



# 矩阵论

主讲教师：徐乐

2015年1月13日星期二



## 上讲回顾

### ❖ 第22讲 矩阵特征值估计

- 特征值界的估计
- 盖尔圆法



# 特征值界的估计

## ❖ 矩阵特征值估计

- 特征值计算较困难，希望找到简便的特征值界限或分布范围的估计方法

## ❖ 定理1

- 设  $A \in \mathbf{R}^{n \times n}$ ， $\lambda$  为  $A$  的任意特征值，则有

$$|\operatorname{Im}(\lambda)| \leq M \sqrt{\frac{n(n-1)}{2}}$$

- 其中

$$M = \max_{1 \leq i, j \leq n} \left| \frac{a_{ij} - a_{ji}}{2} \right|$$



# 特征值界的估计

## ❖ 定理2

- 设  $A \in \mathbf{R}^{n \times n}$ ,  $\lambda$  为  $A$  的任意特征值, 则有

$$|\lambda| \leq n\rho$$

$$|\operatorname{Re}(\lambda)| \leq \frac{1}{2}n\tau$$

$$|\operatorname{Im}(\lambda)| \leq \frac{1}{2}ns$$

• 其中

$$\rho = \max_{1 \leq i, j \leq n} |a_{ij}|$$

$$\tau = \max_{1 \leq i, j \leq n} |a_{ij} + \overline{a_{ji}}|$$

$$s = \max_{1 \leq i, j \leq n} |a_{ij} - \overline{a_{ji}}|$$





# 盖尔圆法

## ❖ 定义

- 设  $A=(a_{i,j})_{n \times n} \in R^{n \times n}$ , 由方程所确定的圆称为  $A$  的第  $i$  个盖尔圆,  $R_i$  称为盖尔圆的半径

$$|z - a_{ii}| \leq R_i = \sum_{\substack{j=1 \\ i \neq j}}^n |a_{ij}|$$

## ❖ 定理3

- 矩阵  $A$  的所有特征值均落在它的所有盖尔圆的并集之中



## ❖ 定理4

- 将矩阵 $A$ 的全体盖尔圆的并集按连通部分分成若干个子集
  - 一个子集由完全连通的盖尔圆组成，不同子集没有相连通的部分
  - 对每个子集，若它恰好由 $K$ 个盖尔圆组成，则该子集中恰好包含 $A$ 的 $K$ 个特征值
- 说明
  - 盖尔圆相互重叠时重复计算，特征值相重时也重复计算



## ❖ 推论

- 孤立盖尔圆中恰好包含一个特征值
- 实矩阵的孤立盖尔圆恰好包含一个实特征值
- 盖尔圆方法中盖尔圆半径可以按列求和(因为方阵转置后特征值不变)
- 盖尔圆半径变为 $R_i$ ，两个盖尔圆定理仍然成立

$$R_i = \sum_{j=1}^n \frac{\alpha_i}{\alpha_j} |a_{ij}|$$



# 盖尔圆法

## ❖ 说明

- 相似矩阵  $\mathbf{P}^{-1}\mathbf{A}\mathbf{P}$  与  $\mathbf{A}$  具有相同的特征值，取

$$\mathbf{P} = \text{diag}[\alpha_1 \quad \alpha_2 \quad \cdots \quad \alpha_n], (\alpha_i > 0)$$

$$\mathbf{B} = \mathbf{P}^{-1}\mathbf{A}\mathbf{P} = \begin{bmatrix} \frac{1}{\alpha_1} & & & 0 \\ & \frac{1}{\alpha_2} & & \\ & & \ddots & \\ 0 & & & \frac{1}{\alpha_n} \end{bmatrix} \begin{bmatrix} \mathbf{a}_{ij} \\ & & & \\ & & & \\ 0 & & & \end{bmatrix} \begin{bmatrix} \alpha_1 & & & 0 \\ & \alpha_2 & & \\ & & \ddots & \\ 0 & & & \alpha_n \end{bmatrix}$$
$$= \begin{bmatrix} \frac{\alpha_i}{\alpha_j} \mathbf{a}_{ij} \end{bmatrix}$$





## 第23讲 广义特征值与极小极大原理

- ❖ 广义特征值问题
- ❖ 瑞利商
- ❖ 极小极大原理



# 广义特征值问题

## ❖ 定义

- 设 $\mathbf{A}$ 、 $\mathbf{B}$ 为 $n$ 阶方阵，若存在数 $\lambda$ ，使得方程 $\mathbf{Ax} = \lambda \mathbf{Bx}$ 存在非零解
  - 则称 $\lambda$ 为 $\mathbf{A}$ 相对于 $\mathbf{B}$ 的广义特征值
  - $\mathbf{x}$ 为 $\mathbf{A}$ 相对于 $\mathbf{B}$ 的属于广义特征值 $\lambda$ 的特征向量
    - 是标准特征值问题的推广
      - ⌚ 当 $\mathbf{B} = \mathbf{I}$ （单位矩阵）时，广义特征值问题退化为标准特征值问题。
    - 特征向量是非零的



# 广义特征值问题

## ❖ 广义特征值的求解

$$(\mathbf{A} - \lambda \mathbf{B})\mathbf{x} = \mathbf{0} \quad (\lambda \mathbf{B} - \mathbf{A})\mathbf{x} = \mathbf{0}$$

- 特征方程  $\det(\mathbf{A} - \lambda \mathbf{B}) = 0$
- 求得  $\lambda$  后代回原方程  $\mathbf{A}\mathbf{x} = \lambda \mathbf{B}\mathbf{x}$  可求出  $\mathbf{x}$

## ❖ 本课程进一步考虑 $\mathbf{A}$ 、 $\mathbf{B}$ 厄米且为正定矩阵的情况



# 广义特征值问题

## ❖ 等价表述

- **B**正定，**B**<sup>-1</sup>存在

$$\mathbf{B}^{-1}\mathbf{A}\mathbf{x} = \lambda\mathbf{x}$$

- 广义特征值问题化为了标准特征值问题
- 但一般来说，一般**B**<sup>-1</sup>**A**不再是厄米矩阵

- **B**厄米，存在Cholesky分解，**B**=**G****G**<sup>H</sup>，**G**满秩

$$\mathbf{A}\mathbf{x} = \lambda\mathbf{G}\mathbf{G}^H\mathbf{x} \quad \mathbf{G}^H\mathbf{x} = \mathbf{y}$$

- 则  $\mathbf{G}^{-1}\mathbf{A}(\mathbf{G}^H)^{-1}\mathbf{y} = \lambda\mathbf{y}$  也成为标准特征值问题





# 广义特征值问题

$$\mathbf{G}^{-1}\mathbf{A}(\mathbf{G}^H)^{-1}\mathbf{y} = \lambda\mathbf{y}$$

- $\mathbf{G}^{-1}\mathbf{A}(\mathbf{G}^H)^{-1}$  为厄米矩阵，广义特征值是实数，可以按大小顺序排列  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$
- 一定存在一组正交归一的特征向量满足

$$\mathbf{G}^{-1}\mathbf{A}(\mathbf{G}^H)^{-1}\mathbf{y}_i = \lambda_i\mathbf{y}_i \quad \mathbf{y}_i^H\mathbf{y}_j = \delta_{ij} = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}$$

- 还原为  $\mathbf{x}_i = (\mathbf{G}^H)^{-1}\mathbf{y}_i$

$$\mathbf{y}_i^H\mathbf{y}_j = (\mathbf{x}_i^H\mathbf{G})(\mathbf{G}^H\mathbf{x}_j) = \mathbf{x}_i^H\mathbf{B}\mathbf{x}_j = \delta_{ij} = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}$$



## ❖ 定义

- **A**、**B**为n阶厄米矩阵，且**B**正定，称**A**相对于**B**的瑞利商为

$$R(\mathbf{x}) = \frac{\mathbf{x}^H \mathbf{A} \mathbf{x}}{\mathbf{x}^H \mathbf{B} \mathbf{x}} \quad (\mathbf{x} \neq \mathbf{0})$$

- 说明：若 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ 为线性无关向量组，则

$$\forall \mathbf{x} \in \mathbb{C}^n$$

$$\exists \mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n \in \mathbb{C}$$

$$\mathbf{x} = \sum_{i=1}^n \mathbf{a}_i \mathbf{x}_i$$

$$\begin{aligned} \mathbf{x}^H \mathbf{B} \mathbf{x} &= \left( \sum_{i=1}^n \mathbf{a}_i \mathbf{x}_i \right)^H \mathbf{B} \left( \sum_{j=1}^n \mathbf{a}_j \mathbf{x}_j \right) = \sum_{i,j=1}^n \bar{\mathbf{a}}_i \mathbf{a}_j \mathbf{x}_i^H \mathbf{B} \mathbf{x}_j = \sum_{i=1}^n |\mathbf{a}_i|^2 \\ \mathbf{x}^H \mathbf{A} \mathbf{x} &= \sum_{i,j=1}^n \bar{\mathbf{a}}_i \mathbf{a}_j \mathbf{x}_i^H \mathbf{A} \mathbf{x}_j = \sum_{i,j=1}^n \bar{\mathbf{a}}_i \mathbf{a}_j \mathbf{x}_i^H \lambda_i \mathbf{B} \mathbf{x}_j = \sum_{i=1}^n \lambda_i |\mathbf{a}_i|^2 \end{aligned}$$



$$R(\mathbf{x}) = \frac{\sum_{i=1}^n \lambda_i |\mathbf{a}_i|^2}{\sum_{i=1}^n |\mathbf{a}_i|^2}$$



## ❖ 瑞利商性质

$$\min_{\mathbf{x} \neq 0} R(\mathbf{x}) = \lambda_1$$

$$\max_{\mathbf{x} \neq 0} R(\mathbf{x}) = \lambda_n$$

■ [证明]  $R(\mathbf{x}) = \frac{\mathbf{x}^H \mathbf{A} \mathbf{x}}{\mathbf{x}^H \mathbf{B} \mathbf{x}} = \frac{(\mathbf{kx})^H \mathbf{A} (\mathbf{kx})}{(\mathbf{kx})^H \mathbf{B} (\mathbf{kx})}$        $\mathbf{k}$  为非零常数

• 取  $\mathbf{k} = \frac{1}{\|\mathbf{x}\|}$        $\|\mathbf{kx}\| = 1$        $R(\mathbf{x}) = \frac{\mathbf{x}^H \mathbf{A} \mathbf{x}}{\mathbf{x}^H \mathbf{B} \mathbf{x}} \Big|_{\|\mathbf{x}\|=1}$

• 当  $\mathbf{x} = \mathbf{x}_1$  或  $\mathbf{a}_i = 0 (i = 2, 3, \dots, n)$        $R(\mathbf{x}) = \lambda_1$

$$\lambda_i \geq \lambda_1 \quad R(\mathbf{x}) \geq \lambda_1 \frac{\sum_{i=1}^n |\mathbf{a}_i|^2}{\sum_{i=1}^n |\mathbf{a}_i|^2} = \lambda_1$$

$$\min_{\mathbf{x} \neq 0} R(\mathbf{x}) = \lambda_1$$

• 另一方面

$$\lambda_i \leq \lambda_n \quad R(\mathbf{x}) \leq \lambda_n \frac{\sum_{i=1}^n |\mathbf{a}_i|^2}{\sum_{i=1}^n |\mathbf{a}_i|^2} = \lambda_n$$

$$\max_{\mathbf{x} \neq 0} R(\mathbf{x}) = \lambda_n$$



❖ 当  $B=I$  时，标准特征值问题  $Ax = \lambda x \quad A^H = A$

$$\begin{cases} \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n \\ \mathbf{x}_i^H \mathbf{x}_j = \delta_{ij} \end{cases}$$



$$\min_{(x \neq 0)} \frac{\mathbf{x}^H A \mathbf{x}}{\mathbf{x}^H \mathbf{x}} = \lambda_1$$

$$\min_{x \neq 0} R(x) \Big|_{a_1=0} = \lambda_2$$

⋮

$$\min_{x \neq 0} R(x) \Big|_{a_1=a_2=\dots=a_k=0} = \lambda_{k+1}$$

$$\max_{(x \neq 0)} \frac{\mathbf{x}^H A \mathbf{x}}{\mathbf{x}^H \mathbf{x}} = \lambda_n$$

$$\max_{x \neq 0} R(x) \Big|_{a_n=0} = \lambda_{n-1}$$

⋮

$$\max_{x \neq 0} R(x) \Big|_{a_n=a_{n-1}=\dots=a_{n-k}=0} = \lambda_{n-k-1}$$





## ❖ 定理1

■ 设  $L = \text{span}\{\mathbf{x}_r, \mathbf{x}_{r+1}, \dots, \mathbf{x}_s\}$  ( $\lambda_r \leq \lambda_{r+1} \leq \dots \leq \lambda_s$ )

■ 则  $\min_{\substack{\mathbf{x} \neq \mathbf{0} \\ \mathbf{x} \in L}} \mathbf{R}(\mathbf{x}) = \lambda_r$        $\max_{\substack{\mathbf{x} \neq \mathbf{0} \\ \mathbf{x} \in L}} \mathbf{R}(\mathbf{x}) = \lambda_s$

- 这一结果不便于应用，希望对上述结果进行改造，改造成不依赖于 $\mathbf{x}_i$ 的一种表达方式
- $\mathbf{a}_1 = \mathbf{0}, \mathbf{a}_n = \mathbf{0}$ 的情况均对应于 $\mathbf{x}$ 在 $(n-1)$ 维的子空间内变动， $\mathbf{x}$ 在 $L$ 中变动是在一个 $(s-r+1)$ 维子空间中变化
- 一般的， $\mathbf{x}$ 在 $\mathbb{C}^n$ 的 $(n-1)$ 维子空间 $V_{n-1}$ 中变动时

$$\min_{\substack{\mathbf{x} \neq \mathbf{0} \\ \mathbf{x} \in V_{n-1}}} \mathbf{R}(\mathbf{x}) \leq \lambda_2$$

$$\max_{\substack{\mathbf{x} \neq \mathbf{0} \\ \mathbf{x} \in V_{n-1}}} \mathbf{R}(\mathbf{x}) \geq \lambda_{n-1}$$



## 极小极大原理

- ❖ 对于不同的  $V_{n-1}$ ,  $R(x)$  最小值及最大值有可能不同, 其中各个最小值中最大者为  $\lambda_2$ , 各个最大值中的最小者为  $\lambda_{n-1}$

$$\max_{V_{n-1} \in C^n} \left[ \min_{\substack{x \neq 0 \\ x \in V_{n-1}}} R(x) \right] = \lambda_2 \qquad \min_{V_{n-1} \in C^n} \left[ \max_{\substack{x \neq 0 \\ x \in V_{n-1}}} R(x) \right] = \lambda_{n-1}$$

### ❖ 定理2

- 设  $V_k$  是  $C^n$  的一个  $k$  维子空间, 则

$$\max_{V_k \in C^n} \left[ \min_{\substack{x \neq 0 \\ x \in V_k}} R(x) \right] = \lambda_{n-k+1} \qquad \min_{V_k \in C^n} \left[ \max_{\substack{x \neq 0 \\ x \in V_k}} R(x) \right] = \lambda_k$$

- 以上两式称为广义特征值的极小极大原理



# 极小极大原理

## ❖ 讨论

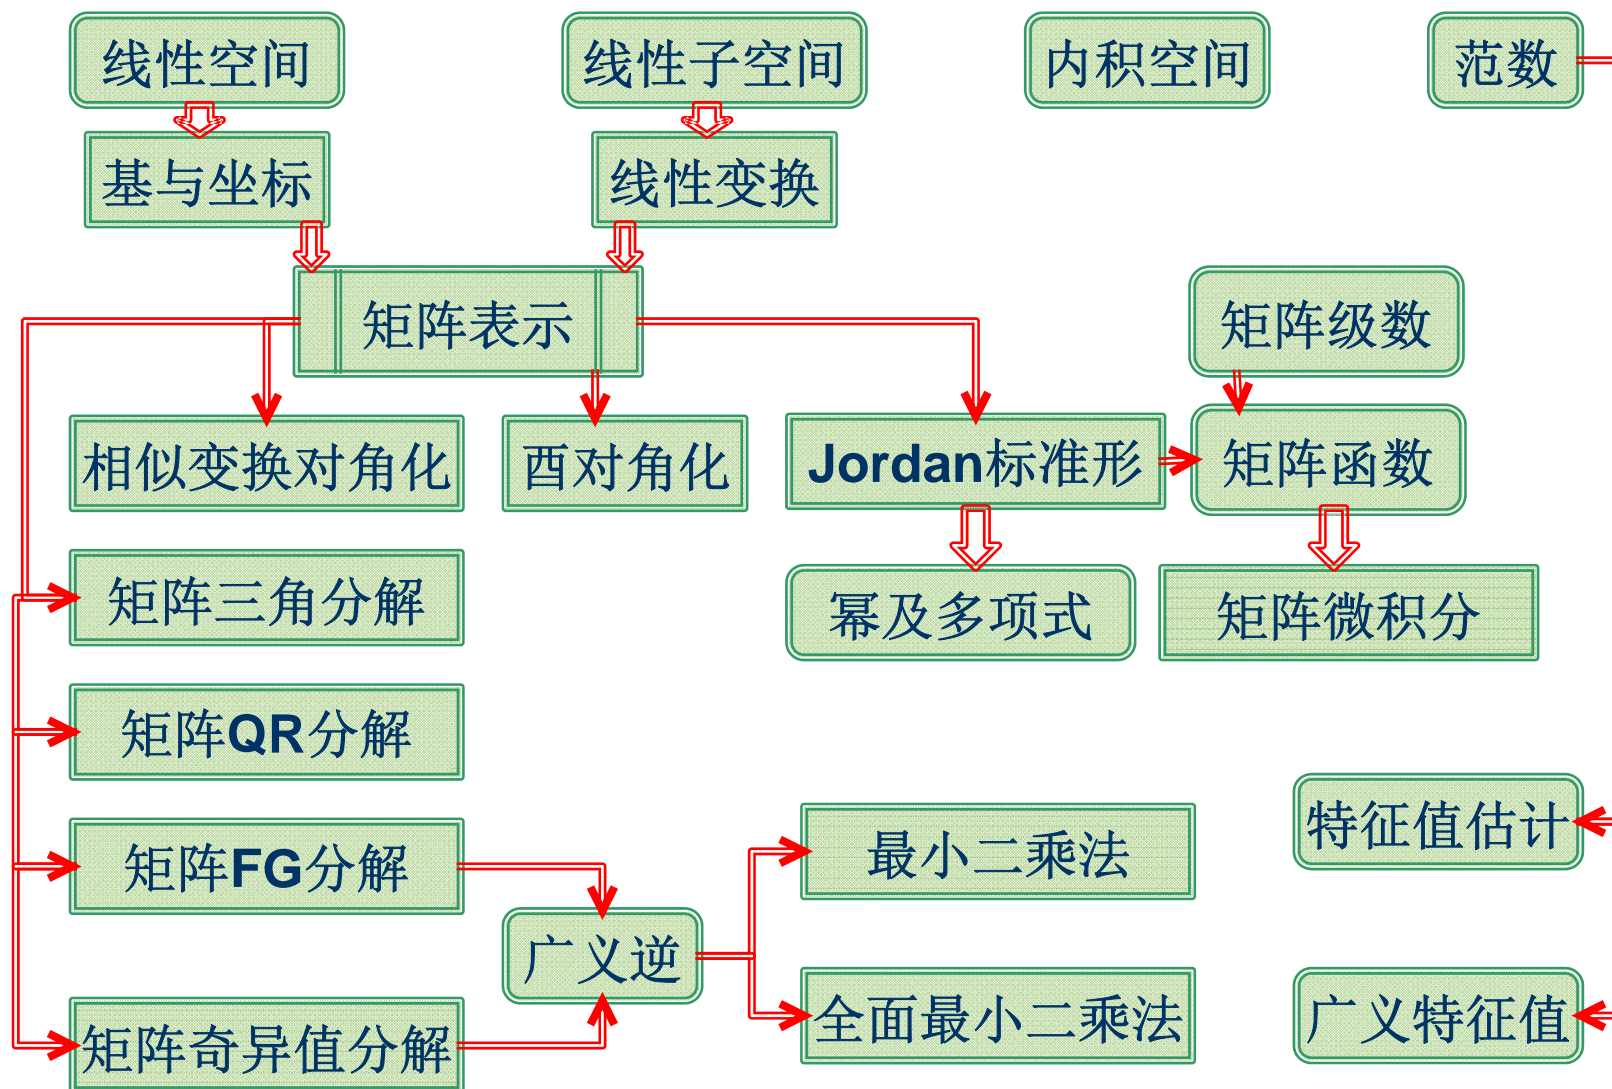
- $\mathbf{B}=\mathbf{I}$ 时，标准特征值问题同样存在上述关系
- 矩阵奇异值问题  $[\sigma(\mathbf{A})]^2 = \lambda(\mathbf{A}^H \mathbf{A})$  非零

$$\mathbf{R}(\mathbf{x}) = \frac{\mathbf{x}^H (\mathbf{A}^H \mathbf{A}) \mathbf{x}}{\mathbf{x}^H \mathbf{x}} = \frac{\|\mathbf{Ax}\|_2^2}{\|\mathbf{x}\|_2^2}$$

$$\sigma_{n-k+1} = \max_{V_k \in C^n} \left[ \min_{\substack{\mathbf{x} \neq 0 \\ \mathbf{x} \in V_k}} \frac{\|\mathbf{Ax}\|_2}{\|\mathbf{x}\|_2} \right]$$

$$\sigma_k = \min_{V_k \in C^n} \left[ \max_{\substack{\mathbf{x} \neq 0 \\ \mathbf{x} \in V_k}} \frac{\|\mathbf{Ax}\|_2}{\|\mathbf{x}\|_2} \right]$$









祝大家考试取得好成绩

态度端正、  
复习认真

做题仔细、  
步骤详细