

## 第一讲 预备知识：线性代数基础

- 1 线性空间与内积空间
- 2 矩阵与投影
- 3 向量范数与矩阵范数
- 4 矩阵标准型
- 5 几类特殊矩阵
- 6 Kronecker 积

# 1 | 线性空间与内积空间

- 数域, 如:  $\mathbb{Q}, \mathbb{R}, \mathbb{C}$
- 线性空间, 如:  $\mathbb{R}^n, \mathbb{C}^n, \mathbb{R}^{n \times n}, \mathbb{R}^{m \times m}, \mathbb{R}^{m \times n}, C[a, b]$
- 线性相关与线性无关, 秩, 基, 维数
- 子空间: 判别, 和, 维数公式
- 张成子空间:  $\text{span}\{x_1, x_2, \dots, x_k\}, \text{span}(A)$
- 像空间 (值域, 列空间)  $\text{Ran}(A)$ , 零空间 (核)  $\text{Ker}(A)$ , 行空间  $\text{Ran}(A^T)$ , 左零空间  $\text{Ker}(A^T)$



为了描述方便, 线性空间中的元素通常称为 **向量**.

## 直和

设  $S_1, S_2$  是子空间, 若  $S_1 + S_2$  中的任一元素都可唯一表示成

$$x = x_1 + x_2, \quad x_1 \in S_1, x_2 \in S_2,$$

则称  $S_1 + S_2$  为直和, 记为  $S_1 \oplus S_2$ .

说明

本讲义只考虑有限维线性空间.

## 直和的判别与重要性质

**定理 (判别定理)** 设  $S_1, S_2$  是线性空间  $S$  的两个子空间, 则下面的论述等价:

- (1)  $S_1 + S_2$  是直和;
- (2)  $S_1 + S_2$  中的零元素表示方法唯一;
- (3)  $S_1 \cap S_2 = \{0\}$ ;
- (4)  $\dim(S_1) + \dim(S_2) = \dim(S_1 + S_2)$ ;

**定理 (重要性质)** 设  $S_1$  是线性空间  $S$  的一个子空间, 则存在  $S$  的另一个子空间  $S_2$ , 使得

$$S = S_1 \oplus S_2.$$

# 内积空间

内积与内积空间的定义与基本性质 (见讲义或线性代数教材)

例 常用内积:

-  $\mathbb{R}^n / \mathbb{C}^n$ :  $(x, y) = y^T x$  /  $(x, y) = y^* x$  (标准内积, 点积)

-  $\mathbb{R}^{m \times n}$ :  $(A, B) = \text{tr}(B^T A)$

-  $C[a, b]$ :  $(f, g) = \int_a^b f(x)g(x) dx$



以上是常用内积, 但并不是唯一内积.

## 正交与正交补

**正交:** 向量与向量, 向量与子空间, 子空间与子空间 (见讲义或线代教材)

**定理** 设  $S_1, S_2$  是内积空间  $S$  的两个子空间, 如果  $S_1 \perp S_2$ , 则  $S_1 + S_2$  是直和.

(留作课外自习)

**例 (正交基)** 设  $x_1, x_2, \dots, x_n \in \mathbb{R}^n$ . 若  $x_1, x_2, \dots, x_n$  线性无关, 则  $\{x_1, x_2, \dots, x_n\}$  构成  $\mathbb{R}^n$  的一组基. 进一步, 如果  $x_1, x_2, \dots, x_n$  相互正交, 即

$$(x_i, x_j) = x_j^T x_i = 0, \quad i, j = 1, 2, \dots, n,$$

则称它们是一组**正交基**. 如果还满足

$$(x_i, x_i) = x_i^T x_i = 1, \quad i = 1, 2, \dots, n,$$

则称它们是一组**标准正交基**或**规范正交基**.

特别地, 记  $e_i$  为单位矩阵的第  $i$  列, 则  $\{e_1, e_2, \dots, e_n\}$  构成  $\mathbb{R}^n$  的一组标准正交基, 这组基通常称为**自然基**.



任何一组基都可以通过 Gram-Schmidt 正交化过程构造标准正交基.

## 正交补

**定义 (正交补)** 设  $S_1$  是内积空间  $S$  的一个子空间, 则  $S_1$  的**正交补**定义为

$$S_1^\perp \triangleq \{ x \in S : x \perp S_1 \},$$

即  $S$  中所有与  $S_1$  正交的元素组成的集合.

可以证明  $S_1^\perp$  也是子空间, 且

**定理** 设  $S_1$  是内积空间  $S$  的一个有限维子空间, 则  $S_1^\perp$  存在唯一, 且


$$S = S_1 \oplus S_1^\perp.$$



# 2 | 矩阵与投影

## 矩阵的秩、特征值、特征向量

- ▶ 矩阵的秩
- ▶ 特征多项式, 特征值, 特征向量, 左特征向量, 特征对
- ▶ 代数重数和几何重数, 特征空间
- ▶ 零化多项式, 最小多项式
- ▶ 可对角化, 特征值分解/谱分解, 可对角化的充要条件

 为了讨论方便, 本节仅考虑实数情形, 对于复数情形, 结论类似.

## 一些基本性质

**定理** 设  $A, B \in \mathbb{R}^{m \times n}$ , 则

- $\text{rank}(A) \leq \min\{m, n\}$ ;
- $\text{rank}(A^T) = \text{rank}(A)$ ;
- $\text{rank}(A^T A) = \text{rank}(A A^T) = \text{rank}(A)$ ;
- $\text{rank}(A + B) \leq \text{rank}(A) + \text{rank}(B)$ ;
- 对任意非奇异矩阵  $P \in \mathbb{R}^{m \times m}$  和  $Q \in \mathbb{R}^{n \times n}$ , 有

$$\text{rank}(PA) = \text{rank}(AQ) = \text{rank}(PAQ) = \text{rank}(A).$$

## 矩阵秩分解

**定理** 设  $\text{rank}(A) = \ell$ , 则存在非奇异矩阵  $P \in \mathbb{R}^{m \times m}$  和  $Q \in \mathbb{R}^{n \times n}$  使得

$$A = P \begin{bmatrix} I_\ell & 0 \\ 0 & 0 \end{bmatrix} Q.$$

进一步,  $\text{rank}(A) = \text{rank}(B)$  当且仅当存在非奇异矩阵  $P \in \mathbb{R}^{m \times m}$  和  $Q \in \mathbb{R}^{n \times n}$  使得  $A = PBQ$ .

**推论 (满秩分解)** 设  $\text{rank}(A) = \ell$ , 则存在非奇异矩阵  $F \in \mathbb{R}^{m \times \ell}$  和  $G \in \mathbb{R}^{\ell \times n}$  使得

$$A = FG.$$

## 秩的更多性质

**定理** 设  $A \in \mathbb{R}^{m \times k}$ ,  $B \in \mathbb{R}^{k \times n}$ , 则

$$\text{rank}(A) + \text{rank}(B) - k \leq \text{rank}(AB) \leq \min\{\text{rank}(A), \text{rank}(B)\}.$$

**推论** 设  $A \in \mathbb{R}^{m \times k}$ ,  $B \in \mathbb{R}^{k \times m}$ ,  $k \leq m$ . 若  $A$  和  $B$  都是满秩矩阵, 则

$$\text{rank}(AB) = \text{rank}(BA) = \text{rank}(A) = \text{rank}(B) = k.$$

## 张成的线性空间

设  $x_1, x_2, \dots, x_k \in \mathbb{R}^n$ , 记

$$\text{span}\{x_1, x_2, \dots, x_k\} \triangleq \{ \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_k x_k : \alpha_1, \alpha_2, \dots, \alpha_k \in \mathbb{R} \},$$

为由  $x_1, x_2, \dots, x_k$  张成的线性空间

### $A \in \mathbb{R}^{m \times n}$ 相关的四个子空间

- ▶ 像空间, 列空间, 值域:  $\text{Ran}(A) = \text{span}\{A\}$
- ▶ 零空间, 核:  $\text{Ker}(A) \triangleq \{ x \in \mathbb{R}^n : Ax = 0 \}$
- ▶ 行空间:  $\text{Ran}(A^T) = \text{span}\{A^T\}$
- ▶ 左零空间:  $\text{Ker}(A^T)$

**定理** 设  $A \in \mathbb{R}^{m \times n}$ , 则有

- $\dim(\text{Ran}(A)) = \dim(\text{Ran}(A^T)) = \text{rank}(A)$ ;
- $\dim(\text{Ker}(A)) + \dim(\text{Ran}(A^T)) = n$ ;
- $\text{Ran}(A^T A) = \text{Ran}(A^T)$ ,  $\text{Ker}(A^T A) = \text{Ker}(A)$ .

**例** 设  $A \in \mathbb{R}^{m \times n}$ , 则

$$\text{Ran}(A)^\perp = \text{Ker}(A^T).$$

(留作课外自习, 证明见讲义)

**例** 设  $A \in \mathbb{R}^{m \times n}$ , 则由上例可知

$$\text{Ker}(A) \oplus \text{Ran}(A^T) = \mathbb{R}^n, \quad \text{Ker}(A^T) \oplus \text{Ran}(A) = \mathbb{R}^m.$$

## 特征值与特征向量

特征值相关性质:  $A \in \mathbb{R}^{n \times n}$

- ▶  $\lambda_1 \lambda_2 \cdots \lambda_n = \det(A)$
- ▶  $\lambda_1 + \lambda_2 + \cdots + \lambda_n = \text{tr}(A)$  (矩阵的迹:  $\text{tr}(A) \triangleq a_{11} + a_{22} + \cdots + a_{nn}$ )
- ▶ 矩阵的谱:  $\sigma(A) \triangleq \{ \lambda_1, \lambda_2, \dots, \lambda_n \}$
- ▶ 谱分解/特征值分解 (可对角化):  $X^{-1}AX = \Lambda$  或  $A = X\Lambda X^{-1}$
- ▶ 矩阵的谱半径:  $\rho(A) \triangleq \max_{\lambda \in \sigma(A)} |\lambda|$

**定理** 矩阵的特征值关于矩阵元素是连续的.

 思考:

- 设  $A \in \mathbb{R}^{n \times n}$ , 则  $A^T$  与  $A$  的特征值和特征向量是什么关系?
- $A^{-1}$  与  $A$  的特征值和特征向量是什么关系?
- 设  $p(t)$  是多项式或有理函数, 则  $p(A)$  与  $A$  的特征值和特征向量是什么关系?



## 特征值估计: Bendixson 定理

**定理** 设  $A \in \mathbb{C}^{n \times n}$ ,  $H$  和  $S$  分别为  $A$  的 Hermite 部分和 Skew-Hermite 部分:

$$H \triangleq \frac{1}{2}(A + A^*), \quad S \triangleq \frac{1}{2}(A - A^*),$$

则

$$\lambda_{\min}(H) \leq \operatorname{Re}(\lambda(A)) \leq \lambda_{\max}(H),$$

$$\lambda_{\min}(-\mathbf{i}S) \leq \operatorname{Im}(\lambda(A)) \leq \lambda_{\max}(-\mathbf{i}S).$$

其中  $\operatorname{Re}(\cdot)$  和  $\operatorname{Im}(\cdot)$  分别表示实部和虚部,  $\mathbf{i}$  是虚部单位. 即: 特征值的实部的取值范围由其 Hermite 部分确定, 而虚部则由其 Skew-Hermite 部分确定.

## 特征值估计: Gerschgorin 圆盘

设  $A = [a_{ij}] \in \mathbb{C}^{n \times n}$ , 则  $A$  的 **Gerschgorin 圆盘** (盖尔圆盘) 定义为

$$D_i \triangleq \left\{ z \in \mathbb{C} : |z - a_{ii}| \leq \sum_{j=1, j \neq i}^n |a_{ij}| \right\}, \quad i = 1, 2, \dots, n.$$

**定理 (Gerschgorin 圆盘定理)** 设  $A \in \mathbb{C}^{n \times n}$ , 则  $A$  的所有特征值都包含在  $A$  的 Gerschgorin 圆盘的并集中, 即  $\sigma(A) \subset \bigcup_{i=1}^n D_i$ . (留作课外自习, 证明见讲义)

**定理** 如果  $\bigcup_{i=1}^n D_i$  可分解成两个不相交的子集  $S$  和  $T$ , 其中  $S$  由  $k$  个圆盘组成, 而  $T$  由其它  $n - k$  个圆盘组成, 则  $S$  恰好包含  $A$  的  $k$  个特征值, 而  $T$  则包含其它  $n - k$  个特征值.

## 不变子空间

设  $A \in \mathbb{R}^{n \times n}$ , 子空间  $S \subseteq \mathbb{R}^n$ . 若  $AS \subseteq S$ , 即对任意  $x \in S$ , 都有  $Ax \in S$ , 则称  $S$  为  $A$  的一个 **不变子空间**.

### 一类特殊的不变子空间

设  $x_1, x_2, \dots, x_m$  是  $A$  的一组线性无关的特征向量, 则  $\text{span}\{x_1, x_2, \dots, x_m\}$  是  $A$  的一个  $m$  维不变子空间.

## 不变子空间的重要性质

**定理** 设  $A \in \mathbb{R}^{n \times n}$ ,  $X \in \mathbb{R}^{n \times k}$  且  $\text{rank}(X) = k$ , 则  $\text{span}(X)$  是  $A$  的不变子空间的充要条件是存在一个矩阵  $B \in \mathbb{R}^{k \times k}$  使得

$$AX = XB,$$

此时,  $B$  的特征值都是  $A$  的特征值.

(板书)

**推论** 设  $A \in \mathbb{R}^{n \times n}$ ,  $X \in \mathbb{R}^{n \times k}$  且  $\text{rank}(X) = k$ . 若存在  $B \in \mathbb{R}^{k \times k}$  使得  $AX = XB$ , 则  $(\lambda, v)$  是  $B$  的特征对当且仅当  $(\lambda, Xv)$  是  $A$  的特征对.

(留作课外自习)

## 投影变换

设  $S = S_1 \oplus S_2$ , 则  $S$  中的任意向量  $x$  都可唯一表示为

$$x = x_1 + x_2, \quad x_1 \in S_1, x_2 \in S_2.$$

我们称  $x_1$  为  $x$  沿  $S_2$  到  $S_1$  上的投影, 记为  $x|_{S_1}$ .

 由于  $S_1$  的补空间不唯一, 因此在讨论投影时要明确给定  $S_2$ .

**例** 设  $S_1 = \text{span}\{e_1\}$ ,  $S_2 = \text{span}\{e_2\}$ ,  $\tilde{S}_2 = \text{span}\{e\}$ , 其中  $e_1 = [1, 0]^T$ ,  $e_2 = [0, 1]^T$ ,  $e = [1, 1]^T$ . 于是有

$$\mathbb{R}^2 = S_1 \oplus S_2 = S_1 \oplus \tilde{S}_2.$$

$x = [2, 3]^T$  沿  $S_2$  到  $S_1$  上的投影是  $[2, 0]^T$ , 沿  $\tilde{S}_2$  到  $S_1$  上的投影是  $[-1, 0]^T$ .

## 投影变换与投影矩阵

定义线性变换  $P: \mathbb{S} \rightarrow \mathbb{S}$  如下:

$$Px = x|_{\mathbb{S}_1},$$

则称  $P$  是从  $\mathbb{S}$  沿  $\mathbb{S}_2$  到  $\mathbb{S}_1$  上的 **投影变换** 或 **投影算子**

对应的变换矩阵称为 **投影矩阵**

### 几点注记

- ▶ 线性变换在不同的基下对应不同的变换矩阵. 在不加特别指出时, 本讲义中如果线性空间是  $\mathbb{R}^n$  或  $\mathbb{R}^{n \times n}$ , 我们采用自然基.
- ▶ 为书写方便, 我们使用  $P$  既表示投影变换也表示其对应的投影矩阵.

## 投影矩阵由其像空间和零空间唯一确定

设  $P$  是从  $\mathbb{S}$  沿  $\mathbb{S}_2$  到  $\mathbb{S}_1$  上的投影变换, 则容易验证

$$\text{Ran}(P) = \mathbb{S}_1, \text{Ker}(P) = \mathbb{S}_2 \implies \mathbb{R}^n = \text{Ran}(P) \oplus \text{Ker}(P)$$



注: 对于一般矩阵有  $\mathbb{R}^n = \text{Ran}(A) \oplus \text{Ker}(A^T)$

**定理** 若  $\mathbb{S}_1$  和  $\mathbb{S}_2$  是  $\mathbb{R}^n$  的两个子空间, 且  $\mathbb{R}^n = \mathbb{S}_1 \oplus \mathbb{S}_2$ , 则存在唯一的投影矩阵  $P$ , 使得

$$\text{Ran}(P) = \mathbb{S}_1, \quad \text{Ker}(P) = \mathbb{S}_2.$$

 若  $\mathbb{S}_1 = \mathbb{R}^n$ , 则  $\mathbb{S}_2 = \{0\}$ , 所对应的投影矩阵即为单位矩阵  $I$ .

 若  $\mathbb{S}_1 = \{0\}$ , 则  $\mathbb{S}_2 = \mathbb{R}^n$ , 此时所对应的投影矩阵即为零矩阵.

## 投影矩阵的一个简单性质

**引理** 设  $P \in \mathbb{R}^{n \times n}$  是一个投影矩阵, 则

- (1)  $I - P$  也是一个投影矩阵, 且  $\text{Ker}(P) = \text{Ran}(I - P)$ ;
- (2)  $P^T$  也是一个投影矩阵.

## 投影矩阵的判别

**定理** 矩阵  $P \in \mathbb{R}^{n \times n}$  是投影矩阵的充要条件是  $P^2 = P$ .

(留作课外自习, 证明见讲义)



## 投影变换的矩阵表示

设  $S_1$  和  $S_2$  是  $\mathbb{R}^n$  的两个  $m$  维子空间, 且  $\mathbb{R}^n = S_1 \oplus S_2^\perp$ , 则存在唯一的投影变换  $P$ , 使得

$$\text{Ran}(P) = S_1, \quad \text{Ker}(P) = S_2^\perp.$$

此时, 我们称  $P$  是  $S_1$  上与  $S_2$  正交的投影矩阵.

**定理** 设  $P \in \mathbb{R}^{n \times n}$  是  $S_1$  上与  $S_2$  正交的投影变换,  $v_1, v_2, \dots, v_m$  和  $w_1, w_2, \dots, w_m$  分别构成  $S_1$  和  $S_2$  的一组基, 则

$$P = V(W^\top V)^{-1}W^\top,$$

其中  $V = [v_1, v_2, \dots, v_m]$ ,  $W = [w_1, w_2, \dots, w_m]$ .

(留作练习)

## 正交投影变换

设  $S_1$  是内积空间  $S$  的一个子空间,  $x \in S$ , 则  $x$  可唯一分解成

$$x = x_1 + x_2, \quad x_1 \in S_1, \quad x_2 \in S_1^\perp,$$

其中  $x_1$  称为  $x$  在  $S_1$  上的正交投影.

- ▶ 若  $P$  是沿  $S_1^\perp$  到  $S_1$  上的投影变换, 则称  $P$  为  $S_1$  上的正交投影变换, 对应的矩阵为 正交投影矩阵, 记为  $P_{S_1}$
- ▶ 非正交投影变换称为 斜投影变换

## 正交投影变换的矩阵表示

设  $P$  是  $S_1$  上的正交投影变换, 则

$$P = VV^T,$$

其中  $V = [v_1, v_2, \dots, v_m]$  的列向量组构成  $S_1$  的一组 **标准正交基**.

## 正交投影的判别

**定理** 投影矩阵  $P \in \mathbb{R}^{n \times n}$  是正交投影矩阵的充要条件  $P^T = P$ .

(留作练习)

# 3 | 向量范数与矩阵范数

## 向量范数

**定义 (向量范数)** 若函数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  (或  $f: \mathbb{C}^n \rightarrow \mathbb{R}$ ) 满足

- (1)  $f(x) \geq 0, \forall x \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ ), 等号当且仅当  $x = 0$  时成立;
- (2)  $f(\alpha x) = |\alpha| \cdot f(x), \forall x \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ ),  $\alpha \in \mathbb{R}$  (或  $\mathbb{C}$ );
- (3)  $f(x + y) \leq f(x) + f(y), \forall x, y \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ );

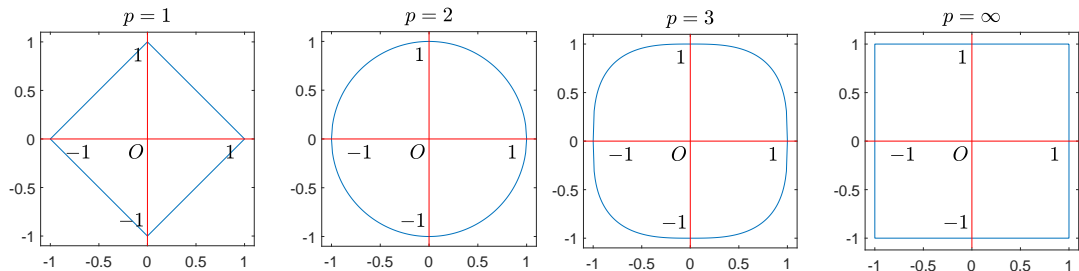
则称  $f(x)$  为  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 上的 **范数**, 通常记作  $\|x\|$ .

如果  $f$  只满足  $f(x) \geq 0$ , 以及 (2) 和 (3), 则称为 **半范数**.

## $\mathbb{R}^n$ 和 $\mathbb{C}^n$ 上常见的向量范数

- ▶ 1-范数:  $\|x\|_1 = |x_1| + |x_2| + \cdots + |x_n|$ ;
- ▶ 2-范数:  $\|x\|_2 = \sqrt{|x_1|^2 + |x_2|^2 + \cdots + |x_n|^2}$ ;
- ▶  $\infty$ -范数:  $\|x\|_\infty = \max_{1 \leq i \leq n} |x_i|$ ;
- ▶  $p$ -范数:  $\|x\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{1/p}$ ,  $p \geq 1$ .

## 例 ( $p$ -范数举例)



  $p$ -范数也称为 Hölder 范数或  $l_p$  范数.

## 范数的连续性

**定理** 设  $\|\cdot\|$  是  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 上的一个向量范数, 则  $f(x) \triangleq \|x\|$  是  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 上的连续函数.

(留作课外自习, 利用范数的三角不等式)

## 范数的等价性

**定义** 设  $\|\cdot\|_\alpha$  与  $\|\cdot\|_\beta$  是  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 上向量范数, 若存在正常数  $c_1, c_2$ , 使得

$$c_1\|x\|_\alpha \leq \|x\|_\beta \leq c_2\|x\|_\alpha$$


对任意  $x \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 都成立, 则称  $\|\cdot\|_\alpha$  与  $\|\cdot\|_\beta$  是等价的.



**定理**  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 上的所有向量范数都是等价的, 特别地, 有

$$\|x\|_2 \leq \|x\|_1 \leq \sqrt{n} \|x\|_2, \quad \|x\|_\infty \leq \|x\|_1 \leq n \|x\|_\infty, \quad \|x\|_\infty \leq \|x\|_2 \leq \sqrt{n} \|x\|_\infty$$

(板书, 以  $\mathbb{R}^n$  为例, 只证明等价性, 三个不等式留作练习)

 事实上, 有限维赋范线性空间上的所有范数都是等价的.

事实上, 我们有

$$\|x\|_p \geq \|x\|_q, \quad \forall 1 \leq p \leq q.$$

(留作课外自习, 证明见讲义)

**定理 (Cauchy-Schwarz 不等式)** 设  $(\cdot, \cdot)$  是  $\mathbb{C}^n$  (或  $\mathbb{R}^n$ ) 上的内积, 则对任意  $x, y \in \mathbb{C}^n$  (或  $\mathbb{R}^n$ ), 有

$$|(x, y)|^2 \leq (x, x) \cdot (y, y)$$

且等号成立的充要条件是  $x$  与  $y$  线性相关.

(板书)

中学数学中的 Cauchy 不等式



$$(a_1b_1 + a_2b_2 + \cdots + a_nb_n)^2 \leq (a_1^2 + a_2^2 + \cdots + a_n^2) (b_1^2 + b_2^2 + \cdots + b_n^2),$$

是 Cauchy-Schwarz 不等式的特例.

更一般地, 我们有下面的 Holder 不等式.

**定理 (Holder 不等式)** 设  $(\cdot, \cdot)$  是  $\mathbb{C}^n$  (或  $\mathbb{R}^n$ ) 上的内积, 则对任意  $x, y \in \mathbb{C}^n$  (或  $\mathbb{R}^n$ ), 有

$$|(x, y)| \leq \|x\|_p \cdot \|y\|_q,$$

其中  $p, q > 0$ , 且  $\frac{1}{p} + \frac{1}{q} = 1$ .

(留作课外自习)

## 内积导出范数

设  $\mathbb{S}$  是内积空间, 对任意  $x \in \mathbb{S}$ , 定义

$$\|x\| \triangleq (x, x)^{\frac{1}{2}},$$

则可以验证,  $\|x\|$  是  $\mathbb{S}$  上的范数. 这就是 **由内积导出的范数**



任意一个内积都可以导出一个相应的范数.

**例**  $\mathbb{R}^n/\mathbb{C}^n$  上由标准内积导出的范数为  $\|x\| = (x, x)^{\frac{1}{2}} = \left( \sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}}$ .

## 矩阵范数

**定义** 若函数  $f: \mathbb{R}^{m \times n} \rightarrow \mathbb{R}$  (或  $f: \mathbb{C}^{m \times n} \rightarrow \mathbb{R}$ ) 满足

(1)  $f(A) \geq 0, \forall A \in \mathbb{R}^{m \times n}$  (或  $\mathbb{C}^{m \times n}$ ) 且等号当且仅当  $A = 0$  时成立;

(2)  $f(\alpha A) = |\alpha| f(A), \forall A \in \mathbb{R}^{m \times n}$  (或  $\mathbb{C}^{m \times n}$ ),  $\alpha \in \mathbb{R}$  (或  $\mathbb{C}$ );

(3)  $f(A + B) \leq f(A) + f(B), \forall A, B \in \mathbb{R}^{m \times n}$  (或  $\mathbb{C}^{m \times n}$ );

则称  $f(X)$  为  $\mathbb{R}^{m \times n}$  (或  $\mathbb{C}^{m \times n}$ ) 上的矩阵范数, 通常记作  $\|X\|$ .

设  $f$  是  $\mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ) 上的矩阵范数, 如果  $f$  还满足

(4)  $f(AB) \leq f(A)f(B), \forall A, B \in \mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ),

则称  $f$  是 **相容的矩阵范数** (本讲义中所涉及的矩阵范数都是指相容的矩阵范数)

## 算子范数

**引理** 设  $\|\cdot\|$  是  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 上的向量范数, 则

$$\|A\| \triangleq \sup_{x \in \mathbb{R}^n, x \neq 0} \frac{\|Ax\|}{\|x\|} = \max_{\|x\|=1} \|Ax\|$$

是  $\mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ) 上的矩阵范数, 称为**算子范数**, 有时也称为**诱导范数**或**导出范数**.

(板书)



相应地, 可以定义  $\mathbb{R}^{m \times n}$  (或  $\mathbb{C}^{m \times n}$ ) 上的算子范数, 此时涉及  $\mathbb{R}^m$  和  $\mathbb{R}^n$  (或  $\mathbb{C}^m$  和  $\mathbb{C}^n$ ) 上的向量范数.

例 设  $A \in \mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ), 常见的矩阵范数有:

➤  $p$ -范数 (算子范数)

$$\|A\|_p = \sup_{x \neq 0} \frac{\|Ax\|_p}{\|x\|_p}, \quad p \geq 1.$$

➤ Frobenius 范数, 简称  $F$ -范数

$$\|A\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2};$$

**引理** 可以证明:

(1) 矩阵 1-范数 (列范数):  $\|A\|_1 = \max_{1 \leq j \leq n} \left( \sum_{i=1}^n |a_{ij}| \right)$ ;

(2) 矩阵  $\infty$ -范数 (行范数):  $\|A\|_\infty = \max_{1 \leq i \leq n} \left( \sum_{j=1}^n |a_{ij}| \right)$ ;

(3) 矩阵 2-范数:  $\|A\|_2 = \sqrt{\rho(A^*A)}$ ;

(4) 矩阵  $F$ -范数:  $\|A\|_F = \sqrt{\text{tr}(A^*A)}$

(板书, 以  $\infty$ -范数和 2-范数为例, 1-范数和  $F$ -范数留作练习)



**定理 (矩阵范数的等价性)**  $\mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ) 上的所有范数都是等价的, 特别地, 有

$$\frac{1}{\sqrt{n}} \|A\|_1 \leq \|A\|_2 \leq \sqrt{n} \|A\|_1, \quad \frac{1}{\sqrt{n}} \|A\|_\infty \leq \|A\|_2 \leq \sqrt{n} \|A\|_\infty.$$

(留作练习)

## 矩阵范数的更多性质

- (1) 对任意矩阵范数  $\|\cdot\|$ , 有  $\|A^k\| \leq \|A\|^k$ ;
- (2) 对任意算子范数  $\|\cdot\|$ , 有  $\|Ax\| \leq \|A\| \cdot \|x\|$ ,  $\|AB\| \leq \|A\| \cdot \|B\|$ ;
- (3)  $\|Ax\|_2 \leq \|A\|_F \cdot \|x\|_2$ ,  $\|AB\|_F \leq \|A\|_F \cdot \|B\|_F$ ;
- (4)  $F$ -范数不是算子范数;
- (5)  $\|\cdot\|_2$  和  $\|\cdot\|_F$  是酉不变范数, 即对任意酉矩阵 (或正交矩阵)  $U, V$ , 有

$$\|UA\|_2 = \|AV\|_2 = \|UAV\|_2 = \|A\|_2,$$

$$\|UA\|_F = \|AV\|_F = \|UAV\|_F = \|A\|_F$$

- (6)  $\|A^*\|_2 = \|A\|_2$ ,  $\|A^*\|_1 = \|A\|_\infty$ ;
- (7) 若  $A$  是正规矩阵, 则  $\|A\|_2 = \rho(A)$ .

(留作课外自习)

在数据处理和机器学习等学科中经常会用到下面的范数:

### ➤ 向量 $l_0$ 范数

$$\|x\|_0 \triangleq x \text{ 中非零元素的个数}, \quad x \in \mathbb{R}^n \text{ (或 } \mathbb{C}^n \text{)}.$$

需要指出的是, 上式定义的  $l_0$  范数并不满足向量范数定义中的条件 (2). 该范数主要用于衡量向量的稀疏性, 是压缩感知和稀疏优化中的研究对象.



### ➤ 矩阵核范数

$$\|A\|_* \triangleq \sum \sigma_i, \quad \text{其中 } \sigma_i \text{ 为 } A \text{ 的所有奇异值}, A \in \mathbb{R}^{m \times n} \text{ (或 } \mathbb{C}^{m \times n} \text{)}.$$

(矩阵奇异值将在第三讲中介绍) 根据奇异值的性质, 核范数也可以定义为

$$\|A\|_* \triangleq \text{tr} \left( \sqrt{A^T A} \right).$$

## 矩阵直和

设  $A_i \in \mathbb{R}^{n_i \times n_i}$  (或  $\mathbb{C}^{n_i \times n_i}$ ),  $i = 1, 2, \dots, k$ , 定义 **直和**

$$\bigoplus_{i=1}^k A_i = A_1 \oplus A_2 \oplus \cdots \oplus A_k \triangleq \begin{bmatrix} A_1 & & & \\ & A_2 & & \\ & & \ddots & \\ & & & A_k \end{bmatrix},$$

即以  $A_i$  为对角块的块对角矩阵. 可以验证


$$\left\| \bigoplus_{i=1}^k A_i \right\|_p = \max_{1 \leq i \leq k} \|A_i\|_p, \quad p = 1, 2, \infty.$$

## 谱半径与范数

**定理 (谱半径与范数的关系)** 设  $A \in \mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ), 则

- (1) 对任意算子范数, 有  $\rho(A) \leq \|A\|$ ;
- (2) 反之, 对任意  $\varepsilon > 0$ , 都存在一个算子范数  $\|\cdot\|_\varepsilon$ , 使得  $\|A\|_\varepsilon \leq \rho(A) + \varepsilon$ , 其中范数  $\|\cdot\|_\varepsilon$  依赖于  $A$  和  $\varepsilon$ . 所以, 若  $\rho(A) < 1$ , 则存在算子范数  $\|\cdot\|_\varepsilon$ , 使得  $\|A\|_\varepsilon < 1$ ;

(板书)

 事实上, 定理 3.8 中的结论 (1) 对任意矩阵范数都成立, 留作练习.

**推论** 设  $A \in \mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ), 则  $\|A\|_2^2 \leq \|A\|_1 \|A\|_\infty$ , 且

$$\max_{1 \leq i, j \leq n} \{|a_{ij}|\} \leq \|A\|_2 \leq n \max_{1 \leq i, j \leq n} \{|a_{ij}|\}.$$

(留作练习, 利用矩阵特征值与迹的关系)

## 最佳逼近与正交投影

### 正交投影变换的一个常用性质

**定理** 设  $P \in \mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ) 是正交投影矩阵, 则  $\|P\|_2 = 1$ , 且对  $\forall x \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ ), 有

$$\|x\|_2^2 = \|Px\|_2^2 + \|(I - P)x\|_2^2.$$

## 用正交投影表示最佳逼近问题的解

**定理** 设  $S$  是  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 的子空间,  $z \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 是一个给定的向量, 则最佳逼近问题

$$\min_{x \in S} \|x - z\|_2$$

的唯一解为

$$x_* = P_S z.$$

即  $S$  中距离  $z$  最近 (在 2-范数意义下) 的向量是  $z$  在  $S$  中的正交投影.

(留作练习)



上述定理中的 2-范数可以推广到一般的能量范数.

**推论** 设  $A \in \mathbb{R}^{n \times n}$  (或  $\mathbb{C}^{n \times n}$ ) 对称正定 (或 Hermite 正定),  $\mathbb{S}$  是  $\mathbb{R}^n$  (或  $\mathbb{C}^n$ ) 的子空间, 给定  $z \in \mathbb{R}^n$  (或  $\mathbb{C}^n$ ), 则  $x_*$  是最佳逼近问题

$$\min_{x \in \mathbb{S}} \|x - z\|_A$$

的解的充要条件是

$$x_* \in \mathbb{S} \quad \text{且} \quad A(x_* - z) \perp \mathbb{S}.$$

此处**能量范数**  $\|\cdot\|_A$  的定义为:  $\|x - z\|_A \triangleq \sqrt{(x - z)^* A (x - z)}$ .

(留作练习)

# 4 | 矩阵标准型

计算矩阵特征值的一个基本思想

通过相似变换, 将其转化成形式尽可能简单的矩阵, 使得其特征值更易于计算.

两个非常有用的特殊矩阵是 Jordan 标准型和 Schur 标准型

## Jordan 标准型

**定理** 设  $A \in \mathbb{C}^{n \times n}$  有  $p$  个不同特征值, 则存在非奇异矩阵  $X \in \mathbb{C}^{n \times n}$ , 使得

$$X^{-1}AX = \begin{bmatrix} J_1 & & & \\ & J_2 & & \\ & & \ddots & \\ & & & J_p \end{bmatrix} \triangleq J, \quad (\text{Jordan 标准型})$$

其中  $J_i$  的维数等于  $\lambda_i$  的代数重数, 且具有下面的结构

$$J_i = \begin{bmatrix} J_i^{(1)} & & & \\ & J_i^{(2)} & & \\ & & \ddots & \\ & & & J_i^{(\nu_i)} \end{bmatrix}, \quad J_i^{(k)} = \begin{bmatrix} \lambda_i & 1 & & \\ & \ddots & \ddots & \\ & & \lambda_i & 1 \\ & & & \lambda_i \end{bmatrix}.$$

这里的  $\nu_i$  为  $\lambda_i$  的几何重数,  $J_i^{(k)}$  称为 (对应于  $\lambda_i$  的) **Jordan 块**.

## 另一种描述

设  $A \in \mathbb{C}^{n \times n}$ , 则存在非奇异矩阵  $X \in \mathbb{C}^{n \times n}$  使得

$$X^{-1}AX = \begin{bmatrix} J_1 & & & \\ & J_2 & & \\ & & \ddots & \\ & & & J_\ell \end{bmatrix},$$

其中

$$J_k = \begin{bmatrix} \lambda_k & 1 & & \\ & \ddots & \ddots & \\ & & \lambda_k & 1 \\ & & & \lambda_k \end{bmatrix}_{n_k \times n_k}, \quad n_k \geq 1, \quad k = 1, 2, \dots, \ell, \quad \text{且} \quad \sum_{k=1}^{\ell} n_k = n.$$

矩阵  $J_k$  就称为 **Jordan 块**,  $\lambda_1, \lambda_2, \dots, \lambda_\ell$  是  $A$  的特征值 (不要求互异).

## Jordan 标准型的基本性质

- ▶ 除了 Jordan 块的排列次序外, Jordan 标准型是唯一确定的.
- ▶ Jordan 块的个数等于  $A$  的线性无关的特征向量的个数;
- ▶  $A$  可对角化的充要条件是每个 Jordan 块都是  $1 \times 1$  的, 此时  $X$  的列向量就是  $A$  的特征向量.
- ▶ 可以证明, 对于每一个 Jordan 块  $J_i^{(k)}$ , 都存在一个列满秩矩阵  $X_i^{(k)}$  使得

$$AX_i^{(k)} = X_i^{(k)} J_i^{(k)}.$$

## Jordan 标准型的应用

**推论** 所有可对角化矩阵组成的集合在所有矩阵组成的集合中是稠密的, 即任何一个矩阵都可以通过可对角化矩阵来逼近.

Jordan 标准型的另一个重要应用是可以用来计算矩阵的最小多项式.

**定理** 设  $\lambda_1, \lambda_2, \dots, \lambda_p$  为  $A \in \mathbb{C}^{n \times n}$  的互不相等的特征值, 则  $A$  的最小多项式为

$$p(\lambda) = \prod_{i=1}^q (\lambda - \lambda_i)^{r_i},$$

其中  $r_i$  是与  $\lambda_i$  所对应的最大 Jordan 块的维数.

## Schur 分解

**定理** 设  $A \in \mathbb{C}^{n \times n}$  (或  $\mathbb{R}^{n \times n}$ ), 则存在酉矩阵  $U \in \mathbb{C}^{n \times n}$  使得

$$U^*AU = \begin{bmatrix} \lambda_1 & r_{12} & \cdots & r_{1n} \\ 0 & \lambda_2 & \cdots & r_{2n} \\ \vdots & & \ddots & \vdots \\ 0 & \cdots & 0 & \lambda_n \end{bmatrix} \triangleq R \quad \text{或} \quad A = URU^*,$$

其中  $\lambda_1, \lambda_2, \dots, \lambda_n$  是  $A$  的特征值 (可以按任意顺序排列).

(板书)

## 关于 Schur 分解的几点说明

- ▶ 该结论告诉我们, 任意一个矩阵都可以酉三角化.
- ▶ 三角矩阵可以说是一般矩阵在酉相似变化下的最简形式.
- ▶ 定理中的  $U$  和  $R$  不是唯一的.
- ▶  $R$  的对角线元素可以按任意顺序排列, 特别地, 可以按模从大到小排列.

**推论** 设  $A \in \mathbb{C}^{n \times n}$ , 则

- (1)  $A$  是正规矩阵当且仅当  $R$  是对角矩阵,  
即  $A$  可酉对角化当且仅当  $A$  是正规矩阵;
- (2)  $A$  是 Hermite 矩阵当且仅当  $R$  是实对角矩阵.



## 实 Schur 分解 (或拟 Schur 分解)

**定理** 设  $A \in \mathbb{R}^{n \times n}$ , 则存在正交矩阵  $Q \in \mathbb{R}^{n \times n}$ , 使得

$$Q^T A Q = T,$$

其中  $T \in \mathbb{R}^{n \times n}$  是**拟上三角矩阵**, 即  $T$  是块上三角的, 且对角块为  $1 \times 1$  或  $2 \times 2$  的块矩阵. 若对角块是  $1 \times 1$  的, 则其就是  $A$  的一个特征值, 若对角块是  $2 \times 2$  的, 则其特征值是  $A$  的一对共轭复特征值.

(板书)

# 5 | 几类特殊矩阵

## 对称正定矩阵

设  $A \in \mathbb{C}^{n \times n}$ .

- ▶ 若对所有向量  $x \in \mathbb{C}^n$  有  $\operatorname{Re}(x^*Ax) \geq 0$ , 则称  $A$  是**半正定**的;
- ▶ 若对所有非零向量  $x \in \mathbb{C}^n$  有  $\operatorname{Re}(x^*Ax) > 0$ , 则称  $A$  是**正定**的;
- ▶ 若  $A$  是 Hermite 的且半正定, 则称  $A$  为 **Hermite 半正定**;
- ▶ 若  $A$  是 Hermite 的且正定, 则称  $A$  为 **Hermite 正定**;
- ▶ 若  $A \in \mathbb{R}^{n \times n}$  是对称的且半正定, 则称  $A$  为**对称半正定**;
- ▶ 若  $A \in \mathbb{R}^{n \times n}$  是对称的且正定, 则称  $A$  为**对称正定**.

本讲义中, 正定和半正定矩阵不要求是对称或 Hermite.

## 对称正定矩阵的判别


**定理** 设  $A \in \mathbb{C}^{n \times n}$ , 则

- (1)  $A$  正定的充要条件是  $H = \frac{1}{2}(A + A^*)$  正定;
- (2)  $A$  半正定的充要条件是  $H = \frac{1}{2}(A + A^*)$  半正定.

(留作练习)

**定理** 设  $A \in \mathbb{R}^{n \times n}$ , 则  $A$  正定 (或半正定) 的充要条件是对任意非零向量  $x \in \mathbb{R}^n$  有  $x^T A x > 0$  (或  $x^T A x \geq 0$ ).

(留作练习)

 该结论表明: 如果  $A$  是实矩阵, 则只需在实数域中考虑即可.

## 对称正定矩阵的基本性质

- (1)  $A$  Hermite 正定当且仅当  $A$  Hermite 且所有特征值都是正的;
- (2)  $A$  Hermite 正定当且仅当存在酉矩阵  $U$  使得  $A = U\Lambda U^*$ , 其中  $\Lambda$  为对角矩阵且对角线均为正实数;
- (3)  $A$  Hermite 正定当且仅当  $S^*AS$  对称正定, 其中  $S \in \mathbb{C}^{n \times n}$  是一个任意的非奇异矩阵;
- (4) 若  $A$  Hermite 正定, 则  $A$  的任意主子矩阵都 Hermite 正定;
- (5) 若  $A$  Hermite 正定, 则  $A$  的所有对角线元素都是正的, 且  $\max_{i \neq j} \{|a_{ij}|\} < \max_i \{a_{ii}\}$ , 即绝对值最大的元素出现在对角线上.

## 平方根

**定理** 设  $A \in \mathbb{C}^{n \times n}$  是一个 Hermite 半正定矩阵,  $k$  是一个给定的正整数. 则存在唯一的 Hermite 半正定矩阵  $B \in \mathbb{C}^{n \times n}$  使得

$$B^k = A.$$

同时, 我们还有下面的性质:

- (1)  $\text{rank}(B) = \text{rank}(A)$ , 因此, 若  $A$  是正定的, 则  $B$  也正定;
- (2) 如果  $A$  是实矩阵的, 则  $B$  也是实矩阵.

特别地, 当  $k = 2$  时, 称  $B$  为  $A$  的平方根, 记为  $A^{\frac{1}{2}}$ .

(留作课外自习)

## Hermite 正定矩阵与内积

**定理** 设  $(\cdot, \cdot)$  是  $\mathbb{C}^n$  上的一个内积, 则存在一个 Hermite 正定矩阵  $A \in \mathbb{C}^{n \times n}$  使得

$$(x, y) = y^* Ax.$$

反之, 若  $A \in \mathbb{C}^{n \times n}$  是 Hermite 正定矩阵, 则

$$f(x, y) \triangleq y^* Ax$$

是  $\mathbb{C}^n$  上的一个内积.

(留作练习)



定理的结论在实数域中也成立.

## 对角占优矩阵

**定义** 设  $A \in \mathbb{C}^{n \times n}$ , 若

$$|a_{ii}| \geq \sum_{j \neq i} |a_{ij}|$$

对所有  $i = 1, 2, \dots, n$  都成立, 且至少有一个不等式严格成立, 则称  $A$  为弱行对角占优, 简称弱对角占优或对角占优. 若所有不等式都严格成立, 则称  $A$  是严格行对角占优, 简称严格对角占优.




类似地, 可以定义列对角占优和严格列对角占优.

## 严格对角占优矩阵的非奇异性

**定理** 若  $A \in \mathbb{C}^{n \times n}$  是严格对角占优矩阵, 则  $A$  非奇异.

(板书)

 如果  $A$  是严格对角占优的, 则可以给出  $\|A^{-1}\|_1$  的一个估计.

**定理** 设  $A \in \mathbb{R}^{n \times n}$  严格列对角占优, 记

$$\delta \triangleq \min_{1 \leq j \leq n} \left( |a_{jj}| - \sum_{i=1}^n |a_{ij}| \right) > 0,$$

则有  $\|A^{-1}\|_1 \leq \delta^{-1}$ .

(留作练习)



## 可约矩阵与不可约矩阵

**定义** 设  $A \in \mathbb{C}^{n \times n}$ , 如果存在置换矩阵  $P$  使得  $PAP^T$  为块上三角矩阵, 即

$$PAP^T = \begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix}, \quad A_{11} \in \mathbb{C}^{k \times k}, \quad A_{22} \in \mathbb{C}^{(n-k) \times (n-k)}$$

其中  $1 \leq k < n$ , 则称  $A$  是**可约**的, 否则就称  $A$  为**不可约**的.

## 不可约的意义

若  $A$  可约, 即存在置换矩阵  $P$ , 使得  $PAP^T = \begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix}$ ,  
则  $Ax = b$  等价于  $(PAP^T)(Px) = Pb$ . 记  $y \triangleq Px$ ,  $f \triangleq Pb$ , 则

$$\begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} f_1 \\ f_2 \end{bmatrix}.$$

- ▶ 因此, 原方程组就转化为两个更小规模的子方程组.
  - ▶ 对于特征值问题,  $A$  的特征值就是  $A_{11}$  和  $A_{22}$  的特征值的并.
- 如果  $A_{22}$  或  $A_{11}$  仍然是可约的, 则可以转化为更小规模的子问题.

## 可约与对角线元素无关

由于  $PAP^T$  保持  $A$  的对角线元素仍然在对角线上, 因此主对角线元素是否为零并不影响矩阵的可约性.

**推论** 设  $A = [a_{ij}] \in \mathbb{C}^{n \times n}$  不可约, 则  $A + D$  也不可约, 其中  $D$  是任意对角矩阵. 特别地,  $B \triangleq A - \text{diag}(a_{11}, a_{22}, \dots, a_{nn})$  不可约.

## 可约矩阵的幂

如果  $A$  可约, 则对任意正整数  $k$ , 有

$$PA^kP^T = (PAP^T)^k = \begin{bmatrix} A_{11}^k & \tilde{A}_{12}^{(k)} \\ 0 & A_{22}^k \end{bmatrix}.$$

**定理** 设  $A \in \mathbb{C}^{n \times n}$ . 若  $A$  可约, 则  $A^k$  也可约. 反之, 若存在一个正整数  $k$ , 使得  $A^k$  是不可约的, 则  $A$  也不可约.



不可约矩阵的幂不一定不可约. 如  $A = \begin{bmatrix} -1 & 1 \\ 1 & 1 \end{bmatrix}$ , 但  $A^2 = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix}$  可约.

## 矩阵不可约的充要条件 (一)

**定理** 设  $A = [a_{ij}] \in \mathbb{C}^{n \times n}$ , 指标集  $\mathbb{Z}_n = \{1, 2, \dots, n\}$ , 则  $A$  可约的充要条件是存在非空指标集  $\mathcal{S}, \mathcal{T} \subset \mathbb{Z}_n$  满足  $\mathcal{S} \oplus \mathcal{T} = \mathbb{Z}_n$ , 使得

$$a_{ij} = 0, \quad i \in \mathcal{S}, \quad j \in \mathcal{T}.$$

(留作课外自习, 证明见讲义)

## 矩阵不可约的充要条件 (二)

**定理** 设  $A = [a_{ij}] \in \mathbb{C}^{n \times n}$ , 指标集  $\mathbb{Z}_n = \{1, 2, \dots, n\}$ , 则  $A$  可约的充要条件是存在两个相异的正整数  $k, l \in \mathbb{Z}_n$ , 使得对任意指标序列  $\{i_1, i_2, \dots, i_r\} \subseteq \mathbb{Z}_n$ , 都有

$$a_{ki_1} a_{i_1 i_2} \cdots a_{i_r l} = 0.$$

这里  $r > 0$  是任意正整数.

(留作课外自习)

### 等价描述

矩阵  $A = [a_{ij}] \in \mathbb{C}^{n \times n}$  不可约的充要条件是: 对任意两个相异正整数  $k, l \in \mathbb{Z}_n$ , 都存在一个指标序列  $\{i_1, i_2, \dots, i_m\} \subseteq \mathbb{Z}_n$  使得

$$a_{ki_1} a_{i_1 i_2} \cdots a_{i_m l} \neq 0.$$

## 不可约对角占优矩阵

**定理** 设  $A \in \mathbb{C}^{n \times n}$  是不可约的弱对角占优矩阵, 则  $A$  非奇异.

(留作练习, 仿照严格对角占优, 再利用不可约充要条件 (一))


### 一个有意思的现象

通常, 如果某个元素全不为零的矩阵具有某种性质, 则这个性质往往能够推广到不可约矩阵.

## 其他常见特殊矩阵

➤ 带状矩阵:

$a_{ij} \neq 0$  only if  $-b_u \leq i - j \leq b_l$ , 其中  $b_u$  和  $b_l$  为非负整数, 分别称为**下带宽**和**上带宽**,  
 $b_u + b_l + 1$  称为  $A$  的**带宽**





➤ 上 Hessenberg 矩阵:  $a_{ij} = 0$  for  $i - j > 1$ ,

$$\begin{bmatrix} * & * & * & \cdots & * \\ * & * & * & \cdots & * \\ & * & * & \cdots & * \\ & & \ddots & \ddots & \vdots \\ & & & * & * \end{bmatrix}$$

➤ 下 Hessenberg 矩阵

$$\begin{bmatrix} * & * & & & \\ * & * & * & & \\ \vdots & \vdots & \ddots & \ddots & \\ * & * & \cdots & * & * \\ * & * & \cdots & * & * \end{bmatrix}$$

➤ Toeplitz 矩阵:

$$T = \begin{bmatrix} t_0 & t_{-1} & \cdots & t_{-n+1} \\ t_1 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & t_{-1} \\ t_{n-1} & \cdots & t_1 & t_0 \end{bmatrix}$$

➤ 循环矩阵 (circulant): 一类特殊的 Toeplitz 矩阵

$$C = \begin{bmatrix} c_0 & c_{n-1} & c_{n-2} & \cdots & c_1 \\ c_1 & c_0 & c_{n-1} & \cdots & c_2 \\ c_2 & c_1 & c_0 & \cdots & c_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ c_{n-1} & c_{n-2} & c_{n-3} & \cdots & c_0 \end{bmatrix}$$

➤ Hankel 矩阵:

$$H = \begin{bmatrix} h_0 & h_1 & \cdots & h_{n-2} & h_{n-1} \\ h_1 & \ddots & \ddots & \ddots & h_n \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ h_{n-2} & \ddots & \ddots & \ddots & h_{2n-2} \\ h_{n-1} & h_n & \cdots & h_{2n-2} & h_{2n-1} \end{bmatrix}$$

Hankel 矩阵与 Toeplitz 矩阵

设  $J = \begin{bmatrix} & & 1 \\ & \ddots & \\ 1 & & \end{bmatrix}$ , 则  $JH$  是 Toeplitz 矩阵.

# 6 | Kronecker 积

**定义** 设  $A \in \mathbb{C}^{m \times n}$ ,  $B \in \mathbb{C}^{p \times q}$ , 则  $A$  与  $B$  的 **Kronecker 积** 定义为

$$A \otimes B = \begin{bmatrix} a_{11}B & a_{12}B & \cdots & a_{1n}B \\ a_{21}B & a_{22}B & \cdots & a_{2n}B \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1}B & a_{m2}B & \cdots & a_{mn}B \end{bmatrix} \in \mathbb{C}^{mp \times nq}.$$

Kronecker 积也称为 **直积**, 或 **张量积**.



任意两个矩阵都存在 Kronecker 积, 但通常  $A \otimes B \neq B \otimes A$ . ( $A \otimes B$  和  $B \otimes A$  有什么关系?)

## Kronecker 积基本性质

$$(1) (\alpha A) \otimes B = A \otimes (\alpha B) = \alpha(A \otimes B), \quad \forall \alpha \in \mathbb{C}$$

$$(2) (A \otimes B)^{\top} = A^{\top} \otimes B^{\top}, \quad (A \otimes B)^* = A^* \otimes B^*$$

$$(3) (A \otimes B) \otimes C = A \otimes (B \otimes C)$$

$$(4) (A + B) \otimes C = A \otimes C + B \otimes C$$

$$(5) A \otimes (B + C) = A \otimes B + A \otimes C$$

$$(6) \text{rank}(A \otimes B) = \text{rank}(A) \text{rank}(B)$$

$$(7) \text{混合积: } (A \otimes B)(C \otimes D) = (AC) \otimes (BD)$$

$$\begin{aligned} (A_1 \otimes A_2 \otimes \cdots \otimes A_k)(B_1 \otimes B_2 \otimes \cdots \otimes B_k) \\ = (A_1 B_1) \otimes (A_2 B_2) \otimes \cdots \otimes (A_k B_k) \end{aligned}$$

$$(A_1 \otimes B_1)(A_2 \otimes B_2) \cdots (A_k \otimes B_k) = (A_1 A_2 \cdots A_k) \otimes (B_1 B_2 \cdots B_k)$$

## Kronecker 积的特征值

**推论** 设  $A = Q_1 \Lambda_1 Q_1^{-1} \in \mathbb{C}^{m \times m}$ ,  $B = Q_2 \Lambda_2 Q_2^{-1} \in \mathbb{C}^{n \times n}$ , 则

$$A \otimes B = (Q_1 \otimes Q_2)(\Lambda_1 \otimes \Lambda_2)(Q_1 \otimes Q_2)^{-1}.$$

**定理** 设  $A \in \mathbb{C}^{m \times m}$ ,  $B \in \mathbb{C}^{n \times n}$ , 并设  $(\lambda, x)$  和  $(\mu, y)$  分别是  $A$  和  $B$  的一个特征对, 则  $(\lambda\mu, x \otimes y)$  是  $A \otimes B$  的一个特征对. 由此可知,  $B \otimes A$  与  $A \otimes B$  具有相同的特征值.

**推论** 设  $A \in \mathbb{C}^{m \times m}$ ,  $B \in \mathbb{C}^{n \times n}$ , 则  $A \otimes I_n + I_m \otimes B$  的特征值为  $\lambda_i + \mu_j$ , 其中  $\lambda_i$  和  $\mu_j$  分别为  $A$  和  $B$  的特征值.

## Kronecker 积的迹和逆

**定理** 设  $A \in \mathbb{C}^{m \times m}$ ,  $B \in \mathbb{C}^{n \times n}$ , 则

(1)  $\operatorname{tr}(A \otimes B) = \operatorname{tr}(A)\operatorname{tr}(B)$ ;

(2)  $\det(A \otimes B) = \det(A)^n \det(B)^m$ ;

(3) 若  $A$  和  $B$  都非奇异, 则  $(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}$ .

## Kronecker 积与向量的乘积

**定理** 设矩阵  $X = [x_1, x_2, \dots, x_n] \in \mathbb{R}^{m \times n}$ , 记  $\text{vec}(X)$  为  $X$  按列拉成的  $mn$  维列向量, 即

$$\text{vec}(X) = [x_1^\top, x_2^\top, \dots, x_n^\top]^\top,$$

则有

$$\text{vec}(AX) = (I \otimes A)\text{vec}(X), \quad \text{vec}(XB) = (B^\top \otimes I)\text{vec}(X),$$

以及

$$(A \otimes B)\text{vec}(X) = \text{vec}(BXA^\top).$$



$\text{vec}(X)$  称为**向量化算子**或**拉直算子**. 该结论对节省运算量和存储量都有好处.



**定理** 矩阵方程

$$AX + XB = D$$

等价于代数方程

$$(I \otimes A + B^T \otimes I)\text{vec}(X) = \text{vec}(D).$$

