

求解非线性矩阵特征值问题的一个 三阶收敛的算法*

陈 广 义 薛 彦 才

(中国科学院沈阳计算所)

A CUBICALLY CONVERGENT ALGORITHM FOR SOLVING NONLINEAR EIGENVALUE PROBLEMS

Chen Guang-yi Xue Yan-cai

(Shenyang Institute of Computing Technology, Academia Sinica)

Abstract

In this paper we give a cubically convergent algorithm for solving the nonlinear eigenvalue problem $A(\lambda)X = 0, X \neq 0$, where $A(\lambda)$ is a functional λ -matrix. The amount of computation is much less than that of Lancaster's cubically convergent algorithm. Several numerical examples are also presented.

§1. 引 言

考虑矩阵 $A(\lambda) \in \mathbb{C}^{n \times n}$, 它的元素 $a_{ij}(\lambda)$ 是复变量 λ 的解析函数, 我们称这样的矩阵为泛函 λ -矩阵^[3]. 如果 $a_{ij}(\lambda)$ 是 λ 的多项式, 则称它为 λ -矩阵^[1].

我们把满足

$$\begin{cases} A(\lambda)x = 0 \\ y^H A(\lambda) = 0 \end{cases} \quad (1.1)$$

的值 λ 和向量 y, x 分别称为泛函 λ -矩阵 $A(\lambda)$ 的特征值和与之对应的特征向量. 满足 (1.1) 的特征值 λ 当然也满足

$$\det A(\lambda) = 0. \quad (1.2)$$

求解 (1.1) 或 (1.2) 称为求解非线性矩阵特征值问题. 关于这类问题的求解已有很多有效的二阶收敛的算法(见[1]—[7]). Lancaster^[1] 对一般的 λ -矩阵曾经给出一个三阶收敛的算法. 该方法每步迭代, 需求出常数矩阵 $A(\lambda_k)$ 的全部特征向量. 利用常用的QR算法求常数矩阵 $A(\lambda_k)$ 的全部特征向量约需 $15n^3$ 个运算量(见[9], pp. 235), 即使 $A(\lambda_k)$

* 1992年3月25日收到.

为对称矩阵也需 $5n^3$ 个运算量(见[9], pp. 282), 显然运算量太大. 另外, Lancaster 是对 $A(\lambda)$ 的特征值 $\mu_n(\lambda)$ 求零点给出的, 但当 λ^* 为重特征值时, $\mu_n(\lambda)$ 是不一定可微的^[9]. 因此, 从理论上讲, 用 Lancaster 方法求重特征值是不适宜的. 本文利用列选主元 QR 分解, 对解析函数 $\phi(\lambda) = \frac{r_{nn}(\lambda)}{\bar{q}_{nn}(\lambda)}$ 求零点给出了一个三阶收敛的算法. 本算法每步迭代的运算量为 $\frac{2}{3}n^3 + 7n^2$, 远远小于 Lancaster 方法的运算量. 本算法对重特征值亦收敛, 特别地, 对具有线性初等因子的重特征值三阶收敛.

§ 2. 算法的导出

对某点 λ , 我们可将矩阵 $A(\lambda)$ 进行列选主元 QR 分解(见[9], pp. 162—165)

$$A(\lambda)P(\lambda) = Q(\lambda)R(\lambda),$$

其中 $P(\lambda)$ 是在进行列选主元中由列互换确定的置换阵, $Q(\lambda)$ 和 $R(\lambda)$ 分别是 $n \times n$ 阶酉矩阵和上三角阵.

$$R(\lambda) = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ & r_{22} & \cdots & r_{2n} \\ & & \ddots & \vdots \\ & & & r_{nn} \end{bmatrix},$$

由列选主元可知, $R(\lambda)$ 的元素满足

$$\begin{cases} |r_{11}| \geq |r_{22}| \geq \cdots \geq |r_{nn}|, \\ |r_{ij}| \geq |r_{ji}| \quad (1 \leq i \leq j \leq n). \end{cases} \quad (2.1)$$

Kublanovskaya^[2] 1970 年对 $r_{nn}(\lambda)$ 求零点给出一个算法, 但该方法的推导有错误. Jain 和 Singhal^[3] 1983 年给出一个改进的方法, 它们不是对 $r_{nn}(\lambda)$ 求零点, 而是对解析函数 $\phi(\lambda) = \frac{r_{nn}(\lambda)}{\bar{q}_{nn}(\lambda)}$ 求零点, 从而给出一个二阶收敛的算法. 本文的目的是在 Jain 和 Singhal 工作的基础上给出一个三阶收敛的算法, 作为对 Lancaster 给出方法的改进.

为了保证 $q_{nn} \neq 0$, 我们采取如下方法:

记 $q_n = Qe_n = (q_{1n}, q_{2n}, \cdots, q_{nn})^T$, 如果 $|q_{nn}| > \varepsilon$ (事先给定的一个正常数) 无需处理; 反之, 可取初等置换矩阵 T (由单位矩阵交换两列而得到的矩阵), 使 Tq_n 的按模最大元素位于矩阵 TQ 的 (n, n) 位置. 设

$$|q_{pn}| = \max\{|q_{1n}|, |q_{2n}|, \cdots, |q_{nn}|\},$$

则 T 由单位矩阵交换第 p 列和第 n 列得到, 显然 $T^H = T^{-1} = T$. 记

$$\tilde{Q} = TQ,$$

$$\tilde{q}_n = Tq_n = (\tilde{q}_{1n}, \tilde{q}_{2n}, \cdots, \tilde{q}_{nn})^T,$$

于是

$$|\tilde{q}_{nn}| \geq \frac{\sqrt{\sum_{i=1}^n |\tilde{q}_{in}|^2}}{\sqrt{n}} = \frac{1}{\sqrt{n}} (> \varepsilon).$$

引入初等置换矩阵 T 后, 矩阵分解式变为

$$T \cdot A(\lambda)P(\lambda) = \tilde{Q}(\lambda)R(\lambda), \quad (2.2)$$

记 $B = TAP$. Jain 和 Singhal^[3] 直接对分解式 $A(\lambda)P(\lambda) = Q(\lambda)R(\lambda)$ 求导并给出了 ψ' 的公式. 本文从另外一个角度出发给出了 ψ' 和 ψ'' 的公式. 对解析函数 $\psi(\lambda)$ 的一、二阶导数为

$$\begin{cases} \psi'(\lambda) = -e_n^T(B^{-1})'e_n / (e_n^T B^{-1} e_n)^2, \\ \psi''(\lambda) = -e_n^T(B^{-1})''e_n / (e_n^T B^{-1} e_n)^2 + 2[e_n^T(B^{-1})'e_n]^2 / (e_n^T B^{-1} e_n)^3. \end{cases} \quad (2.3)$$

由于

$$\begin{aligned} (B^{-1})' &= -B^{-1}B'B^{-1}, \\ (B^{-1})'' &= 2B^{-1}B'B^{-1}B'B^{-1} - B^{-1}B''B^{-1}, \end{aligned}$$

于是

$$\begin{cases} \psi'(\lambda) = e_n^T B^{-1} B' B^{-1} e_n / (e_n^T B^{-1} e_n)^2, \\ \psi''(\lambda) = e_n^T (B^{-1} B'' B^{-1} - 2B^{-1} B' B^{-1} B' B^{-1}) e_n / (e_n^T B^{-1} e_n)^2 \\ \quad + 2(e_n^T B^{-1} B' B^{-1} e_n)^2 / (e_n^T B^{-1} e_n)^3. \end{cases}$$

当 λ 充分接近 λ^* 时, 矩阵 T 和 P 可视为常数^[2], 对矩阵 $B = TAP$ 分别求一、二阶导数得

$$B' = TA'P, \quad B'' = TA''P.$$

代入 ψ' 、 ψ'' 的表达式得

$$\begin{cases} \psi(\lambda) = r_{nn} / \bar{q}_{nn}, \\ \psi'(\lambda) = \frac{r_{nn}}{\bar{q}_{nn}^2} e_n^T \tilde{Q}^H T A' P R^{-1} \tilde{Q}^H e_n, \\ \psi''(\lambda) = \frac{2(\psi')^2}{\psi} + \frac{r_{nn}}{\bar{q}_{nn}^2} [e_n^T \tilde{Q}^H T A'' P R^{-1} \tilde{Q}^H e_n \\ \quad - 2e_n^T \tilde{Q}^H T A' P R^{-1} \tilde{Q}^H T A' P R^{-1} \tilde{Q}^H e_n]. \end{cases} \quad (2.4)$$

设向量 u, v 并定义为

$$\begin{cases} Ru = \frac{r_{nn}}{\bar{q}_{nn}} \tilde{Q}^H e_n, \end{cases} \quad (2.5)$$

$$\begin{cases} \tilde{Q}^H T v = \frac{1}{\bar{q}_{nn}} e_n. \end{cases} \quad (2.6)$$

引入向量 u, v 之后, 式(2.4)可写为

$$\begin{cases} \psi(\lambda) = r_{nn} / \bar{q}_{nn}, \\ \psi'(\lambda) = v^H A' P u, \\ \psi''(\lambda) = \frac{2(\psi')^2}{\psi} + v^H A'' P u - 2v^H A' P R^{-1} \tilde{Q}^H T A' P u. \end{cases} \quad (2.7)$$

记

$$R = \begin{bmatrix} R_1 & & r \\ & \ddots & \\ 0 & & r_{nn} \end{bmatrix}_{n-1}^{n-1}, \quad \tilde{Q}^H e_n = \begin{pmatrix} \bar{q}_{n1} \\ \vdots \\ \bar{q}_{nn} \end{pmatrix} = \begin{pmatrix} q \\ \vdots \\ \bar{q}_{r_n} \end{pmatrix}_1^{n-1},$$

于是

$$\begin{aligned}
R^{-1} &= \begin{bmatrix} R_1^{-1} & -R_1^{-1}r/r_{nn} \\ 0 & 1/r_{nn} \end{bmatrix} = \begin{bmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{bmatrix} + \begin{pmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{pmatrix} e_n^H, \\
2v^H A' P R^{-1} \tilde{Q}^H T A' P u & \\
&= 2v^H A' P \left[\begin{pmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{pmatrix} + \begin{pmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{pmatrix} e_n^H \right] \tilde{Q}^H T A' P u \\
&= 2v^H A' P \begin{pmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{pmatrix} \tilde{Q}^H T A' P u + 2v^H A' P \begin{bmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{bmatrix} e_n^H \tilde{Q}^H T A' P u \\
&= 2v^H A' P \begin{pmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{pmatrix} \tilde{Q}^H T A' P u + 2\bar{q}_{nn} \cdot v^H A' P \begin{bmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{bmatrix} \cdot v^H A' P u \\
&= 2v^H A' P \begin{pmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{pmatrix} \tilde{Q}^H T A' P u + 2\phi' \bar{q}_{nn} \cdot v^H A' P \begin{bmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{bmatrix}. \quad (2.8)
\end{aligned}$$

又因为

$$\begin{aligned}
u &= \frac{r_{nn}}{\bar{q}_{nn}} R^{-1} \tilde{Q}^H e_n = r_{nn} \begin{bmatrix} R_1^{-1} & -R_1^{-1}r/r_{nn} \\ 0 & 1/r_{nn} \end{bmatrix} \begin{bmatrix} q/\bar{q}_{nn} \\ 1 \end{bmatrix} \\
&= r_{nn} \left[\begin{pmatrix} R_1^{-1}q/\bar{q}_{nn} \\ 0 \end{pmatrix} + \begin{pmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{pmatrix} \right],
\end{aligned}$$

代入(2.8)式的后半部分

$$\begin{aligned}
2\phi' \bar{q}_{nn} \cdot v^H A' P \begin{pmatrix} -R_1^{-1}r/r_{nn} \\ 1/r_{nn} \end{pmatrix} &= 2\phi' \bar{q}_{nn} \cdot v^H A' P \left[\frac{u}{r_{nn}} - \begin{pmatrix} R_1^{-1}q/\bar{q}_{nn} \\ 0 \end{pmatrix} \right] \\
&= \frac{2(\phi')^2}{\phi} - 2\phi' \cdot v^H A' P \begin{pmatrix} R_1^{-1}q \\ 0 \end{pmatrix}.
\end{aligned}$$

因此

$$\phi'' = v^H A'' P u + 2v^H A' P \begin{pmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{pmatrix} \left[\phi' \begin{pmatrix} q \\ 0 \end{pmatrix} - \tilde{Q}^H T A' P u \right],$$

于是,(2.7)式可写为

$$\begin{cases} \phi(\lambda) = r_{nn}/\bar{q}_{nn}, \\ \phi'(\lambda) = v^H A' P u, \\ \phi''(\lambda) = v^H A'' P u + 2v^H A' P \begin{pmatrix} R_1^{-1} & 0 \\ 0 & 0 \end{pmatrix} \left[\phi' \begin{pmatrix} q \\ 0 \end{pmatrix} - \tilde{Q}^H T A' P u \right]. \end{cases} \quad (2.9)$$

由(2.9)式便可构造三阶收敛的算法。实际上,我们还可以构造更高阶的算法。

定理 2.1. 将矩阵 $A(\lambda)$ 按(2.2)式进行分解,则 $\det A(\lambda)$ 的零点与 $\phi(\lambda) = r_{nn}(\lambda)/\bar{q}_{nn}(\lambda)$ 的零点相同,这里 $\bar{q}_{nn}(\lambda)$ 是酉阵 \tilde{Q} 的 (n,n) 元素的共轭。

定理 2.2. 设向量 u, v 是由(2.5)、(2.6)定义的两个向量。当 λ^* 为 $A(\lambda)$ 的特征值时, v 和 Pu 分别是对应 λ^* 的左、右特征向量。

算法. 本算法适用于求解一般非线性矩阵特征值问题,具体步骤如下:

1. 给定初始值 λ_0 和正常数 $\epsilon (< 1)$ 。
2. 形成矩阵 $A(\lambda_k), k = 0, 1, 2, \dots$ 。
3. 对矩阵 $A(\lambda_k)$ 进行列选主元 QR 分解

$$A(\lambda_k)P_k = Q_k R_k.$$

4. 如果 $|q_{nn}| > \varepsilon$ 、取 $T = I$ ；否则，按上面给出的方法选取矩阵 T 。
5. 按(2.5)给出向量 u 。
6. 求向量 $v = \frac{1}{\tilde{q}_{nn}} Q e_n$ 。
7. 按(2.9)计算 $\phi_k, \phi'_k, \phi''_k$ 。
8. 实行 Halley 迭代

$$\lambda_{k+1} = \lambda_k - \phi_k / \left(\phi'_k - \frac{\phi_k \phi''_k}{2\phi'_k} \right).$$

9. 重复步骤 2—8，直到满足精度要求为止。

本算法能同时给出特征值 λ^* 和与之对应的特征向量。当 $A(\lambda)$ 为实阵时，若取 λ_0 为实数，则由迭代产生的序列 $\{\lambda_k\}$ 均为实数，不可能收敛到复根。因此，我们推荐取初值 λ_0 为复数。

§ 3. 运算量和收敛性分析

在计算每步迭代的运算量时，由于形成 $A(\lambda_k)$ 、 $A'(\lambda_k)$ 和 $A''(\lambda_k)$ 的运算量依赖于 $A(\lambda)$ 本身。因此，我们不考虑形成 $A(\lambda_k)$ 、 $A'(\lambda_k)$ 、 $A''(\lambda_k)$ 的运算量。列选主元 QR 分解约需 $\frac{2}{3}n^3$ 个运算量，计算向量 u, v 共需 $\frac{5}{2}n^2$ 个运算量，计算 ϕ'_k 需 n^2 个运算量，计算 ϕ''_k 需 $\frac{7}{2}n^2$ 个运算量。因此，本文给出的算法每步迭代需 $\frac{2}{3}n^3 + 7n^2$ 个运算量。

Jain 和 Singhal 改进的 Kublanovskaya 算法，每步迭代需 $\frac{2}{3}n^3 + \frac{7}{2}n^2$ 个运算量。因此，本算法比 Jain 和 Singhal 的二阶收敛的方法每步迭代仅多 $\frac{7}{2}n^2$ 个运算量，但收敛阶提高一阶。

Lancaster^[1] 曾给出一个三阶收敛的算法，该算法每步迭代的运算量为 $15n^3$ 。显然，本文给出的算法的运算量少于 Lancaster 方法。

为了说明本算法对重特征值的收敛性，我们定义：

设 λ^* 是泛函 λ -矩阵 $A(\lambda)$ 的 $\alpha (\geq 2)$ 重特征值，即

$$\det A(\lambda) = O(|\lambda - \lambda^*|^\alpha).$$

如果 $\text{rank} A(\lambda^*) = n - \alpha$ ，则称 λ^* 是具有线性初等因子的重特征值。

定理 3.1. 设 λ^* 是具有线性初等因子的重特征值，则 $\phi'(\lambda^*) \neq 0$ 。

证明。不妨假设 λ^* 为 $\alpha (\geq 2)$ 重特征值，我们用反证法证明本命题：

若 $\phi'(\lambda^*) = 0$ ，由于 $\phi(\lambda)$ 在 λ^* 点的某个小邻域内是解析的^[3]，因此，可对 $\phi(\lambda)$ 在 λ^* 点泰勒展开

$$\phi(\lambda) = \phi(\lambda^*) + \phi'(\lambda^*)(\lambda - \lambda^*) + O(|\lambda - \lambda^*|^2)$$

$$= O(|\lambda - \lambda^*|^2).$$

但 $\phi(\lambda) = r_{nn}/\bar{q}_{nn}, |\bar{q}_{nn}| \geq \varepsilon$, 于是

$$r_{nn}(\lambda) = O(|\lambda - \lambda^*|^2).$$

由于 $A(\lambda)$ 是泛函 λ -矩阵且 $\text{rank} A(\lambda^*) = n - \alpha$, 故可假设

$$r_{ii}(\lambda) = O(|\lambda - \lambda^*|), n - \alpha + 1 \leq i \leq n - 1.$$

于是

$$\det A(\lambda) = \prod_{i=1}^n r_{ii}(\lambda) = O(|\lambda - \lambda^*|^{\alpha+1})$$

这与 $\det A(\lambda) = O(|\lambda - \lambda^*|^\alpha)$ 产生矛盾. 命题得证.

推论. 设 λ^* 是泛函 λ -矩阵 $A(\lambda)$ 的单重特征值, 则 $\phi'(\lambda^*) \neq 0$.

定理 3.2. 设 λ^* 是解析函数 $\phi(\lambda)$ 的零点, λ_0 为给定的初值, $\{\lambda_k\}$ 为由 Halley 迭代

$$\lambda_{k+1} = \lambda_k - \phi_k / \left(\phi'_k - \frac{\phi_k \phi''_k}{2\phi'_k} \right)$$

产生的收敛于 λ^* 的序列, 则

1) 如果 $\phi'(\lambda^*) = 0$, 则 $\{\lambda_k\}$ 三阶收敛.

2) 如果 $\phi'(\lambda^*) \neq 0$, 则 $\{\lambda_k\}$ 二阶收敛.

证明. 记 $e_k = \lambda_k - \lambda^*$

$$1) e_{k+1} = e_k - \phi_k / \left(\phi'_k - \frac{\phi_k \phi''_k}{2\phi'_k} \right),$$

$$\begin{aligned} \frac{\phi_k \phi'_k}{(\phi'_k)^2 - \frac{\phi_k \phi''_k}{2}} &= \left\{ \left[\phi'(\lambda^*) e_k + \frac{\phi''(\lambda^*)}{2} e_k^2 + O(e_k^3) \right] \right. \\ &\quad \cdot \left. \left[\phi'(\lambda^*) + \phi''(\lambda^*) e_k + \phi'''(\lambda^*) \frac{e_k^2}{2} + O(e_k^3) \right] \right\} / \\ &\quad \left\{ \left[\phi'(\lambda^*) + \phi''(\lambda^*) e_k + \frac{\phi'''(\lambda^*)}{2} e_k^2 + O(e_k^3) \right]^2 \right. \\ &\quad \left. - \frac{1}{2} \left[\phi'(\lambda^*) e_k + \frac{\phi''(\lambda^*)}{2} e_k^2 + O(e_k^3) \right] \right. \\ &\quad \left. \cdot \left[\phi''(\lambda^*) + \phi'''(\lambda^*) e_k + \frac{\phi^{(4)}(\lambda^*)}{2} e_k^2 + O(e_k^3) \right] \right\} \\ &= \left\{ (\phi'(\lambda^*))^2 e_k + \frac{3}{2} \phi'(\lambda^*) \phi''(\lambda^*) e_k^2 + O(e_k^3) \right\} / \\ &\quad \left\{ (\phi'(\lambda^*))^2 + \frac{3}{2} \phi'(\lambda^*) \phi''(\lambda^*) e_k \right. \\ &\quad \left. + \frac{e_k^2}{2} [(\phi''(\lambda^*))^2 + \phi'(\lambda^*) \phi'''(\lambda^*)] + O(e_k^3) \right\}, \end{aligned}$$

于是

$$\begin{aligned}
e_{k+1} &= e_k - \frac{\phi_k \phi'_k}{(\phi'_k)^2 - \phi_k \phi''_k / 2} \\
&= \left\{ [\phi'(\lambda^*)]^2 e_k + \frac{3}{2} \phi'(\lambda^*) \phi''(\lambda^*) e_k^2 - [\phi'(\lambda^*)]^2 e_k \right. \\
&\quad \left. - \frac{3}{2} \phi'(\lambda^*) \phi''(\lambda^*) e_k^2 + O(e_k^3) \right\} / \left\{ [\phi'(\lambda^*)]^2 + \frac{3}{2} \phi'(\lambda^*) \phi''(\lambda^*) e_k \right. \\
&\quad \left. + \frac{e_k^2}{2} \{ [\phi''(\lambda^*)]^2 + \phi'(\lambda^*) \phi'''(\lambda^*) \} + O(e_k^3) \right\} \\
&= \frac{O(e_k^3)}{(\phi'(\lambda^*))^2 + O(e_k)}
\end{aligned}$$

即 $e_{k+1} = O(e_k^3) \cdot \frac{1}{(\phi'(\lambda^*))^2 + O(e_k)}$, 三阶收敛.

2) 设 $\phi'(\lambda^*) = \dots = \phi^{(t)}(\lambda^*) = 0$, $\phi^{(t+1)}(\lambda^*) \neq 0$, t 是大于或等于 1 的正整数. 将 $\phi(\lambda_k)$ 、 $\phi'(\lambda_k)$ 和 $\phi''(\lambda_k)$ 分别在 λ^* 点泰勒展开

$$\phi(\lambda_k) = \frac{\phi^{(t+1)}(\lambda^*)}{(t+1)!} e_k^{t+1} + O(e_k^{t+2}),$$

$$\phi'(\lambda_k) = \frac{\phi^{(t+1)}(\lambda^*)}{t!} e_k^t + O(e_k^{t+1}),$$

$$\phi''(\lambda_k) = \frac{\phi^{(t+1)}(\lambda^*)}{(t-1)!} e_k^{t-1} + O(e_k^t).$$

于是

$$\begin{aligned}
e_{k+1} &= e_k - \frac{2\phi_k \phi'_k}{2(\phi'_k)^2 - \phi_k \phi''_k} \\
&= e_k - \left\{ 2 \left[\frac{\phi^{(t+1)}(\lambda^*)}{(t+1)!} e_k^{t+1} + O(e_k^{t+2}) \right] \left[\frac{\phi^{(t+1)}(\lambda^*)}{t!} e_k^t + O(e_k^{t+1}) \right] \right\} / \\
&\quad \left\{ 2 \left[\frac{\phi^{(t+1)}(\lambda^*)}{t!} e_k^t + O(e_k^{t+1}) \right]^2 - \left[\frac{\phi^{(t+1)}(\lambda^*)}{(t+1)!} e_k^{t+1} + O(e_k^{t+2}) \right] \right. \\
&\quad \left. \cdot \left[\frac{\phi^{(t+1)}(\lambda^*)}{(t-1)!} e_k^{t-1} + O(e_k^t) \right] \right\} \\
&= \frac{t}{t+2} e_k + O(e_k^2).
\end{aligned}$$

证毕.

综上所述, 本算法的收敛性归纳为:

本算法对单特征值和具有线性初等因子的重特征值三阶收敛, 对其它情形的特征值线性收敛.

§4. 数值例子

为了验证算法的收敛性, 我们在 VAX-2600 系列计算机上对三个问题进行了数值实

验, 计算使用双精度.

例 1. 考虑如下二次特征值问题([3,6]):

$$A(\lambda) = A\lambda^2 + B\lambda + C,$$

其中

$$A = \begin{bmatrix} 1.76 & 1.28 & 2.89 \\ 1.28 & 0.824 & 0.413 \\ 2.89 & 0.413 & 0.725 \end{bmatrix}, B = \begin{bmatrix} 7.66 & 2.45 & 2.1 \\ 0.23 & 1.04 & 0.223 \\ 0.6 & 0.756 & 0.658 \end{bmatrix},$$

$$C = \begin{bmatrix} 121.0 & 18.9 & 15.9 \\ 0.0 & 2.7 & 0.145 \\ 11.9 & 3.64 & 15.5 \end{bmatrix}.$$

这个问题有三对分离得很好的非线性特征值(只给出 10 位有效数字), 即

$$\lambda_1 = -0.9179981715 + i1.760584204, \lambda_4 = \bar{\lambda}_1,$$

$$\lambda_2 = 0.09472172578 + i2.522876588, \lambda_5 = \bar{\lambda}_2,$$

$$\lambda_3 = -0.8848302463 + i8.441512159, \lambda_6 = \bar{\lambda}_3.$$

表 1 给出了用本算法与[3]中给出的方法求解本问题的收敛结果、迭代次数和 e_k (迭代结果与精确特征值的误差)。两种方法迭代的终止条件相同。可以看出, 本算法的迭代次数少于[3]的迭代次数。

表 1

初 始 值	JAIN 和 SINGHAL 的方法		本文的算法		e_k
	迭代次数	收敛结果	迭代次数	收敛结果	
-0.9+1.7i	4	λ_1	2	λ_1	0.65E-13
-1.0+1.5i	5	λ_1	3	λ_1	0.25E-16
2.0i	8	λ_2	5	λ_2	0.38E-16
0.1+2.5i	4	λ_2	2	λ_2	0.24E-14
2.4i	5	λ_2	3	λ_2	0.22E-16
2.5i	5	λ_2	3	λ_2	0.26E-16
3.0i	8	λ_2	4	λ_2	0.24E-16
4.0i	6	λ_3	4	λ_1	0.71E-10
5.0i	5	λ_3	3	λ_3	0.85E-16
10.0i	5	λ_3	3	λ_3	0.53E-16

注 1. 表 1 第二列中的迭代次数有几个比[3]中的迭代次数多一, 这是由于迭代终止时要求的精度较高造成的。

注 2. 对于不同的算法, 相同的初值可能收敛到不同的特征值。

例 2. 考虑二次对称特征值问题^[7]

$$A(\lambda) = \begin{bmatrix} -\lambda^2 - 3\lambda + 1 & & & & \\ \lambda^2 - 1 & -2\lambda^2 - 3\lambda + 5 & & & \text{对称} \\ -\lambda^2 - 3\lambda + 1 & \lambda^2 - 1 & -2\lambda^2 - 5\lambda + 2 & & \\ -2\lambda^2 - 6\lambda + 2 & 2\lambda^2 - 2 & -4\lambda & -9\lambda^2 - 19\lambda + 14 & \end{bmatrix},$$

这个矩阵有两个二重特征值 1 和 -2, 还有四个单特征值 $-4 \pm \sqrt{19}$ 和 $-4 \pm \sqrt{18}$. 由于二

表 2

初值 数据 次数	1.2+0.1i		-2.01+0.2i	
	收敛结果	$ \lambda_k - \lambda^* $	收敛结果	$ \lambda_k - \lambda^* $
1	0.99339215593515 - i0.11E-01	0.13E-01	-1.9865024457538 - i0.27E-01	0.30E-01
2	0.99999458939738 + i0.16E-06	0.54E-05	-2.0001052281430 + i0.24E-04	0.11E-03
3	1.00000000000000 + i0.37E-16	0.54E-15	-1.99999999999999 - i0.10E-12	0.17E-12
4			-2.00000000000000 - i0.95E-29	0.95E-29
5				

重特征值 1 和 -2 都是具有线性初等因子的重特征值, 因此, 由算法的收敛性结果可知迭代应具有三阶收敛性. 表 2 中的数据也说明了这一点, $|\lambda_{k+1} - \lambda^*| \approx c \cdot |\lambda_k - \lambda^*|^3$, c 为某正常数.

例 3. 为了考察算法对其它情形的重特征值的收敛性, 我们给出了下面的二次特征值问题([4, 6]):

$$A(\lambda) = A\lambda^2 + B\lambda + C,$$

其中

$$A = I,$$

$$B = \begin{bmatrix} 3\alpha & -(1 + \alpha^2 + 2\beta^2) & \alpha(1 + 2\beta^2) & -\beta^2(\alpha^2 + \beta^2) \\ 2 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 2 & 0 \end{bmatrix},$$

$$C = \begin{bmatrix} -1 + 2\alpha^2 & \alpha(1 - \alpha^2 - 2\beta^2) & 2\alpha^2\beta^2 & -\alpha\beta^2(\alpha^2 + \beta^2) \\ 2\alpha & -(\alpha^2 + 2\beta^2) & 2\alpha\beta^2 & -\beta^2(\alpha^2 + \beta^2) \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix},$$

这里 $\alpha \geq 0$ 是参数, 且 $\beta = 1 + \alpha$. $\det A(\lambda)$ 的零点之间的分离程序随 α 的改变而改变. 特别当 $\alpha = 0$ 时, 它有三重特征值 $\pm i$ 和二重特征值 0.

由于 $\text{rank} A(\pm i) = 2$, $\text{rank} A(0) = 3$, 因此 $\pm i$ 和 0 都不是具有线性初等因子的重特征值. 表 3 给出了 $\alpha = 0$ 时用本算法求解此问题的数值结果.

表 3

初始值	迭代次数	收敛结果
0.1	3	-0.12E-15 - 0.0000000i
-0.01-1.01i	7	-0.46E-05-1.0000047i
2+i	11	-0.36E-05 - 0.9999956i
2+2i	12	0.44E-05 - 1.0000008i

对于初值 $2+i$ 和 $2+2i$, [4]给出的迭代次数分别为 22 和 25 次, 而对于初值 0.1, [6]迭代了 30 次才精确到 0.5×10^{-5} . 可见, 本算法对不具有线性初等因子的重特征值也是有效的.

参 考 文 献

- [1] P. Lancaster, *Lambda matrices and vibrating system*, Pergamon Press, Oxford, 1966.
- [2] V. N. Kublanovskaya, On an approach to the solution of the generalized latent value problem for lambda-matrices, *SIAM J. Numer. Anal.*, 7(1970), 532—537.
- [3] N. K. Jain, K. Singhal, On Kublanovskaya's approach to the solution of the generalized latent value problem for functional lambda-matrices, *SIAM J. Numer. Anal.*, 20(1983) 1062—1070.
- [4] 李仁仓, QR 分解与非线性特征值问题, *计算数学*, 11: 4(1989), 374—385.
- [5] P. Lancaster, A generalized Rayleigh quotient iteration for lambda-matrices, *Arch. Rat. Mech. Anal.*, 8(1961), 309—322.
- [6] A. Ruhe, Algorithms for the nonlinear eigenvalue problem, *SIAM J. Numer. Anal.*, 10(1973), 674—689.
- [7] Neumaier, Residual inverse iteration for the nonlinear eigenvalue problem, *SIAM J. Numer. Anal.*, 22(1985), 914—923.
- [8] Sun Ji-guang, Eigenvalues and eigenvectors of a matrix dependent on several parameters, *Journal of computational mathematics*, 3(1985), 351—364.
- [9] G.H. Golub, C.F. Van Loan, *Matrix Computations*, The Johns Hopkins University Press, 1983.