

第九章 特征值和特征向量的计算.

特征值的求解方法主要分为迭代法和分解法.

9.1 幂法

幂法的基本思想: 令 $\vec{x}^{(k)} = A^k \vec{x}^{(0)}$

当 k 充分大时, 归一化的 $\vec{x}^{(k)}$ 趋近于特征向量 \vec{v}_1 .

1° 证明: 假设 $A \in \mathbb{R}^{n \times n}$, A 有 n 个线性无关的特征向量 $\vec{v}_1, \vec{v}_2, \dots, \vec{v}_n$, 且相应特征值按模递减, 且 λ_1 是单实根.

$$\text{令 } \vec{x}^{(0)} = \sum_{i=1}^n a_i \vec{v}_i$$

$$\text{则 } \vec{x}^{(k)} = A^k \sum_{i=1}^n a_i \vec{v}_i = \sum_{i=1}^n a_i \lambda_i^k \vec{v}_i = \lambda_1^k \left(\sum_{i=1}^n a_i \left(\frac{\lambda_i}{\lambda_1}\right)^k \vec{v}_i \right)$$

$$\text{当 } k \rightarrow \infty \text{ 时, } \vec{x}^{(k)} \approx \lambda_1^k a_1 \vec{v}_1 \text{ 且 } \frac{\vec{x}^{(k+1)}}{\lambda_1} \rightarrow \lambda_1.$$

注: 当 $|\frac{\lambda_2}{\lambda_1}| \approx 1$ 时, 收敛速度慢; 当 $|\frac{\lambda_2}{\lambda_1}|$ 小时, 收敛速度快.

归一化操作:

$$\begin{cases} \vec{y}^{(k)} = \frac{\vec{x}^{(k)}}{\|\vec{x}^{(k)}\|_\infty} \\ \vec{x}^{(k+1)} = A \vec{y}^{(k)} \end{cases}$$

类似地, 可证当 $k \rightarrow \infty$ 时, $|\vec{y}^{(k)}| \rightarrow \left| \frac{a_1 \vec{v}_1}{\|a_1 \vec{v}_1\|_\infty} \right|$ 且 $\|\vec{x}^{(k)}\|_\infty \rightarrow |\lambda_1|$

2° 若 λ_1 是重根, 即 $\lambda_1 = \lambda_2 = \dots = \lambda_r$, ($r \leq n$),

$$\text{则 } \vec{y}^{(k)} = \frac{\vec{x}^{(k)}}{\|\vec{x}^{(k)}\|_\infty} = \left(\frac{\lambda_1}{|\lambda_1|}\right)^k \frac{a_1 \vec{v}_1 + a_2 \vec{v}_2 + \dots + a_r \vec{v}_r + a_{r+1} \left(\frac{\lambda_{r+1}}{\lambda_1}\right)^k \vec{v}_{r+1} + \dots + a_n \left(\frac{\lambda_n}{\lambda_1}\right)^k \vec{v}_n}{\|a_1 \vec{v}_1 + a_2 \vec{v}_2 + \dots + a_r \vec{v}_r + a_{r+1} \left(\frac{\lambda_{r+1}}{\lambda_1}\right)^k \vec{v}_{r+1} + \dots + a_n \left(\frac{\lambda_n}{\lambda_1}\right)^k \vec{v}_n\|_\infty}$$

$$\therefore |\vec{y}^{(k)}| \rightarrow \frac{a_1 \vec{v}_1 + a_2 \vec{v}_2 + \dots + a_r \vec{v}_r}{\|a_1 \vec{v}_1 + a_2 \vec{v}_2 + \dots + a_r \vec{v}_r\|_\infty}, \text{ 仍是 } \lambda_1 \text{ 的特征向量.}$$

$$\text{且 } \|\vec{x}^{(k)}\|_\infty \rightarrow |\lambda_1|$$

注: 1) 若计算结果不收敛, 则应改用它法.

2) 幂法的特点: 优点: 算法简单, 能同时求特征值和特征向量, 适合稀疏矩阵. (因为每步迭代计算量小.)
缺点: 收敛速度慢.

9.2 幂法的加速与降阶

1° 加速 (原点位移法)

用 $A - \lambda_0 I$ 代替 A 进行迭代时, 新的特征值为 $\lambda_i - \lambda_0$, 如果能使 $\max \left\{ \left| \frac{\lambda_2 - \lambda_0}{\lambda_1 - \lambda_0} \right|, \dots, \left| \frac{\lambda_n - \lambda_0}{\lambda_1 - \lambda_0} \right| \right\}$ 有效地减小, 则实现了幂法的加速。

例如, 对正定矩阵, 可令 $\lambda_0 = \frac{1}{2}(\lambda_2 + \lambda_n)$, ($\lambda_1 \neq \lambda_2$)。

注: 由于矩阵特征值的分布并不清楚, 所以常常需预估一个 λ_0 。

2° 降阶

假设 A 为实对称矩阵, 则 A 有 n 个相互正交的特征向量。

记 $A^{(1)} = A$, 构造

$$A^{(2)} = A^{(1)} - \lambda_1 \frac{\vec{v}_1 \vec{v}_1^T}{(\vec{v}_1^T \vec{v}_1)}$$

$$\text{则 } A^{(2)} \vec{v}_1 = A^{(1)} \vec{v}_1 - \lambda_1 \frac{\vec{v}_1 \vec{v}_1^T \vec{v}_1}{(\vec{v}_1^T \vec{v}_1)} = \vec{0}$$

$$A^{(2)} \vec{v}_i = A^{(1)} \vec{v}_i - \lambda_1 \vec{v}_1 \frac{\vec{v}_1^T \vec{v}_i}{\vec{v}_1^T \vec{v}_1} = \lambda_i \vec{v}_i \quad (i=2, \dots, n)$$

\therefore 此时, $A^{(2)}$ 的按模最大特征值为 λ_2 , 按幂法可得 λ_2 和 \vec{v}_2

一般地, 可以定义

$$A^{(k+1)} = A^{(k)} - \lambda_k \frac{\vec{v}_k \vec{v}_k^T}{(\vec{v}_k^T \vec{v}_k)}, \text{ 从而求得 } \lambda_k \text{ 和 } \vec{v}_k.$$

注: 此法求出的特征值精度会下降, 一般只能求前几个特征值和特征向量。

9.3 反幂法

用途: 求矩阵的按模最小特征值和特征向量。

假设矩阵 A 是实非奇异阵, 且有 n 个线性无关的特征向量 $\vec{v}_1, \dots, \vec{v}_n$, 且对应特征值按模递减。

$$\therefore A \vec{v}_i = \lambda_i \vec{v}_i$$

$$\therefore A^{-1} \vec{v}_i = \frac{1}{\lambda_i} \vec{v}_i, \text{ 即 } A^{-1} \text{ 的特征值为 } \frac{1}{\lambda_i}, \text{ 且按模最大特征值为 } \frac{1}{\lambda_n}.$$

① 解线性方程组法

因为 A^{-1} 很难求, 一般解法为:

$$\begin{cases} \vec{y}^{(k)} = \frac{\vec{x}^{(k)}}{\|\vec{x}^{(k)}\|_\infty} \\ A \vec{x}^{(k+1)} = \vec{y}^{(k)} \end{cases} \quad (k=0, 1, 2, \dots)$$

$$\text{作 LU 分解得 } \begin{cases} \vec{y}^{(k)} = \frac{\vec{x}^{(k)}}{\|\vec{x}^{(k)}\|_\infty} \\ L \vec{z}^{(k)} = \vec{y}^{(k)} \\ U \vec{x}^{(k+1)} = \vec{z}^{(k)} \end{cases}$$

② 原点加速法

$(A - \lambda_0 I)^{-1}$ 的特征值为 $\frac{1}{\lambda_1 - \lambda_0}, \dots, \frac{1}{\lambda_n - \lambda_0}$.

1° 若取 $\lambda_0 \approx \lambda_k$, 则 $\left| \frac{\frac{1}{\lambda_1 - \lambda_0}}{\frac{1}{\lambda_k - \lambda_0}} \right|$ ($k \neq 1$) 可以很大,

能很快收敛. 因为 $A - \lambda_0 I$ 几乎奇异, 所以用到主元 LU 分解求解.

2° 若已知近似的 \vec{x}_1 , 则 $\lambda_k \approx \frac{\vec{x}_1^T A \vec{x}_1}{\vec{x}_1^T \vec{x}_1}$, 可令 $\lambda_0 = \lambda_k$.

③ 特征值修正.

若已知近似的特征值 λ^* , 可令 $\lambda_0 = \lambda^*$, 求出 $\frac{1}{\lambda - \lambda^*}$,

收敛速度一般很快.

9.4 平行迭代法

基本算法: 幂法 \rightarrow 修正幂法

用途: 同时计算前几个较大的特征值及对应特征向量.

对于高阶对称稀疏矩阵比较有效.

9.5 QR 算法

用途: 求实非奇异阵的全部特征值.

QR 分解定理: 若 $A \in \mathbb{R}^{n \times n}$ 且非奇异, 则 $\exists Q, R$, st.

$$A = QR.$$

且除矩阵的 \bullet 行(列)号外, 分解是唯一的.

① 基本 QR 算法

取 $A_1 = A$, 做迭代

$$\begin{cases} A_k = Q_k R_k & (k=0, 1, \dots) \\ A_{k+1} = R_k Q_k \end{cases}$$

$$\therefore A_{k+1} = R_k Q_k = Q_k^T A_k Q_k$$

$\therefore A_{k+1} \sim A_k$, 有相同的特征值.

② QR 算法的收敛性.

本质收敛: 序列 $\{A_k\}$ 收敛于上三角(或分块上三角)矩阵,

其对角线元素(或子块)有确定的极限.(简单情形收敛到对角阵)

定理: 若 A 可对角化, 且 $A = XDX^{-1}$, D 的各对角元按模

递减排列, 且 $X^{-1} = LyUy$,

则 $\{A_k\}$ 本质收敛.

③ QR分解法

- 1° Schmidt 正交化
- 2° Householder 变换
- 3° Givens 变换

④ 用反幂法求特征向量

已知近似的 λ^* , 令 $\lambda_0 = \lambda^*$, 用反幂法可求出更精确的 λ 和对应特征向量 \vec{v}

⑤ 带原点位移的 QR 方法

取 $A_1 = A$, 作迭代

$$\begin{cases} A_k - \mu_k I = Q_k R_k \\ A_{k+1} = R_k Q_k + \mu_k I \end{cases} \quad (k=1, 2, \dots)$$

其中, μ_k 称为第 k 次迭代的原点位移量, 可取 $a_{nn}^{(k)}$

$$\begin{aligned} \therefore A_{k+1} &= R_k Q_k + \mu_k I \\ &= Q_k^{-1} (A_k - \mu_k I) Q_k + \mu_k I \\ &= Q_k^{-1} A_k Q_k \end{aligned}$$

$\therefore A_{k+1} \sim A_k$, 有相同的特征值.

9.6 Jacobi 迭代法

用途: 求实对称矩阵的特征值和特征向量. 适用于阶数不高的实对称阵.

① 基本思想

取 $A_0 = A$, 做迭代: $A_k = R_k^T A_{k-1} R_k$, 其中 R_k 为正交阵, 逐步将 A_k 变换为对角阵 D .

记 $V_k = R_1 \cdots R_k$, 则 V_k 也是正交阵, 且 $D = V_k^T A V_k$.

$$A V_k = V_k D$$

即 D 的对角元为 A 的特征值, V_k 的列向量为 A 的特征向量.

② 平面旋转矩阵.

$$\text{平面旋转矩阵: } R(i, j, \varphi) = \begin{pmatrix} 1 & & & & & \\ & \ddots & & & & \\ & & \cos \varphi & & -\sin \varphi & \\ & & & \ddots & & \\ & & \sin \varphi & & \cos \varphi & \\ & & & & & \ddots & \\ & & & & & & 1 \end{pmatrix}$$

对对称矩阵A作正交相似变换: $A_1 = R_{ij}^T A R_{ij}$

$$\begin{cases} a_{ii}^{(1)} = a_{ii} \cos^2 \varphi + a_{jj} \sin^2 \varphi + 2a_{ij} \cos \varphi \sin \varphi \\ a_{jj}^{(1)} = a_{ii} \sin^2 \varphi + a_{jj} \cos^2 \varphi - 2a_{ij} \cos \varphi \sin \varphi \\ a_{il}^{(1)} = a_{li}^{(1)} = a_{il} \cos \varphi + a_{jl} \sin \varphi \quad (l \neq i, j) \\ a_{jl}^{(1)} = a_{lj}^{(1)} = -a_{il} \sin \varphi + a_{jl} \cos \varphi \quad (l \neq i, j) \\ a_{ij}^{(1)} = a_{ji}^{(1)} = \frac{1}{2}(a_{ij} - a_{ji}) \sin 2\varphi + a_{ij} \cos 2\varphi \\ a_{lm}^{(1)} = a_{ml}^{(1)} = a_{ml} = a_{lm} \end{cases}$$

若取 φ , 使得 $\cot 2\varphi = \frac{a_{ii} - a_{jj}}{2a_{ij}}$, 则旋转得到 $a_{ij}^{(1)} = a_{ji}^{(1)} = 0$.

每次取按模最大的非对角元所在的行和列为 i, j 进行如上旋转, 经过无穷次平面旋转可以使矩阵对角化。

③收敛性

设A的非对角线元素平方和为 $E(A) = \sum_{i \neq j} a_{ij}^2$

$$\begin{aligned} \therefore (a_{il}^{(k+1)})^2 + (a_{jl}^{(k+1)})^2 &= (a_{il}^{(k)} \cos \varphi + a_{jl}^{(k)} \sin \varphi)^2 + (-a_{il}^{(k)} \sin \varphi + a_{jl}^{(k)} \cos \varphi)^2 \\ &= (a_{il}^{(k)})^2 + (a_{jl}^{(k)})^2 \end{aligned}$$

$$\text{同理 } (a_{li}^{(k+1)})^2 + (a_{lj}^{(k+1)})^2 = (a_{li}^{(k)})^2 + (a_{lj}^{(k)})^2$$

$$\text{又 } (a_{lm}^{(k+1)})^2 = (a_{ml}^{(k+1)})^2 = (a_{lm}^{(k)})^2 = (a_{ml}^{(k)})^2$$

$$\bullet a_{ij}^{(k+1)} = a_{ji}^{(k+1)} = 0$$

$$\therefore E(A_{k+1}) = E(A_k) - 2(a_{ij}^{(k)})^2$$

对角线元素之和

$$\begin{aligned} (a_{ii}^{(k+1)})^2 + (a_{jj}^{(k+1)})^2 &= (a_{ii}^{(k)} \cos^2 \varphi + a_{jj}^{(k)} \sin^2 \varphi + 2a_{ij}^{(k)} \cos \varphi \sin \varphi)^2 + \\ &\quad (a_{ii}^{(k)} \sin^2 \varphi + a_{jj}^{(k)} \cos^2 \varphi - 2a_{ij}^{(k)} \cos \varphi \sin \varphi)^2 \\ &= (a_{ii}^{(k)})^2 + (a_{jj}^{(k)})^2 + 2(a_{ij}^{(k)})^2 \end{aligned}$$

\therefore 正交相似变换矩阵元素的平方和不变, 且上述变换对角线元素平方和增大。

$$\text{按②中的 } i, j \text{ 取法时, } (a_{ij}^{(k)})^2 \geq \frac{E(A_k)}{n^2 - n}$$

$$\therefore E(A_{k+1}) \leq E(A_k) - 2(a_{ij}^{(k)})^2 \leq E(A_k) - 2 \frac{E(A_k)}{n^2 - n} = (1 - \frac{2}{n^2 - n}) E(A_k)$$

$$\therefore E(A_k) \leq (1 - \frac{2}{n^2 - n})^k E(A), \text{ 即 } \lim_{k \rightarrow \infty} E(A_k) = 0.$$

$\bullet \therefore$ Jacobi 迭代法收敛

注: Jacobi 迭代法得到的系数矩阵不一定稀疏。