_{k-1}}$$