

特征值问题的数值方法

包承龙

丘成桐数学科学中心

本章研究对象及目标

对于矩阵 $\mathbf{A} \in \mathbb{R}^{n \times n}$, 求特征值 $\lambda \in \mathbb{C}$ 及 $\mathbf{x} \in \mathbb{C}^n$, 满足

$$\mathbf{A}\mathbf{x} = \lambda\mathbf{x}$$

特征多项式

$$p(\lambda) = \det(\lambda\mathbf{I} - \mathbf{A}) = \lambda^n + a_{n-1}\lambda^{n-1} + \cdots + a_1 + a_0 := q(\lambda)$$

$q(\lambda)$ 是矩阵

$$\begin{bmatrix} 0 & 0 & \cdots & 0 & -a_0 \\ 1 & 0 & \cdots & 0 & -a_1 \\ & 1 & \cdots & 0 & -a_2 \\ & & \ddots & : & : \\ & & & 1 & -a_{n-1} \end{bmatrix}$$

的特征多项式。

Hessenberg矩阵-QR方法求解

目录

- 1 特征值估计和扰动
- 2 正交变换和矩阵因式分解
- 3 （逆）幂迭代法
- 4 QR方法
- 5 对称矩阵的特征值问题

特征值估计

设 $\sigma(\mathbf{A})$ 为 \mathbf{A} 的所有特征值集合：在复平面中， $\sigma(\mathbf{A})$ 位于半径为 $\|\mathbf{A}\|$ 的圆盘内。

定理 (Gershgorin定理)

设 $\mathbf{A} = [a_{ij}] \in \mathbb{C}^{n \times n}$ ，则对任意 $\lambda \in \sigma(\mathbf{A})$ ，有 $\lambda \in \cup_{i=1}^n D_i$ ，其中 D_i 是复平面上以 a_{ii} 为中心， $r_i = \sum_{j=1, j \neq i}^n |a_{ij}|$ 为半径的圆盘，即

$$D_i = \{z \mid |z - a_{ii}| \leq r_i, z \in \mathbb{C}\} \quad (1)$$

设 $\mathbf{D} = \text{Diag}(a_{11}, a_{22}, \dots, a_{nn})$ ，有

$$(\mathbf{A} - \mathbf{D})\mathbf{x} = (\lambda\mathbf{I} - \mathbf{D})\mathbf{x} \Rightarrow \|\mathbf{x}\|_{\infty} \leq \|(\lambda\mathbf{I} - \mathbf{D})^{-1}(\mathbf{A} - \mathbf{D})\|_{\infty} \|\mathbf{x}\|_{\infty}$$

定理

在由(1)所表示的 n 个圆盘中, 有 m 个圆盘构成一个连通区域 S , 且与其余 $n - m$ 个圆盘严格分离, 则 S 中恰有 m 个特征值。

若 $m = 1$, 则说明每个孤立的圆盘内恰有一个特征值。

取 $\mathbf{B} = \text{Diag}(b_1, b_2, \dots, b_n)$, 其中 $b_i \neq 0$, 则 \mathbf{A} 与 $\mathbf{B}^{-1}\mathbf{A}\mathbf{B}$ 相似, 且 $\mathbf{B}^{-1}\mathbf{A}\mathbf{B}$ 的Gershgorin圆盘的半径为

$$\sum_{j=1, j \neq i}^n \left| \frac{a_{ij}b_j}{b_i} \right|$$

$$\text{例: } \mathbf{A} = \begin{bmatrix} 0.9 & 0.01 & 0.12 \\ 0.01 & 0.8 & 0.13 \\ 0.01 & 0.02 & 0.4 \end{bmatrix} \Rightarrow |\lambda_1 - 0.9| \leq 0.022, |\lambda_2 - 0.8| \leq 0.023, |\lambda_3 - 0.4| \leq 0.03$$

特征值扰动

定理

设 $\mu \in \sigma(\mathbf{A} + \mathbf{E})$, 且 $\mathbf{X}^{-1}\mathbf{A}\mathbf{X} = \mathbf{D} = \text{Diag}(\lambda_1, \lambda_2, \dots, \lambda_n), \mathbf{X} \in \mathbb{C}^{n \times n}$, 则

$$\min_{\lambda \in \sigma(\mathbf{A})} |\lambda - \mu| \leq \|\mathbf{X}^{-1}\| \|\mathbf{X}\| \|\mathbf{E}\|$$

设 $\mu \notin \sigma(\mathbf{A})$, 则有

$$\mathbf{A} + \mathbf{E} - \mu\mathbf{I} = \mathbf{X}[\mathbf{D} - \mu\mathbf{I} + \mathbf{X}^{-1}\mathbf{E}\mathbf{X}]\mathbf{X}^{-1} \Rightarrow \mathbf{D} - \mu\mathbf{I} + \mathbf{X}^{-1}\mathbf{E}\mathbf{X} \text{非奇异}$$

存在非零向量 \mathbf{y} , 使得 $\mathbf{y} = -(\mathbf{D} - \mu\mathbf{I})^{-1}(\mathbf{X}^{-1}\mathbf{E}\mathbf{X})\mathbf{y}$

$\|\mathbf{X}\| \|\mathbf{X}^{-1}\|$: 特征值问题的条件数

\mathbf{A} 为正规矩阵 ($\mathbf{A}\mathbf{A}^H = \mathbf{A}^H\mathbf{A}$), 则可取 \mathbf{X} 为酉矩阵, $\|\mathbf{X}\|_2 \|\mathbf{X}^{-1}\|_2 = 1$ 。

若 $\mathbf{A} \in \mathbb{C}^{n \times n}$ 为非正规矩阵, 则 \mathbf{A} 可能对某些特征值敏感。

设 $\lambda \in \sigma(\mathbf{A})$, \mathbf{x} , \mathbf{y} 分别为右、左特征向量:

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

存在可微函数 $\mathbf{x}(\epsilon)$ 与 $\lambda(\epsilon)$ 满足 $\mathbf{x}(0) = \mathbf{x}$, $\lambda(0) = \lambda$,

$$\begin{aligned} (\mathbf{A} + \epsilon\mathbf{F})\mathbf{x}(\epsilon) &= \lambda(\epsilon)\mathbf{x}(\epsilon), \quad \|\mathbf{F}\|_2 = 1 \\ \Rightarrow \mathbf{A}\dot{\mathbf{x}}(0) + \mathbf{F}\mathbf{x} &= \lambda'(0)\mathbf{x} + \lambda\dot{\mathbf{x}}(0) \\ \Rightarrow |\dot{\lambda}(0)| &= \frac{\mathbf{y}^H \mathbf{F} \mathbf{x}}{\mathbf{y}^H \mathbf{x}} \leq \underbrace{\frac{1}{|\mathbf{y}^H \mathbf{x}|}}_{\frac{1}{S(\lambda)}} \end{aligned}$$

$S(\lambda)$ 称为关于特征值 λ 的条件数。

目录

- 1 特征值估计和扰动
- 2 正交变换和矩阵因式分解**
- 3 (逆) 幂迭代法
- 4 QR方法
- 5 对称矩阵的特征值问题

Householder变换

设 $\mathbf{w} \in \mathbb{R}^n$ 且 $\|\mathbf{w}\| = 1$, 称矩阵

$$\mathbf{P} = \mathbf{I} - 2\mathbf{w}\mathbf{w}^\top, \quad (\text{Householder 矩阵})$$

- \mathbf{P} 对称, 且正交 $\Rightarrow \|\mathbf{P}\mathbf{x}\|_2 = \|\mathbf{x}\|_2$
- 设 S 为过原点且与 \mathbf{w} 垂直的平面, $\forall \mathbf{v} \in \mathbb{R}^n$, 存在 $\mathbf{v}_1 \in S, \mathbf{v}_2 \in S^\perp$, 满足 $\mathbf{v} = \mathbf{v}_1 + \mathbf{v}_2$, 有

$$\mathbf{P}\mathbf{v}_1 = \mathbf{v}_1, \quad \mathbf{P}\mathbf{v}_2 = -\mathbf{v}_2 \quad \Rightarrow \quad \mathbf{P}\mathbf{v} = \underbrace{\mathbf{v}_1 - \mathbf{v}_2}_{\text{初等镜面反射}}$$

- 任给 $\mathbf{x} \neq \mathbf{y}$ 且 $\|\mathbf{x}\|_2 = \|\mathbf{y}\|_2$, 存在 Householder 矩阵 \mathbf{P} , 使得 $\mathbf{y} = \mathbf{P}\mathbf{x}$

Givens变换

记 $c = \cos \theta$, $s = \sin \theta$, 旋转矩阵 $\mathbf{J} = \begin{bmatrix} c & s \\ -s & c \end{bmatrix}$

$\mathbf{J}(i, k, \theta) \in \mathbb{R}^{n \times n}$ 是旋转矩阵, 且有 $\mathbf{y} = \mathbf{J}(i, k, \theta)\mathbf{x}$ 满足

$$y_j = x_j, j \neq i, k, \quad y_i = cx_i + sx_k, \quad y_k = -sx_i + cx_k$$

不妨设 $k > i$ 。可以通过选取 c, s , 使得 $y_k = 0$ 。

- 若 $x_k = 0$, 则取 $c = 1, s = 0$
- 若 $x_k \neq 0$, 则有

$$\begin{cases} t = \frac{x_i}{x_k}, s = \text{sign}(x_k)(1 + t^2)^{-\frac{1}{2}}, c = st, & |x_k| \geq |x_i| \text{ 时,} \\ t = \frac{x_k}{x_i}, c = \text{sign}(x_k)(1 + t^2)^{-\frac{1}{2}}, s = ct, & |x_k| < |x_i| \text{ 时.} \end{cases}$$

QR因式分解

定理

设 $A \in \mathbb{R}^{n \times n}$, 则存在正交矩阵 P , 使得 $PA = R$, 其中 R 是上三角矩阵。

定理

设 $A \in \mathbb{R}^{n \times n}$, 存在正交矩阵 Q 与上三角矩阵 R , 使得

$$A = QR$$

若 A 是非奇异的, 且若规定 R 的对角元素大于 0, 则这种分解是唯一的。

QR分解计算: Householder变换、Givens变换、Gram-Schmidt正交化。

Shur分解

定理

设 $\mathbf{A} \in \mathbb{C}^{n \times n}$, 则存在酉矩阵 \mathbf{Q} , 使得 $\mathbf{Q}^H \mathbf{A} \mathbf{Q} = \mathbf{T}$ 为上三角矩阵。

定理 (实Shur分解定理)

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

$$\mathbf{Q}^T \mathbf{A} \mathbf{Q} = \begin{bmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} & \cdots & \mathbf{R}_{1n} \\ & \mathbf{R}_{22} & \cdots & \mathbf{R}_{2n} \\ & & \ddots & \vdots \\ & & & \mathbf{R}_{nn} \end{bmatrix}$$

其中 \mathbf{R}_{ii} 是 1×1 或者 2×2 的, 为 \mathbf{A} 的特征值或者一对共轭的复特征值。

目录

- 1 特征值估计和扰动
- 2 正交变换和矩阵因式分解
- 3 (逆) 幂迭代法**
- 4 QR方法
- 5 对称矩阵的特征值问题

幂迭代法

设 $\mathbf{A} \in \mathbb{R}^{n \times n}$ 且可对角化, 则有 n 个线性无关的特征向量 \mathbf{x}_i 满足

$$\mathbf{A}\mathbf{x}_i = \lambda_i\mathbf{x}_i, \quad i = 1, 2, \dots, n$$

对任意的 $\mathbf{x}^{(0)}$, 存在 $\alpha_i \in \mathbb{R}$, $i = 1, 2, \dots, n$ 使得

$$\mathbf{x}^{(0)} = \alpha_1\mathbf{x}_1 + \alpha_2\mathbf{x}_2 + \cdots + \alpha_n\mathbf{x}_n$$

若 $\alpha_1 \neq 0$, 有

$$\mathbf{A}^k \mathbf{x}^{(0)} = \lambda_1^k \left[\alpha_1 \mathbf{x}_1 + \underbrace{\sum_{i=2}^n \alpha_i \left(\frac{\lambda_i}{\lambda_1} \right)^k \mathbf{x}_i}_{\rightarrow 0, k \rightarrow \infty, \text{若 } |\lambda_i| < |\lambda_1|} \right] \approx \lambda_1^k \alpha_1 \mathbf{x}_1$$

给定 $\mathbf{v}^{(0)} \in \mathbb{R}^n$, 幂法迭代公式为

$$\mathbf{z}^{(k)} = \mathbf{A}\mathbf{v}^{(k-1)}, \quad m_k = \max(\mathbf{z}^{(k)}), \quad \mathbf{v}^{(k)} = \frac{\mathbf{z}^{(k)}}{m_k}$$

其中 $\max(\mathbf{z}) = z_i$, $|z_i| = \|\mathbf{z}\|_\infty$.

定理

若 \mathbf{A} 有 n 个线性无关的特征向量, 且对应的特征值满足

$$|\lambda_1| > |\lambda_2| \geq \cdots \geq |\lambda_n|,$$

若 $\mathbf{v}^{(0)}$ 在 \mathbf{x}_1 方向的投影非零, 则有

$$\lim_{k \rightarrow \infty} \mathbf{v}^{(k)} = \frac{\mathbf{x}_1}{\max(\mathbf{x}_1)}, \quad \lim_{k \rightarrow \infty} m_k = \lambda_1$$

λ_1 称为 \mathbf{A} 的主特征值, \mathbf{x}_1 称为主特征向量。

幂迭代法的收敛速度

$$|m_k - \lambda_1| \approx K \left| \frac{\lambda_2}{\lambda_1} \right|^k, \quad \frac{|m_{k+1} - \lambda_1|}{|m_k - \lambda_1|} \approx \left| \frac{\lambda_2}{\lambda_1} \right|$$

对于一般的矩阵A, 幂迭代法的分析则较为复杂。

加速技术: 类似于Aitken方法, 构造 $\bar{\lambda}_1^{(k)}$

$$\bar{\lambda}_1^{(k)} = \frac{m_k m_{k+2} - m_{k+1}^2}{m_{k+2} - 2m_{k+1} + m_k}$$

逆幂迭代法

将幂迭代法作用于 \mathbf{A}^{-1} :

$$\underbrace{\mathbf{z}^{(k)} = \mathbf{A}^{-1} \mathbf{v}^{(k-1)}}_{\text{求解 } \mathbf{A} \mathbf{z}^{(k)} = \mathbf{v}^{(k-1)}}, \quad m_k = \max(\mathbf{z}^{(k)}), \quad \mathbf{v}^{(k)} = \frac{\mathbf{z}^{(k)}}{m_k}$$

在幂迭代定理的条件下, 若

$$|\lambda_1| \geq |\lambda_2| \geq \cdots \geq |\lambda_{n-1}| > |\lambda_n| > 0, \quad \alpha_n \neq 0$$

则有

$$\lim_{k \rightarrow \infty} \mathbf{v}^{(k)} = \frac{\mathbf{x}_n}{\max(\mathbf{x}_n)}, \quad \lim_{k \rightarrow \infty} m_k = \lim_{k \rightarrow \infty} \frac{1}{\lambda_n} \left[1 + O \left(\left| \frac{\lambda_n}{\lambda_1} \right|^k \right) \right] = \frac{1}{\lambda_n}$$

原点位移逆幂迭代

如何通过逆幂迭代，找到特征值离 q 最近的特征值？

$$\sigma(\mathbf{A} - q\mathbf{I}) = \{\lambda - q | \lambda \in \sigma(\mathbf{A})\}$$

离 q 最近的特征值等价于 $\mathbf{A} - q\mathbf{I}$ 模长最小的特征值，对矩阵 $(\mathbf{A} - q\mathbf{I})^{-1}$ 做逆幂迭代，有

$$\underbrace{\mathbf{z}^{(k)} = (\mathbf{A} - q\mathbf{I})^{-1} \mathbf{v}^{(k-1)}}_{\text{求解 } (\mathbf{A} - q\mathbf{I})\mathbf{z}^{(k)} = \mathbf{v}^{(k-1)}}, \quad m_k = \max(\mathbf{z}^{(k)}), \quad \mathbf{v}^{(k)} = \frac{\mathbf{z}^{(k)}}{m_k}$$

$$\Rightarrow \lim_{k \rightarrow \infty} \mathbf{v}^{(k)} = \frac{\mathbf{x}_i}{\max(\mathbf{x}_i)}, \quad \lim_{k \rightarrow \infty} m_k = \frac{1}{\lambda_i}$$

q 值的估计可以从Gerschgorin圆盘定理得到。

收缩方法

设 $|\lambda_1| > |\lambda_2| > |\lambda_3| \geq \cdots \geq |\lambda_n|$, 若已经计算完 λ_1 , 如何计算 λ_2 ?

存在Householder矩阵 \mathbf{H} , 使得 $\mathbf{H}\mathbf{x}_1 = k\mathbf{e}_1$, 其中 $k = \|\mathbf{x}_1\|_2$, 则有

$$\mathbf{H}\mathbf{A}\mathbf{H}^{-1}\mathbf{e}_1 = \lambda_1\mathbf{e}_1 \quad \Rightarrow \quad \mathbf{A}_2 = \mathbf{H}\mathbf{A}\mathbf{H}^{-1} = \begin{bmatrix} \lambda_1 & \mathbf{b}_1^\top \\ \mathbf{0} & \mathbf{B}_2 \end{bmatrix}$$

且 $\sigma(\mathbf{B}_2) = \{\lambda_2, \lambda_3, \dots, \lambda_n\}$, 对 $\mathbf{B}_2 \in \mathbb{R}^{(n-1) \times (n-1)}$ 做幂迭代, 有 $\mathbf{B}_2\mathbf{y}_2 = \lambda_2\mathbf{y}_2$. 设 $\mathbf{z}_2 = [\alpha, \mathbf{y}^\top]^\top$, 由

$$\mathbf{A}_2\mathbf{z}_2 = \lambda_2\mathbf{z}_2 \Rightarrow \begin{cases} \lambda_1\alpha + \mathbf{b}_1^\top\mathbf{y} = \lambda_2\alpha \\ \mathbf{B}_2\mathbf{y} = \lambda_2\mathbf{y} \end{cases} \Rightarrow \mathbf{y} = \mathbf{y}_2, \alpha = \frac{\mathbf{b}_1^\top\mathbf{y}_2}{\lambda_2 - \lambda_1}$$

有 $\mathbf{x}_2 = \mathbf{H}^{-1}\mathbf{z}_2$ 是 \mathbf{A} 对应 λ_2 的特征向量。

设 λ_1 的重数为1, 向量 \mathbf{v} 满足 $\mathbf{v}^\top \mathbf{x}_1 = 1$, 则矩阵 $\mathbf{B} = \mathbf{A} - \lambda_1 \mathbf{x}_1 \mathbf{v}^\top$ 有特征值 $0, \lambda_2, \lambda_3, \dots, \lambda_n$, 对应的特征向量为 $\mathbf{x}_1, \mathbf{y}_2, \mathbf{y}_3, \dots, \mathbf{y}_n$, 其中 \mathbf{x}_i 与 \mathbf{y}_i 满足如下关系

$$\mathbf{x}_i = (\lambda_i - \lambda_1) \mathbf{y}_i + \lambda_1 (\mathbf{v}^\top \mathbf{y}_i) \mathbf{x}_1, i = 2, 3, \dots, n$$

Wielandt收缩方法:

$$\mathbf{v} = \frac{1}{\lambda_1 x_{1i}} (a_{i1}, a_{i2}, \dots, a_{in})^\top, \quad \mathbf{x}_1 = (x_{11}, x_{12}, \dots, x_{1n})^\top$$

有

$$\mathbf{v}^\top \mathbf{x}_1 = \frac{1}{\lambda_1 x_{1i}} \sum_{j=1}^n a_{ij} x_{1j} \Rightarrow \mathbf{B} \text{第} i \text{行元素全是零}$$

则可以删去 \mathbf{B} 的第 i 行与第 i 列。

目录

- 1 特征值估计和扰动
- 2 正交变换和矩阵因式分解
- 3 (逆) 幂迭代法
- 4 QR方法**
- 5 对称矩阵的特征值问题

QR方法

令 $A_1 = A$, 有如下迭代:

$$A_k = Q_k R_k \text{ (QR分解)}, \quad A_{k+1} = R_k Q_k \quad (2)$$

QR迭代(2)有如下性质:

- $A_{k+1} = Q_k^T A_k Q_k$
- 设 $\bar{Q}_k = Q_1 Q_2 \cdots Q_k$, $\bar{R}_k = R_k R_{k-1} \cdots R_1$, 有

$$A_{k+1} = \bar{Q}_k^T A \bar{Q}_k, \quad A^k = \bar{Q}_k \bar{R}_k$$

基本收敛到上三角矩阵: 矩阵序列 $\{A_k\}$ 对角元素均收敛且严格下三角元素收敛到0

引理

设 $M_k = Q_k R_k$, 其中 Q_k 正交, R_k 是正对角元素的上三角矩阵。
若 $M_k \rightarrow I$, 则有 $Q_k \rightarrow I, R_k \rightarrow I$

定理

设 A 的特征值满足 $|\lambda_1| > |\lambda_2| > \cdots > |\lambda_n| > 0$, 矩阵 $X = [x_1, x_2, \dots, x_n]$ 的每一列是所对应的特征向量。设 $X^{-1} = LU$, 其中 L 为单位下三角, U 为上三角, 则 QR 方法产生的序列 $\{A_k\}$ 基本收敛到上三角矩阵, 且有

$$\lim_{k \rightarrow \infty} a_{ii}^{(k)} = \lambda_i, \quad i = 1, 2, \dots, n$$

一般情况下的 QR 方法收敛性较为复杂。

上Hessenberg矩阵

上Hessenberg矩阵： $b_{ij} = 0, \forall i > j + 1$. 若 $b_{i,i-1} \neq 0$, 则B为不可约的上Hessenberg矩阵。

$$B = \begin{bmatrix} \star & \star & \cdots & \star & \star \\ \star & \star & \cdots & \star & \star \\ & \star & \cdots & \star & \star \\ & & \ddots & \vdots & \vdots \\ & & & \star & \star \end{bmatrix}$$

定理

设 $A \in \mathbb{R}^{n \times n}$, 则存在正交矩阵 $Q \in \mathbb{R}^{n \times n}$, 有 $B = Q^T A Q$ 为一个上Hessenberg矩阵。

上Hessenberg矩阵形式不唯一，但具有如下性质。

定理 (隐式Q定理)

设 Q, V 均为正交矩阵，且有 $Q^T A Q = H$ 和 $V^T A V = G$ 均为上Hessenberg矩阵。记 k 为 $h_{k+1,k} = 0$ 为最小整数，当 H 不可约时规定 $k = n$ 。如果 $q_1 = v_1$ ，则对 $i = 2, \dots, k$ 有

$$q_i = \pm v_i, \quad |h_{i,i-1}| = |g_{i,i-1}|$$

若 $k < n$ ，则 $g_{k+1,k} = 0$

G 与 H “本质上相同”，即 $G = D^{-1} H D$ ， D 为对角矩阵且对角元素为1或者-1

上Hessenberg矩阵的QR方法

用 $n - 1$ 次Givens变换将 \mathbf{H} 下三角元素变成0，即

$$\mathbf{U}^\top = \mathbf{J}(n - 1, n, \theta_{n-1}) \cdots \mathbf{J}(1, 2, \theta_1), \quad \mathbf{U}^\top \mathbf{H} = \mathbf{R}$$

可以验证，

$$\mathbf{H}_2 = \mathbf{R}\mathbf{U}$$

仍为上Hessenberg矩阵，即QR迭代法保持了上Hessenberg矩阵的结构形式。

带原点位移的QR方法

对 \mathbf{H} 的QR迭代方法的收敛速度取决于 $\max \left| \frac{\lambda_{j+1}}{\lambda_j} \right|$, 设 $\mathbf{H}_1 = \mathbf{H}$, 有

$$\mathbf{H}_k - \mu \mathbf{I} = \mathbf{U}_k \mathbf{R}_k (\mathbf{H}_k - \mu \mathbf{I} \text{ 的QR分解}), \quad \mathbf{H}_{k+1} = \mathbf{R}_k \mathbf{U}_k + \mu \mathbf{I}$$

上述迭代有如下关系:

$$\begin{aligned} \mathbf{H}_{k+1} &= \mathbf{R}_k \mathbf{U}_k + \mu \mathbf{I} = \mathbf{U}_k^\top (\mathbf{U}_k \mathbf{R}_k + \mu \mathbf{I}) \mathbf{U}_k = \mathbf{U}_k^\top \mathbf{H}_k \mathbf{U}_k \\ \Rightarrow \quad \mathbf{H}_k &\sim \mathbf{H}, \quad \forall k \in \mathbb{N} \end{aligned}$$

若 $\mu \in \sigma(\mathbf{A})$, 则 $\mathbf{H}_k - \mu \mathbf{I}$ 奇异, 从而 \mathbf{R}_k 对角线上必有零元素

可以证明 $|r_{ii}^{(k)}| \geq |h_{i+1,i}^{(k)}|$, $i = 1, 2, \dots, n-1$. 若 \mathbf{H}_k 不可约, 则有 $r_{nn}^{(k)} = 0$, 从而 \mathbf{H}_{k+1} 的最后一行为 $(0, \dots, 0, \mu)$

- 第一种带原点位移的QR迭代

$$\text{取 } \mu_k = h_{nn}^{(k)}, \quad \mathbf{H}_k - \mu_k \mathbf{I} = \mathbf{U}_k \mathbf{R}_k, \quad \mathbf{H}_{k+1} = \mathbf{R}_k \mathbf{U}_k + \mu_k \mathbf{I}$$

$$\text{取 } \bar{\mathbf{U}}_k = \mathbf{U}_1 \mathbf{U}_2 \cdots \mathbf{U}_k, \quad \bar{\mathbf{R}}_k = \mathbf{R}_k \mathbf{R}_{k-1} \cdots \mathbf{R}_1, \text{ 有}$$

$$\mathbf{H}_{k+1} = \bar{\mathbf{U}}_k^\top \mathbf{H}_1 \bar{\mathbf{U}}_k, \quad (\mathbf{H}_k \text{ 相似于 } \mathbf{H}_1)$$

$$(\mathbf{H}_1 - \mu_{k+1} \mathbf{I})(\mathbf{H}_1 - \mu_k \mathbf{I}) \cdots (\mathbf{H}_1 - \mu_1 \mathbf{I}) = \bar{\mathbf{U}}_{k+1} \mathbf{R}_{k+1}$$

- 第二种带原点位移的QR迭代

$$\mu_k \in \sigma \left(\begin{bmatrix} h_{n-1,n-1}^{(k)} & h_{n-1,n}^{(k)} \\ h_{n,n-1}^{(k)} & h_{nn}^{(k)} \end{bmatrix} \right)$$

且 μ_k 更接近于 $h_{nn}^{(k)}$

- 无法处理复共轭特征根

双重步QR方法

$$\mathbf{G} = \begin{bmatrix} h_{n-1,n-1} & h_{n-1,n} \\ h_{n,n-1} & h_{nn} \end{bmatrix}, \quad \mu_1, \mu_2 \in \sigma(\mathbf{G})$$

若 $\mu_1 = \bar{\mu}_2 \in \mathbb{C}$,

$$\begin{aligned} \mathbf{H} - \mu_1 \mathbf{I} &= \mathbf{U}_1 \mathbf{R}_1 \quad (\mathbf{H} - \mu_1 \mathbf{I} \text{ 复的QR分解}), & \mathbf{H}_1 &= \mathbf{R}_1 \mathbf{U}_1 + \mu_1 \mathbf{I} \\ \mathbf{H}_1 - \mu_2 \mathbf{I} &= \mathbf{U}_2 \mathbf{R}_2 \quad (\mathbf{H}_1 - \mu_2 \mathbf{I} \text{ 复的QR分解}), & \mathbf{H}_2 &= \mathbf{R}_2 \mathbf{U}_2 + \mu_2 \mathbf{I} \end{aligned} \quad (3)$$

设 $s = \mu_1 + \mu_2 \in \mathbb{R}$, $t = \mu_1 \mu_2 \in \mathbb{R}$, 则(3)等价于

$$\text{计算 } \mathbf{M} = \mathbf{H}^2 - s\mathbf{H} + t\mathbf{I}, \quad \mathbf{M} = \mathbf{Z}\mathbf{R} \text{ (实QR分解)}, \quad \mathbf{H}_2 = \mathbf{Z}^\top \mathbf{H} \mathbf{Z} \quad (4)$$

定理： 若 \mathbf{H} 为上 Hessenberg 矩阵, $\mu_1, \mu_2 \notin \sigma(\mathbf{H})$, 且 \mathbf{H}_2 由(4)得到,

则 \mathbf{H}_2 为上 Hessenberg 矩阵。

目录

- 1 特征值估计和扰动
- 2 正交变换和矩阵因式分解
- 3 (逆) 幂迭代法
- 4 QR方法
- 5 对称矩阵的特征值问题**

对称矩阵的性质

若 $\mathbf{A} \in \mathbb{R}^{n \times n}$ 且有 $\mathbf{A} = \mathbf{A}^\top$

性质： 存在正交矩阵 $\mathbf{Q} \in \mathbb{R}^{n \times n}$ ，使得

$$\mathbf{Q}^\top \mathbf{A} \mathbf{Q} = \text{Diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$$

定理

设 $\mathbf{A} = \mathbf{A}^\top$ ，且 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ ，则有

$$\lambda_i = \max_{\dim(\mathbf{W})=i} \min_{\mathbf{x} \in \mathbf{W}, \mathbf{x} \neq \mathbf{0}} \frac{(\mathbf{A}\mathbf{x}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})} = \min_{\mathbf{x} \in \text{Span}\{\mathbf{x}_1, \dots, \mathbf{x}_i\}, \mathbf{x} \neq \mathbf{0}} \frac{(\mathbf{A}\mathbf{x}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})}$$

$$\lambda_i = \min_{\dim(\mathbf{W})=n-i+1} \max_{\mathbf{x} \in \mathbf{W}, \mathbf{x} \neq \mathbf{0}} \frac{(\mathbf{A}\mathbf{x}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})} = \max_{\mathbf{x} \in \text{Span}\{\mathbf{x}_i, \dots, \mathbf{x}_n\}, \mathbf{x} \neq \mathbf{0}} \frac{(\mathbf{A}\mathbf{x}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})}$$

定理 (扰动性质)

设 \mathbf{A} , \mathbf{E} 为对称矩阵, 有

$$\sigma(\mathbf{A}) = \{\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n\}$$

$$\sigma(\mathbf{E}) = \{v_1 \geq v_2 \geq \cdots \geq v_n\}$$

$$\sigma(\mathbf{A} + \mathbf{E}) = \{\mu_1 \geq \mu_2 \geq \cdots \geq \mu_n\}$$

则有 $\lambda_i + v_n \leq \mu_i \leq \lambda_i + v_1, \forall i = 1, 2, \dots, n$

推论: $|\lambda_i - \mu_i| \leq \rho(\mathbf{E}) \leq \|\mathbf{E}\|_2, \forall i = 1, 2, \dots, n$

定理

设 $\mathbf{A} = \mathbf{A}^\top$, $\mathbf{B} = \mathbf{P}^\top \mathbf{A} \mathbf{P}$, 其中 \mathbf{P} 是正交矩阵, 则有 $\|\mathbf{B}\|_F = \|\mathbf{A}\|_F$

Rayleigh商迭代法

$\mathbf{A} \in \mathbb{C}^{n \times n}$, $\mathbf{x} \in \mathbb{C}^n$, $\mathbf{x} \neq \mathbf{0}$, 定义

$$\mathbf{R}(\mathbf{x}) = \frac{(\mathbf{A}\mathbf{x}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})}, \quad (\text{Rayleigh商})$$

性质: $\mathbf{R}(\mathbf{x}) = \min_{\lambda \in \mathbb{C}} \|(\mathbf{A} - \lambda \mathbf{I})\mathbf{x}\|_2$

因此, 若 \mathbf{v} 近似一个特征向量, 则 $\mathbf{R}(\mathbf{v})$ 近似相应的特征值。

Rayleigh商迭代法: 给定 $\mathbf{v}^{(0)} \in \mathbb{R}^n$ 且 $\|\mathbf{v}^{(0)}\|_2 = 1$

$$\mu_k = \mathbf{R}(\mathbf{v}^{(k)}), \quad \text{解}(\mathbf{A} - \mu_k \mathbf{I})\mathbf{y}^{(k+1)} = \mathbf{v}^{(k)}, \quad \mathbf{v}^{(k+1)} = \mathbf{y}^{(k+1)} / \|\mathbf{y}^{(k+1)}\|_2 \quad (5)$$

可以证明, (5)是三次收敛的。

古典Jacobi方法

利用Givens变换（Jacobi旋转矩阵）,使得 $\text{off}(\mathbf{A})$ 变为0。

$$\text{off}(\mathbf{A}) = \sum_{i,j=1, i \neq j}^n a_{ij}^2 = \|\mathbf{A}\|_F^2 - \sum_{i=1}^n a_{ii}^2$$

考虑 $\mathbf{J} = \mathbf{J}(p, q, \theta)$, 则 $\mathbf{B} = \mathbf{J}\mathbf{A}\mathbf{J}^{-1}$ 有

$$\begin{aligned} b_{pp} &= a_{pp}c^2 + a_{qq}s^2 + a_{pq}\sin 2\theta, \\ b_{qq} &= a_{pp}s^2 + a_{qq}c^2 - a_{pq}\sin 2\theta \\ b_{pq} &= b_{qp} = \frac{1}{2}(a_{qq} - a_{pp})\sin 2\theta + a_{pq}\cos 2\theta \end{aligned} \Rightarrow \begin{aligned} &b_{pp}^2 + b_{qq}^2 + 2b_{pq}^2 \\ &= a_{pp}^2 + a_{qq}^2 + 2a_{pq}^2 \end{aligned}$$

$$b_{ip} = b_{pi} = a_{ip}c + a_{iq}s, \quad i \neq p, q$$

$$b_{iq} = b_{qi} = -a_{ip}s + a_{iq}c, \quad i \neq p, q \Rightarrow b_{ip}^2 + b_{iq}^2 = a_{ip}^2 + a_{iq}^2$$

$$b_{ij} = a_{ij}, \quad \text{otherwise}$$

$$\begin{aligned}
\text{off}(\mathbf{B}) &= \|\mathbf{B}\|_F^2 - \sum_{i=1}^n b_{ii}^2 = \|\mathbf{A}\|_F^2 - \sum_{i \neq p,q}^n a_{ii}^2 - (b_{pp}^2 + b_{qq}^2) \\
&= \|\mathbf{A}\|_F^2 - \sum_{i=1}^n a_{ii}^2 + (a_{pp}^2 + a_{qq}^2 - b_{pp}^2 - b_{qq}^2) \\
&= \text{off}(\mathbf{A}) - 2a_{pq}^2 + 2b_{pq}^2
\end{aligned}$$

选取合适的 θ , 使得

$$b_{pq} = \frac{1}{2}(a_{qq} - a_{pp}) \sin 2\theta + a_{pq} \cos 2\theta = 0 \Rightarrow \cot 2\theta = \frac{a_{pp} - a_{qq}}{2a_{pq}} = \tau$$

令 $t = \tan \theta$, 则 t 满足

$$\begin{aligned}
t^2 + 2t\tau - 1 &= 0 \Rightarrow t = \frac{\text{sign}\tau}{|\tau| + \sqrt{1 + \tau^2}}, (|\theta| \leq \pi/4) \\
&\Rightarrow c = \frac{1}{\sqrt{1 + t^2}}, \quad s = tc
\end{aligned} \tag{6}$$

设 $\mathbf{A}_1 = \mathbf{A}$, 在 \mathbf{A}_k 中选取非对角元素绝对值最大的元素 $a_{pq}^{(k)}$, 按照公式(6)选取合适的 c 和 s , 构造相应的矩阵 $\mathbf{J}_k = \mathbf{J}(p, q, \theta_k)$, 使得

$$\mathbf{A}_{k+1} = \mathbf{J}_k \mathbf{A}_k \mathbf{J}_k^\top$$

则有

$$\text{off}(\mathbf{A}_{k+1}) = (\text{off})(\mathbf{A}_k) - 2a_{pq}^{(k)2} \leq 1 - \frac{1}{N} \text{off}(\mathbf{A}_k),$$

其中 $N = \frac{n(n-1)}{2}$ 。

更进一步,

$$\mathbf{J}_m \cdots \mathbf{J}_1 \mathbf{A} \mathbf{J}_1^\top \cdots \mathbf{J}_m^\top \approx \mathbf{D}$$

\mathbf{D} 为一个对角矩阵, $\mathbf{Q}_m = \mathbf{J}_1^\top \cdots \mathbf{J}_m^\top$ 为近似特征向量。

注: 合理选择更新次序, 平行化实现, 实现迭代加速。

对称矩阵的QR方法

若 $A = A^T$, 存在正交矩阵 Q , 使得 $Q^T A Q = H$ 为 **实对称三对角矩阵**。

设 T 为实对称三对角矩阵, T 的QR分解具有如下性质:

- $T = QR$, 正交矩阵 Q 下带宽为1, 上三角矩阵 R 上带宽为2, 而且 $RQ = Q^T T Q$ 也是对称三对角矩阵。
- $s \in \mathbb{R}$, $T - sI = QR$, 则 $RQ + sI = Q^T T Q$ 也是三对角矩阵
- 设 T 不可约, 对一切 $s \in \mathbb{R}$, 有 $T - sI$ 前 $n-1$ 列线性无关。
若 $s \in \sigma(T)$, $QR = T - sI$, 则有 $r_{nn} = 0$ 且 $RQ + sI$ 的最后一列等于 se_n

迭代格式:

$$T_k - \mu_k I = Q_k R_k \text{ (QR分解)}, \quad T_{k+1} = R_k Q_k + \mu_k I$$

μ_k 的选取: Wilkinson位移。