

Lect 11 Eigenvalue Problem

一. Why?

1. 量子力学: $\hat{H}\psi = \lambda\psi$ 目的: 求最小特征值 $\lambda_{\min}$: 基态2. 动力系统: $\dot{y} = F(y)$ 局部稳定性, $J = \partial F / \partial y$ 特征值及向量.3. Markov 链: $\mu_{n+1} = P \cdot \mu_n$ 不变分布的收敛速度: P 的第二大特征值.

二. 基本结果:

1. Jordan 形: $A = P \cdot J \cdot P^{-1}$, $A \in \mathbb{C}^{n \times n}$ 2. 对称矩阵: $A = Q \Lambda Q^T$, $Q^T Q = I$,

$$\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$$

3. Courant-Fisher 定理:

设 A 对称, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$, 定义 Rayleigh 商.

$$R_A(u) = \frac{u^T A u}{u^T u}$$

则 $\lambda_1 = \max R_A(u)$, $\lambda_n = \min R_A(u)$

4. Gershgorin 圆盘定理: $A \in \mathbb{C}^{n \times n}$, 则 A 特征值位于区域

$$D = \bigcup_{\bar{i}} D_{\bar{i}} \text{ 内}$$

其中

$$D_{\bar{i}} = \left\{ z \mid |z - a_{ii}| \leq \sum_{j \neq i} |a_{ij}| \right\}$$

证: 设 $A \cdot X = \lambda X$, 及 $|x_j| = \|X\|_\infty$, 则

$$\begin{aligned} |\lambda - a_{jj}| &= \left| \sum_{k \neq j} a_{jk} x_k / x_j \right| \leq \sum_{k \neq j} |a_{jk}| \cdot |x_k| / \|X\|_\infty \\ &\leq \sum_{k \neq j} |a_{jk}| \quad \# \end{aligned}$$

二. 幂法 (power method)

幂法是计算矩阵模最大特征值及其特征向量的方法。

1. 设 $A = V \Lambda \cdot V^{-1}$, $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$, 及

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|$$

任取 $u_0 = \alpha_1 v_1 + \dots + \alpha_n v_n$, v_i 为 V 的列向量。

则 $A^k u_0 = \sum_j \alpha_j A^k v_j = \sum_j \alpha_j \lambda_j^k v_j$

11-03

$$= \lambda_1^k \left(\alpha_1 v_1 + \sum_{j \neq 1} \alpha_j \left(\frac{\lambda_j}{\lambda_1} \right)^k v_j \right)$$

由此知 $\lim_{k \rightarrow \infty} \frac{A^k u_0}{\lambda_1^k} = \alpha_1 v_1$

2. 算法:

step1: 设置初值 u_0 , $k=1$;

step2: 求 $y_k = A \cdot u_{k-1}$;

step3: 找 k s.t. μ_k 为 y_k 中模最大的分量.

step4: 归一化: $u_k = y_k / \mu_k$, k 增加1.

则 $u_k \rightarrow v_1$, $\mu_k \rightarrow \lambda_1$.

3. 收敛性:

定理: 设 $A \in \mathbb{C}^{n \times n}$ 有 p 个不同特征值, $|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_p|$ 且 λ_1 为半单的 (即 λ_1 的几何重数 = 代数重数). 如 u_0 在 λ_1 的特征子空间投影不为 0, 则 $u_k \rightarrow \lambda_1$ 的某特征向量 v_1 , $\mu_k \rightarrow \lambda_1$.

证: 由假设

11-04

$$A = V \cdot \text{diag}(J_1, \dots, J_p) \cdot V^{-1}$$

$J_{\bar{i}} \in \mathbb{C}^{n_{\bar{i}} \times n_{\bar{i}}}$ 为 $\lambda_{\bar{i}}$ 的 Jordan 块上三角阵, $\sum_{\bar{i}=1}^p n_{\bar{i}} = n$
 λ_i 为单根 $\Leftrightarrow J_i = \lambda_i I_{n_i}$.

令 $y = V^{-1} u_0$, 及 $y = (y_1^T, \dots, y_p^T)^T$,

$V = [V_1, V_2, \dots, V_p]$ $V_{\bar{i}}$ 为 $n \times n_{\bar{i}}$ 的矩阵

则
$$\begin{aligned} A^k u_0 &= \sum_{\bar{j}=1}^p V_{\bar{j}} J_{\bar{j}}^k y_{\bar{j}} \\ &= \lambda_1^k V_1 y_1 + \sum_{\bar{j}=2}^p V_{\bar{j}} J_{\bar{j}}^k y_{\bar{j}} \\ &= \lambda_1^k \left(V_1 y_1 + \sum_{\bar{j}=2}^p V_{\bar{j}} J_{\bar{j}}^k / \lambda_1^k y_{\bar{j}} \right) \end{aligned}$$

于是 $\lim_{k \rightarrow \infty} \frac{1}{\lambda_1^k} A^k u_0 = V_1 y_1 \neq 0$

令 $v_1 = \zeta^{-1} V_1 y_1$, ζ 为 $V_1 y_1$ 的模最大分量,

而 ζ_k 为 $A^k u_0$ 的模最大分量, 则

$$\begin{aligned} u_k &= A u_{k-1} / \mu_k = A^k u_0 / \zeta_k = \frac{A^k u_0}{\lambda_1^k} / \frac{\zeta_k}{\lambda_1^k} \\ &\longrightarrow V_1 y_1 / \zeta = v_1 \end{aligned}$$

11-05

$$\text{而 } Au_{k-1} = \mu_k u_k \quad u_k \rightarrow v_1 \Rightarrow \mu_k \rightarrow \lambda_1$$

4. 其它特征值的计算:

设 $Av_1 = \lambda_1 v_1$, 设酉阵 P s.t. $Pv_1 = \alpha e_1$,
 则 $PA P^* e_1 = \lambda_1 e_1$,

即 $PA P^* = \begin{bmatrix} \lambda_1 & \dots \\ 0 & B_1 \end{bmatrix}$ 对 B_1 可继续用幂法.

5. 反幂法 (inverse power method)

反幂法即对 A^{-1} 用幂法得 A 模最小的特征值.

$$\begin{cases} Ay_k = u_{k-1} \\ \mu_k = \sum_{i=1}^n y_{ki}^2 \text{ 为 } y_k \text{ 模最大的分量} \\ u_k = y_k / \mu_k \end{cases}$$

实际应用中, 反幂法主要用来求接近 $\tilde{\lambda}$ 的特征值 λ^*
 (即 $\tilde{\lambda} \approx \lambda^*$ 为一近似), 应用幂法至 $A - \tilde{\lambda}I$, 即

$$(A - \tilde{\lambda}I)y_k = u_{k-1}$$

即得一收敛较快的方法.

11-06

6. Rayleigh 高加速:

如 A 对称, 已有近似特征向量 u_0 , 则可用以下 Rayleigh 高加速:

step1: 初值 u_0 , $k=1$;

step2: $\mu_k = R_A(u_{k-1})$

step3: ~~解~~ $(A - \mu_k I) y_k = u_{k-1}$;

step4: $u_k = y_k / \|y_k\|_2$, 迭代

Rayleigh 高加速如收敛, 则为三次收敛!

四. QR 方法简述:

给定 $A_0 = A \in \mathbb{C}^{n \times n}$, QR 算法的格式为

$$A_{m-1} = Q_m R_m,$$

$$A_m = R_m Q_m, \quad m=1, 2, \dots$$

其中 Q 为酉阵 ($Q^* Q = I$), R 为上三角阵.

显然: $A_m = Q_m^* A_{m-1} Q_m$

$$= \tilde{Q}_m^* A \tilde{Q}_m, \quad \tilde{Q}_m = Q_1 \cdots Q_m$$

11-07

定理: 设 A 的特征值 $|\lambda_1| > |\lambda_2| > \dots > |\lambda_n| > 0$, 设 V 的第 i 行为 A 对应于 λ_i 的左特征向量 ($A = V^{-1} \Lambda \cdot V$), 如 V 有 LU 分解, 则 QR 迭代中 $A_m = [\alpha_{ij}^{(m)}]$ 的对角线以下元素 $\rightarrow 0$, 且对角线 $\alpha_{ii}^{(m)} \rightarrow \lambda_i$, $i=1, \dots, n$

RMK: QR 方法二次收敛!