



## 7.2 幂法和反幂法

### 7.2.1 幂法和加速方法

### 7.2.2 反幂法和原点位移





## 7.2.1 幂法和加速方法

设矩阵  $A \in R^{n \times n}$  的  $n$  个特征值满足

$$|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|, \quad (7.2.1)$$

对应的  $n$  个特征向量  $x_1, x_2, \dots, x_n$  线性无关. 称模最大的特征值  $\lambda_1$  为主特征值, 称对应的特征向量  $x_1$  为主特征向量.

幂法用于主特征值和特征向量. 它的基本思想是任取一个非零的初始向量  $v_0$ , 由矩阵  $A$  构造一向量序列

$$v_k = Av_{k-1} = A^k v_0, k = 1, 2, \dots$$

由假设  $v_0$  可表示为

$$v_0 = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n. \quad (7.2.2)$$





若记  $(v_k)_i$  为  $v_k$  的第  $i$  个分量，则有

$$\begin{aligned} v_k &= A^k v_0 = \sum_{i=1}^n \alpha_i \lambda_i^k x_i \\ &= \lambda_1^k \left[ \alpha_1 x_1 + \sum_{i=2}^n \alpha_i \left( \frac{\lambda_i}{\lambda_1} \right)^k x_i \right] = \lambda_1^k (\alpha_1 x_1 + \varepsilon_k), \end{aligned}$$

$$\frac{(v_{k+1})_i}{(v_k)_i} = \frac{\lambda_1 (\alpha_1 x_1 + \varepsilon_{k+1})_i}{(\alpha_1 x_1 + \varepsilon_k)_i},$$

其中  $\varepsilon_k = \sum_{i=2}^n \alpha_i \left( \lambda_i / \lambda_1 \right)^k x_i$ 。若  $\alpha_1 \neq 0, (x_1)_i \neq 0$ ,

则由  $\lim_{k \rightarrow \infty} \varepsilon_k = 0$  知

$$\lim_{k \rightarrow \infty} \frac{v_k}{\lambda_1^k} = \alpha_1 x_1, \quad \lim_{k \rightarrow \infty} \frac{(v_{k+1})_i}{(v_k)_i} = \lambda_1.$$

可见，当  $k$  充分大时， $v_k$  近似于主特征值， $v_{k+1}$  与  $v_k$  的对应非零分量的比值近似于主特征值。





在实际计算中,需要对计算结果进行规范化。因为当 $|\lambda_1| < 1$ 时,  $v_k$  趋于零, 当 $|\lambda_1| > 1$ 时,  $v_k$  的非零分量趋于无穷。从而计算时会出现下溢 或上溢。

为此,对 $Z = (z_1, z_2, \dots, z_n)^T \in R^n$ , 记  $\max(Z) = z_i$ , 其中 $|z_i| = \|Z\|_\infty$ . 这样,我们有

如下幂法的实用的计算公式:

$$\begin{cases} v_0 = u_0 \neq 0, \\ v_k = Au_{k-1}, \\ u_k = v_k / \max(v_k), k = 1, 2, \dots \end{cases} \quad (7.2.3)$$

定理 7.4 设  $A \in R^{n \times n}$  的特征值  $\lambda_i (i = 1, 2, \dots, n)$  满足 (7.2.1) 并且有对应的  $n$  个线性无关的特征向量  $x_i (i = 1, 2, \dots, n)$ 。给定初值向量  $v_0 = \sum_{i=1}^n \alpha_i x_i$ ,  $\alpha_i \neq 0$ , 则由 (7.2.3) 生成的向量序列有

$$\lim_{k \rightarrow \infty} u_k = \frac{x_1}{\max(x_1)}, \lim_{k \rightarrow \infty} \max(v_k) = \lambda_1.$$





证 :由 (7.2.3) 有

由(7.2.2)有 
$$v_k = \frac{A^k v_0}{\max(A^{k-1} v_0)}, u_k = \frac{A^k v_0}{\max(A^k v_0)}$$

$$A^k v_0 = \lambda_1^k \left[ \alpha_1 x_1 + \sum_{i=2}^n \alpha_i \left( \frac{\lambda_i}{\lambda_1} \right)^k x_i \right] = \lambda_1^k (\alpha_1 x_1 + \varepsilon_k),$$

$$u_k = \frac{A^k v_0}{\max(A^k v_0)} = \frac{\lambda_1^k (\alpha_1 x_1 + \varepsilon_k)}{\max[\lambda_1^k (\alpha_1 x_1 + \varepsilon_k)]}$$

$$= \frac{\alpha_1 x_1 + \varepsilon_k}{\max(\alpha_1 x_1 + \varepsilon_k)} \rightarrow \frac{x_1}{\max(x_1)} (k \rightarrow \infty).$$

同理,可得到

$$v_k = \frac{\lambda_1^k (\alpha_1 x_1 + \varepsilon_k)}{\max[\lambda_1^{k-1} (\alpha_1 x_1 + \varepsilon_{k-1})]} = \frac{\lambda_1 (\alpha_1 x_1 + \varepsilon_k)}{\max(\alpha_1 x_1 + \varepsilon_{k-1})},$$

$$\max(v_k) = \lambda_1 \frac{\max(\alpha_1 x_1 + \varepsilon_k)}{\max(\alpha_1 x_1 + \varepsilon_{k-1})} \rightarrow \lambda_1 (k \rightarrow \infty).$$

定理得证。





由定理的证明可见，幂法的收敛速度由  $|\lambda_2 / \lambda_1|$  的大小确定。若  $A$  的特征值不满足 (7.2.1)，将有不同的情况。如果  $\lambda_1 = \lambda_2 = \dots = \lambda_r$ ，且  $|\lambda_r| > |\lambda_{r+1}|$ ，可以作类似的分析，对初始向量(7.2.2)和计算公式(7.2.3)有

$$\lim_{k \rightarrow \infty} u_k = \frac{\sum_{i=1}^r \alpha_i x_i}{\max(\sum_{i=1}^r \alpha_i x_i)}, \lim_{k \rightarrow \infty} \max(v_k) = \lambda_1。$$

可见， $u_k$  仍收敛于一个主特征向量。对特征值的其他情况，讨论较为复杂。

完整的幂法程序要加上各种情况的判断。

### 例7.1 用幂法求矩阵

$$A = \begin{pmatrix} 1 & 1 & 0.5 \\ 1 & 1 & 0.25 \\ 0.5 & 0.25 & 2 \end{pmatrix}$$

的主特征值和主特征向量。





解：取初始向量  $u_0 = (1,1,1)^T$ ，按(7.2.3)的计算结果如表 7-1。

表7-1

K	$u_k^T$	$\max(v_k)$
0	(1.0000,1.0000,1)	
1	(0.9091,0.8182,1)	2.7500000
5	(0.7651,0.6674,1)	2.5887918
10	(0.7494,0.6508,1)	2.5380029
15	(0.7483,0.6497,1)	2.5366256
20	(0.7482,0.6497,1)	2.5365323

矩阵A的主特征值和特征向量 的准确值(8位数字)分别为  $\lambda_1 = 2.5365258$ ， $x_1^* = (0.74822116, 0.64966116, 1)^T$ 。可见迭代 20次后，所得的主特征值 有5位有效数字。





从定理 7.4 的证明中易见, 当  $k$  充分大时, 有  $|\max(v_k) - \lambda_1| \approx c |\lambda_2 / \lambda_1|^k$ 。因此, 幂法是线性收敛的方法。当  $|\lambda_2|$  接近于  $|\lambda_1|$  时, 收敛很慢。这时, 一个补救的办法是采用加速收敛的方法。下面简要的介绍两种加速方法。

### 1. Aitken 外推法

记  $m_k = \max(v_k)$ 。对幂法的计算结果进行外推加速:

$$\tilde{m}_k = m_m - \frac{(m_k - m_{k-1})^2}{m_k - 2m_{k-1} + m_{k-2}}, \quad k \geq 3,$$

$$\tilde{(u_k)}_j = (u_k)_j - \frac{((u_k)_j - (u_{k-1})_j)^2}{(u_k)_j - 2(u_{k-1})_j + (u_{k-2})_j}, (u_k)_j \neq 1。$$

### 2. Rayleigh 商加速

若  $A \in R^{n \times n}$  为对称矩阵, 则幂法所得的规范化向量  $u_k$  的 Rayleigh 商给出特征值  $\lambda_1$  较好的近似值,

$$\frac{(Au_k, u_k)}{(u_k, u_k)} = \lambda_1 + O\left(\left(\frac{\lambda_2}{\lambda_1}\right)^{2k}\right)。$$







## 7.2.2 反幂法和原点位移

反幂法用来计算矩阵按模最小的特征值及其特征向量。设  $A \in R^{n \times n}$  为非奇异矩阵，它的特征值满足

$$|\lambda_1| \geq |\lambda_2| \geq \dots \geq |\lambda_{n-1}| > |\lambda_n| > 0, \quad (7.2.4)$$

则  $A^{-1}$  的特征值  $\lambda_1^{-1}, \lambda_2^{-1}, \dots, \lambda_n^{-1}$  满足

$$|\lambda_n^{-1}| > |\lambda_{n-1}^{-1}| \geq \dots \geq |\lambda_1^{-1}|,$$

即  $\lambda_n^{-1}$  是  $A^{-1}$  的主特征值。因此，对  $A^{-1}$  应用幂法可得矩阵  $A$  的按模最小的特征值及其特征向量，称为反幂法，计算公式为

$$\begin{cases} v_0 = u_0 \neq 0, \\ v_k = A^{-1}u_{k-1}, \\ u_k = v_k / \max(v_k), k = 1, 2, \dots \end{cases} \quad (7.2.5)$$

在(7.2.5)中，向量  $v_k$  可以通过解方程组  $Av_k = u_{k-1}$  得到。





定理7.5: 设非奇异矩阵 $A \in R^{n \times n}$ 的特征值 $\lambda_i (i = 1, 2, \dots, n)$ 满足(7.2.4), 并且有对应的 $n$ 个线性无关的特征向量 $x_i (i = 1, 2, \dots, n)$ 。给定初始向量

$v_0 = \sum_{i=1}^n \alpha_i x_i, \alpha_n \neq 0$ , 则由(7.2.5)生成的向量序列有

$$\lim_{k \rightarrow \infty} u_k = \frac{x_n}{\max(x_n)}, \lim_{k \rightarrow \infty} \max(v_k) = \frac{1}{\lambda_n}。$$

反幂法的一个重要应用是利用“原点位移”，求指定点附近的某个特征值和对应的特征向量。

如果矩阵 $(A - pI)^{-1}$ 存在，显然其特征值为 $(\lambda_i - p)^{-1}, i = 1, 2, \dots, n$ , 对应的特征向量仍然是 $x_i (i = 1, 2, \dots, n)$ 。如果 $p$ 是 $A$ 的特征值 $\lambda_j$ 的一个近似值，且

$$|\lambda_j - p| < |\lambda_i - p|, i \neq j, \quad (7.2.6)$$

即 $(\lambda_j - p)^{-1}$ 是 $(A - pI)^{-1}$ 的主特征值，可用反幂法计算相应的特征值和特征向量，计算公式为





$$\begin{cases} u_0 = v_0 \neq 0, \\ v_k = (A - pI)^{-1} u_{k-1}, \\ u_k = v_k / \max(v_k), k = 1, 2, \dots \end{cases} \quad (7.2.7)$$

定理7.6 设  $A \in R^{n \times n}$  的特征值  $\lambda_i (i = 1, 2, \dots, n)$  对应的特征向量  $x_i (i = 1, 2, \dots, n)$  线性无关,  $p$  为  $\lambda_j$  的近似值, 满足(7.2.6),  $(A - pI)^{-1}$  存在。

给定初始向量  $v_0 = \sum_{i=1}^n \alpha_i x_i, \alpha_j \neq 0$ , 则由(7.2.7)生成的向量序列有

$$\lim_{k \rightarrow \infty} u_k = \frac{x_j}{\max(x_j)}, \lim_{k \rightarrow \infty} \max(v_k) = \frac{1}{\lambda_j - p}。$$

由该定理可知,  $p + [\max(v_k)]^{-1}$  是特征值  $\lambda_j$  的近似值, 对应的近似特征向量为  $u_k$ 。迭代收敛速度由比值  $\sigma = \max_{i \neq j} |(\lambda_j - p) / (\lambda_i - p)|$  来确定。

反幂法迭代公式 (7.2.7) 中的  $v_k$  是通过解方程组

$$(A - pI)v_k = u_{k-1}$$





求得的，为了节省计算工作量，可以先将  $(A - pI)$  进行三角分解

其中  $P$  为排列阵。
$$P(A - pI) = LU,$$

只要选择的  $P$  是  $\lambda_i$  的一个较好的近似且特征值分离情况较好，一般  $\sigma$  很小，收敛将是较快的。实验表明，按下述方法选择  $v_0 = u_0$  是较好的：选

$u_0$  使

$$Uv_1 = L^{-1}Pu_0 = (1, 1, \dots, 1)^T,$$

用回代求解可得  $v_1$ 。

**例7.2** 用反幂法求下列矩阵的接近于  $P=1.2679$  的特征值(精确特征值

$\lambda_3 = 3 - \sqrt{3}$ )及其特征向量(用5位浮点数进行计算),

$$A = \begin{pmatrix} 2 & 1 & 0 \\ 1 & 3 & 1 \\ 0 & 1 & 4 \end{pmatrix}.$$





解：用列选主元元的三角分解将  $A - pI$  分解为

$$P(A - pI) = LU,$$

其中

$$P = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix}, L = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0.7321 & -0.26807 & 1 \end{pmatrix},$$

$$U = \begin{pmatrix} 1 & 1.7321 & 1 \\ 0 & 1 & 2.7321 \\ 0 & 0 & 0.29405 \times 10^{-3} \end{pmatrix}.$$

由  $Uv_1 = (1,1,1)^T$  得

$$v_1 = (12692, -9290.3, 3400.8)^T,$$

$$u_1 = (1, -0.73198, 0.26795)^T.$$

由  $LUv_2 = Pu_1$  得

$$v_2 = (20404, -14937, 5467.4)^T,$$

$$u_2 = (1, -0.73206, 0.26796)^T.$$





由此可得特征值  $\lambda_3 (= 1.2679492)$  的近似值

$$1.2679 + \frac{1}{20404} = 1.267949$$

$\lambda_3$  对应的特征向量是

$$x_3 = (1, 1 - \sqrt{3}, 2 - \sqrt{3})^T \approx (1, -0.73205, 0.26795)^T。$$

由此可见,  $u_2$  是  $x_3$  的相当好的近似。

