

# 解病态线性方程组的一类直接方法\*

赵金熙

(南京大学)

## §1 引言

我们讨论的向题是解亚定方程组

$$A^T x = b, \quad (1.1)$$

其中  $A = [a_1, a_2, \dots, a_n] \in R^{m \times n}$ ,  $m \geq n$ ,  $\text{rank}(A) = n$ .

设  $\sigma_1, \sigma_n$  分别是  $A$  的最大、最小奇异值。则当

$$K_2(A) = \sigma_1 / \sigma_n > 1$$

时, 传统的解 (1.1) 的数值方法都会遇到不同程度的困难, 往往使算法严重失效。

近年来讨论较多的一类递推算法 [1]、[2]、[4]、[6] 是解病态线性方程组的有效算法, 如 [4] 讨论了下列算法:

### 算法 I

(1) 用直交化方法确定  $R(A) = \text{span}[a_1, \dots, a_n]$  的一组标准直交基  $p_1, p_2, \dots, p_n$ , 且  $p_i \in \text{span}[a_1, \dots, a_{i-1}]^\perp$ ;

(2) 令  $x_0 = 0$ , 对  $i = 1, 2, \dots, n$  计算

$$x_i = x_{i-1} + \alpha_i p_i, \quad \alpha_i = (b_i - a_i^T x_{i-1}) / p_i^T a_i,$$

其中  $b_i$  为  $b$  的第  $i$  个分量;

(3)  $x_n$  就是 (1.1) 的极小范数解。

这一类算法的基本思想是在第  $k$  步求得  $x_k$ , 使  $x_k$  为 (1.1) 的前  $k$  个方程的解。这类算法的关键在于逐次构造  $A$  的象空间  $R(A)$  的直交基向量, 而这一组直交基向量精度的差异 ( $p_i \in \text{span}[a_1, \dots, a_{i-1}]^\perp$  的破坏) 又受  $A$  的条件数的严重影响。例如, 我们在算法 I 的第 (1) 步用改进 Gram-Schmidt 直交化方法来求得  $p_1, p_2, \dots, p_n$ , 且令

$$Q = [p_1, p_2, \dots, p_n]$$

为精确的 (理论上的) 列直交阵,  $\overline{Q} = [\overline{p}_1, \overline{p}_2, \dots, \overline{p}_n]$  为实际算得的矩阵, 则在一定假设下已经证明<sup>[4]</sup>:

$$\|I - \overline{Q}^T \overline{Q}\| \leq \frac{1.74}{(1-\beta)^{\frac{1}{2}}} n^{\frac{1}{2}} (n+1) \times 2^{-t} \|A\|_E \|R^{-1}\|_2,$$

$$\beta = 3.42 n^{\frac{1}{2}} (n+1 + 2.5m) 2^{-t} \|A\|_E \|R^{-1}\|_2.$$

1986年9月4日收到。

\*国家教委自然科学基金资助项目。

而

$$\|A\|_F \|R^{-1}\|_2 \leq n^{\frac{1}{2}} K_2(A).$$

因此, 确定  $R(A)$  的直交基是这一类递推算法的重要问题.

本文给出了一类解病态线性方程组(1.1)的递推算法, 其基本思想是引进一个可供选择的  $n \times n$  非奇异上三角阵  $W$ , 使得  $AW$  的列向量有较强的线性独立性. 据此确定  $R(AW)$  的一组直交基  $p_1, p_2, \dots, p_n$ , 使得

$$p_i \in R(A_{i-1})^\perp = \text{span}\{a_1, \dots, a_{i-1}\}^\perp \quad (1.2)$$

§2 给出了基本算法; §3 讨论基本算法的性质; §4 方法的实现及矩阵  $W$  的选取; §5  $R(A)$  的直交基对解的影响; §6 数值结果表明本文讨论的算法有很好的数值稳定性.

## §2 基本算法

在本文讨论的一类递推算法中, 所不同的是确定满足  $p_{i+1} \in R(A_i)^\perp$  ( $i=0, 1, 2, \dots, n-1$ ) 的标准直交向量系  $p_1, p_2, \dots, p_n$ . 也就是说, 若  $Q_i Q_i^T$  是  $R(A_i)$  的直交投影算子, 则可以有

$$p_{i+1} = [(I - Q_i Q_i^T) a_{i+1}] / \beta_{i+1}, \quad i=0, 1, 2, \dots, n-1. \quad (2.1)$$

其中

$$\beta_{i+1} = \|(I - Q_i Q_i^T) a_{i+1}\|_2,$$

得到  $R(A)$  的一组互相直交的基底.

这个算法的关键在于确定对所有  $i$  都有  $p_{i+1} \in R(A_i)^\perp$  的  $R(A)$  的直交基底  $\{p_i\}$ . 而这又取决于  $A$  的列向量间的相关性程度, 为此可以采取下列二种途径加以克服:

(1) 当  $A$  的列向量间有较强的线性相关性时, 就确定  $A$  的伪秩, 作为亏秩问题求解;

(2) 引进非奇异条件予优矩阵  $P$ , 使得  $AP$  的条件比  $A$  的条件要好, 然后解

$$APy = b \quad (2.2)$$

得

$$x = Py \quad (2.3)$$

上面两种处理方法对病态问题往往都能收到一定的效果.

这里我们是引进一个可供选择的非奇异上三角阵  $W$ , 使  $AW$  的列向量有较强的线性独立性, 由此构造满足  $p_{i+1}^T a_j = 0$  ( $j=1, 2, \dots, i$ ) 的  $R(A)$  的直交基向量  $p_1, p_2, \dots, p_n$ .

这个算法与条件预优方法有所不同, 它不是建立与(1.1)等价的条件预优方程(2.2), 而是以  $AW$  的列向量来确定  $R(A)$  的一组直交基向量, 而可望这一组基向量能较好地满足(1.2).

设引进的  $n \times n$  阶非奇异上三角矩阵  $W$  为

$$W = [w_1, w_2, \dots, w_n], \quad A = [a_1, \dots, a_n], \quad b = [b_1, \dots, b_n]^T$$

则可以构造下列算法:

**算法 I (基本算法)**

(1) 确定非奇异上三角矩阵  $W = [w_1, \dots, w_n]$ , 令  $x_0 = 0$ ,  $H_0 = I$ ;

(2) 对  $i = 1, 2, \dots, n$  计算

$$v_i = H_{i-1} A w_i, \quad p_i = v_i / \beta_i, \quad \beta_i = \|v_i\|_2,$$

$$x_i = x_{i-1} + \alpha_i p_i, \quad \alpha_i = (b_i - a_i^T x_{i-1}) / p_i^T a_i$$

$$H_i = H_{i-1} - p_i p_i^T;$$

(3)  $x_n$  就是 (1.1) 的极小范数解。

**§3 算法的基本性质**

算法 I 中的寻查方向  $\{p_i\}$ 、校正矩阵  $\{H_i\}$  和解向量  $\{x_i\}$  有一些重要的性质。

**定理 1** 由算法 I 得到的向量系  $p_1, p_2, \dots, p_n$  是一组标准直交向量系, 且满足

$$p_{i+1} \in R(A_i)^\perp, \quad i = 1, 2, \dots, n-1 \quad (3.1)$$

**证明** 由于  $W = [w_1, \dots, w_n]$  是  $n \times n$  上三角矩阵, 故  $A w_i$  是  $a_1, a_2, \dots, a_i$  的线性组合, 则利用数学归纳法不难证明  $p_1, p_2, \dots, p_n$  是一组标准直交向量系, 又由于  $p_i$  是  $A w_1, A w_2, \dots, A w_i$  的线性组合。故

$$\text{span} \{p_1, \dots, p_i\} = \text{span} \{A w_1, \dots, A w_i\} = \text{span} \{a_1, a_2, \dots, a_i\}.$$

而

$$p_{i+1} \in \text{span} \{p_1, p_2, \dots, p_i\}^\perp$$

则有

$$p_{i+1} \in \text{span} \{a_1, \dots, a_i\}^\perp$$

定理得证。

(3.1) 式在构造递推算法中有重要的作用。

**定理 2** 对  $i = 1, 2, \dots, n$ , 由算法 I 得到的校正矩阵  $\{H_i\}$  满足

$$H_i^T = H_i, \quad H_i^2 = H_i \quad (3.2)$$

$$H_i p_j = \begin{cases} 0 & i \geq j \\ p_j & i < j \end{cases} \quad (3.3)$$

$$H_i H_j = H_j, \quad j \geq i \quad (3.4)$$

也就是说,  $H_i$  是  $R(A_i)^\perp$  上的直交投影算子。

**证明** 由  $H_i$  的表达式及  $H_0 = I$ , 易见

$$H_i = H_i^T. \quad (3.5)$$

由定理 1 得  $\{p_i\}$  为一直交向量系, 则用数学归纳法可以证明  $H_i^2 = H_i$ , 这就证明了 (3.2)

式, 即  $H_i$  为一直交投影算子。

又由于当  $i \geq j$  时

$$H_i p_j = (I - \sum_{k=1}^i p_k p_k^T) p_j = 0, \quad (3.6)$$

而  $i < j$  时有

$$H_i p_j = (I - \sum_{k=1}^i p_k p_k^T) p_j = p_j, \quad (3.7)$$

又因为

$$p_j \in R(A_{j-1})^\top$$

故  $H_i$  是  $R(A_i)^\top$  的直交投影算子. 另一方面, 当  $i \leq j$  时

$$\begin{aligned} H_i H_j &= H_i (H_i - \sum_{k=i+1}^j p_k p_k^T) \\ &= H_i - \sum_{k=i+1}^j p_k p_k^T \\ &= H_j. \end{aligned} \quad (3.8)$$

由(3.5)–(3.8)定理得证.

由定理 1.2 可以证明

**定理 3** 设直交向量系  $p_1, p_2, \dots, p_n$  由算法 I 得到, 并令

$$Q_i = [p_1, \dots, p_i], \quad i = 1, 2, \dots, n$$

则

$$R(Q_n) = R(AW) = R(A) \quad (3.9)$$

$$H_i = I - Q_i Q_i^T, \quad \text{rank}(H_i) = n - i, \quad i = 1, 2, \dots, n \quad (3.10)$$

由此可以看出, 算法 I 给出了构造  $R(AW)$  的直交基底的方法, 并以此为寻查方向得到解(1.1)的一类递推法. 更进一步有:

**定理 4** 设  $x_i$  是算法 I 在第  $i$  步得到的解, 则

$$X = x_i + H_i y, \quad y \in R^n \quad (3.11)$$

是

$$\begin{pmatrix} a_1^T \\ \vdots \\ a_i^T \end{pmatrix} x = \begin{pmatrix} b_1 \\ \vdots \\ b_i \end{pmatrix} \quad (3.12)$$

的通解, 而  $x_i$  是(3.12)的极小范数解.

**证明** 因为  $p_1, p_2, \dots, p_i$  是  $R(A_i)$  的一组直交基, 故  $A_i$  总能表示成

$$A_i = [p_1, \dots, p_i] R_i = Q_i R_i \quad (3.13)$$

其中  $R_i$  是  $i \times i$  非奇异阵, 因此

$$A_i A_i^+ = Q_i Q_i^T.$$

这样对任何  $y \in R^n$  都有

$$H_i y = (I - Q_i Q_i^T) y, y \in N(A_i^T)$$

这里  $N(A_i^T)$  为  $A_i^T$  的零空间, 而  $x_i$  是 (3.12) 的一个解, 故

$$x = X_i + H_i y \quad (3.14)$$

是 (3.12) 的通解. 下面证明由算法 I 得到的  $x_i$  是 (3.12) 的极小范数解.

由 (3.14) 得

$$x^T x = x_i^T x_i + 2y^T H_i x_i + (H_i y)^T (H_i y)$$

故

$$x^T x \geq x_i^T x_i + 2y^T H_i x_i.$$

由于  $x_i$  能够表示成  $p_1, p_2, \dots, p_i$  的线性组合, 再利用 (3.3) 式得

$$H_i x_i = 0.$$

因此

$$x^T x \geq x_i^T x_i.$$

故由算法 I 得到的  $x_i$  是 (3.12) 的极小范数解, 也就有

**推论** 由算法 I 得到的  $x_n$  是 (1.1) 的极小范数解.

#### §4 方法的实现及矩阵 $W$ 的选取

由前面的讨论, 我们可以看出, 算法 I 的基本步骤大致可以分为两步, 首先是确定  $R(AW)$  的一组直交基  $p_1, p_2, \dots, p_n$ ; 然后再根据这一组直交基构造递推公式. 因此, 我们可用下列基本步骤来实现.

##### 算法 I

(1) 确定  $n \times n$  非奇异上三角阵  $W = [w_1, \dots, w_n]$ , 令  $x_0 = 0$ ;

(2) 用直交化分解 (如改进 Gram-Schmidt 方法等, 但无需存储上三角阵  $R$ ) 得到  $R(AW)$  的直交基  $p_1, p_2, \dots, p_n$ ;

(3) 对  $i = 1, 2, \dots, n$  计算

$$x_i = x_{i-1} + a_i p_i; \quad a_i = (b_i - a_i^T x_{i-1}) / p_i^T a_i;$$

(4)  $x_n$  就是 (1.1) 的极小范数解.

在基本算法 I、II 中都需要确定  $n \times n$  的上三角阵  $W$ , 从理论上讲, 只要  $W$  非奇异就能保证

$$R(AW) = R(A),$$

故对  $AW$  的列向量进行直交化的过程就能得到  $R(A)$  的一组直交基向量  $p_1, \dots, p_n$ . 而要求  $W$  为上三角阵是为了保证

$$p_i \in R(A_{i-1})^\perp \quad (4.1)$$

的条件成立. 也就是说, 只要  $W$  为非奇异的上三角阵时, 算法 I、II 总能继续下去.

但是对  $W$  的不同选取, 效果是很不相同的, 在这里  $W$  的选取是重要的, 无疑我们

要求  $AW$  的列向量有较强的线性独立性.

另一方面, 我们可以这样看. 设  $A$  有直交分解

$$A = Q_1 R_1 \quad (4.2)$$

其中  $Q_1$  为  $m \times n$  的列直交阵,  $R_1$  为  $n \times n$  的上三角阵, 若取

$$W = R_1^{-1}$$

则  $R(AW) = R(Q_1)$ , 故  $AW$  的列向量为直交向量, 这当然是最理想的. 但由于我们是在有限精度的计算机上计算, 这种选取矩阵  $W$  的方法有时是不现实的. 但这也给我们以启发, 如果取(4.2)中上三角阵  $R_1$  的近似逆阵作为  $W$ , 可望  $AW$  的列向量有较强的线性独立性.

设(4.2)中的矩阵  $R_1$  为

$$R_1 = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ & r_{22} & \cdots & r_{2n} \\ 0 & & \ddots & \vdots \\ & & & r_{nn} \end{pmatrix} \quad (4.4)$$

我们把由元素  $r_{11}, r_{22}, \dots, r_{nn}$  组成的主对角线称为  $R_1$  的第1条对角线; 把  $r_{12}, \dots, r_{n-1, n}$  称为  $R_1$  的第2条对角线;  $\dots$ ;  $r_{1k}, \dots, r_{n-k+1, n}$  称为  $R_1$  的第  $k$  条对角线; 显然  $R_1$  的第  $n$  条对角线由单个元素  $r_{1n}$  组成.

这样我们取  $R_1$  的前  $k$  条对角线组成的矩阵的逆阵作为  $W$ . 为了区别起见, 我们以  $W_0, W_1, \dots, W_n$  表示

$$W_0 = I,$$

$$W_1 = \begin{pmatrix} r_{11} & & & \\ \cdot & & & \\ 0 & \cdot & & \\ & & 0 & \\ & & & r_{nn} \end{pmatrix}^{-1}, \quad W_2 = \begin{pmatrix} r_{11} & r_{12} & & \\ \cdot & \cdot & & 0 \\ 0 & \cdot & \cdot & \\ & & \cdot & r_{n-1, n} \\ & & & r_{nn} \end{pmatrix}^{-1},$$

$$W_k = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1k} & & \\ \cdot & \cdot & \cdot & \cdot & & 0 \\ 0 & \cdot & \cdot & \cdot & & \\ & & \cdot & \cdot & r_{n-k+1, n} & \\ & & & \cdot & \cdot & r_{n-1, n} \\ & & & & & r_{nn} \end{pmatrix}^{-1}, \quad 1 \leq k \leq n.$$

计算  $w_k$  有一个简单递推式, 记  $w_k = [w_{ij}]$ , 则

$$w_{ii} = 1/r_{ii}, \quad i = 1, 2, \dots, n.$$

$$w_{i, i+j} = - \left( \sum_{l=1}^j r_{i, i+l} w_{l+1, i+j} \right) / r_{ii}$$

$$j = 1, 2, \dots, k-1.$$

$w_k$  的其它元素为 0. §6 的表 4 可以看出, 不同的选取  $k$ , 结果一般是不同的, 而当  $A$  为极端坏条件 (如 Hilbert 矩阵) 时,  $k$  一般要比较接近于  $n$ . 若  $A$  为一般坏条件矩阵时,  $k$  可取小一些, 如  $\lfloor \frac{n}{2} \rfloor$ . 数值结果表明, 这种处理方法对病态线性方程组是很有效的. 上面的讨论可归纳成下面的算法.

#### 算法 IV

- (1) 对  $A$  作直交分解  $A = Q_1 R_1$ ;
- (2) 确定  $1 \leq k \leq n$ , 进行下列计算
  - (2.1) 对  $n \times n$  矩阵  $W$  置零, 即  $0 \Rightarrow W$ ;
  - (2.2) 对  $l = 1, 2, \dots, k-1$  计算
    - 对  $i = 1, 2, \dots, n-l$  计算
 
$$ss = 0.0,$$
    - 对  $j = 1, 2, \dots, l$  计算
 
$$ss = ss + r(i, i+j) * w(i+j, i+l)$$
    - end  $j$ 

$$w(i, i+l) = -ss / r(i, i)$$
    - end  $i$ ;
 end  $l$ .

- (3) 对  $AW$  进行直交分解得到直交阵

$$Q = [p_1, p_2, \dots, p_n];$$

- (4) 令  $x_0 = 0$ , 对  $i = 1, 2, \dots, n$  计算

$$x_i = x_{i-1} + a_i p_i, \quad a_i = (b_i - a_i^T x_{i-1}) / p_i^T a_i$$

- (5)  $x_n$  就为 (1.1) 的极小范数解.

另外, 我们知道上面算法的极端情形是取  $W = R_1^{-1}$  或  $W = I$ , 当  $W = I$  时算法 IV 就退化为算法 I; 当取  $W = R_1^{-1}$  时, 若不计舍入误差应有

$$AW = Q_1 \tag{4.6}$$

但由于精度所限及坏条件影响, (4.6) 一般是不成立的. 但这时对  $Q_1$  作直交分解, 即

$$Q_1 = QR \tag{4.7}$$

然后以  $Q$  的列向量为递推算法的寻查方向, 得到 (1.1) 的极小范数解, 这时有算法,

#### 算法 V

- (1) 对  $A$  作直交分解  $A = Q_1 R_1$ ;
- (2) 对  $Q_1$  作直交分解得到  $R(A)$  的直交基

$$Q = [p_1, p_2, \dots, p_n].$$

- (3) 令  $x_0 = 0$ , 对  $i = 1, 2, \dots, n$  计算

$$x_i = x_{i-1} + a_i p_i, \quad a_i = (b_i - a_i^T x_{i-1}) / p_i^T a_i$$

(4)  $x_n$  就是 (1.1) 的极小范数解。

这个算法的数值结果明显地高于  $W=I$  时的情形 (比直接取  $W=R_1^{-1}$  稍差一些), 也是解病态线性方程组值得推荐的一个算法。

### §5 $R(A)$ 的直交基对解的影响

前面我们讨论了算法的基本性质及具体实现, 这里我们要讨论这样两个问题, 其一是 (1.1) 的子方程组的解与 (1.1) 的解的关系; 其二是  $R(A)$  的直交基对解的影响。

首先我们注意下列数值例子, 设问题为解

$$Ax=b \quad (5.1)$$

其中

$$A=[a_{ij}], \quad a_{i1}=a_{1i}=1, \quad i=1,2,\dots,n$$

$$a_{ij}=a_{i-1,j}+a_{i,j-1} \quad i,j=2,\dots,n.$$

$$b=[b_1,\dots,b_n]^T, \quad b_i=\sum_{j=1}^i a_{ij}$$

这时 (5.1) 的精确解  $x^*=[1,1,\dots,1]^T$ 。例如  $n=5$  时,

$$A = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 2 & 3 & 4 & 5 \\ 1 & 3 & 6 & 10 & 15 \\ 1 & 4 & 10 & 20 & 35 \\ 1 & 5 & 15 & 35 & 70 \end{pmatrix}, \quad b=[5, 15, 35, 70, 126]^T.$$

当  $n$  较大时 (例  $n=20, 30, 40, \dots$ )。这类矩阵是极端坏条件的, 但我们用算法 I 在计算机上进行计算, 得到的解  $x$  的相对误差却接近于 0, 这是什么原因呢? 事实上, 我们仔细分析一下就可以发现, 由算法 I 得到的

$$x_1 = \frac{b_1}{a_1^T a_1} a_1 = a_1 = [1,1,\dots,1]^T.$$

这就是说, 用递推算法 I 得到 (5.1) 的第一个方程

$$a_1^T x = b_1$$

的解刚好就是整个问题的解。故若忽略舍入误差的影响应有

$$X^* = x_{n-1} = \dots = x_1.$$

更一般地可以明证

**定理 4** 设  $x_j^*$  是方程组

$$\begin{pmatrix} a_1^T \\ \vdots \\ a_j^T \end{pmatrix} x = \begin{pmatrix} b_1 \\ \vdots \\ b_j \end{pmatrix}, \quad j \leq n$$

的解, 则  $x_j^*$  为 (1.1) 的解  $x^*$  的充要条件是

$$a_{j+k} = 0, \quad k=1, 2, \dots, n-j. \quad (5.2)$$

这个定理告诉我们, 若由递推算法得到  $x_1, x_2, \dots$ , 能是  $x^*$  较好的近似, 则  $|a_{j+k}|$  就较少. 这时有可能得到好的数值结果. 问题 (5.1) 的结果就属此例, 关于  $\{a_j\}$  对解的影响及其校正公式已有<sup>[4]</sup> 讨论.

另一方面, 我们注意到算法 I 的计算公式, 其中  $a_i$  的选择是使得  $x_i$  是  $a_i^T x = b_i$  的解. 而

$$p_i \in R(A_{i-1})^\perp \quad (5.3)$$

的要求是十分重要的, 也是递推算法的核心, 它是要求  $x_i$  同时为 (1.1) 的前  $i-1$  个方程组解的需要.

下面我们在其它计算都是精确的假设下, 来分析 (5.3) 的条件破坏时对解的影响. 若仅在第  $j$  步 ( $j > 1$ ) 时有误差

$$(p_j, a_i) = e_{ij}, \quad i=1, 2, \dots, j-1;$$

这时可以验证得到的解向量

$$x_j = x_{j-1} + \alpha_j p_j$$

满足方程组

$$\begin{pmatrix} a_1^T \\ \vdots \\ a_j^T \end{pmatrix} x_j = \begin{pmatrix} b_1 \\ \vdots \\ b_j \end{pmatrix} + \alpha_j \begin{pmatrix} e_{1j} \\ e_{2j} \\ \vdots \\ e_{j-1,j} \\ 0 \end{pmatrix}$$

在第  $n$  步得到的解向量

$$x_n = x_{n-1} + \alpha_n p_n.$$

从理论上讲应有

$$x_n = x^*.$$

但若 (5.3) 式不成立且有下列误差量

$$(p_j, a_i) = e_{ij} \quad (5.4)$$

$$j=1, 2, \dots, n$$

$$i=1, 2, \dots, j-1$$

则可以证明

**定理 5** 假设在算法 I 中的其他量都是精确的, 而  $\{p_i\}$  满足 (5.4) 式, 则算法 I 得到的  $x_n$  满足方程组

$$A^T x = b + E\alpha \quad (5.5)$$

其中  $n \times n$  矩阵  $E$  及  $n$  维向量  $\alpha$  分别为

$$E = \begin{pmatrix} 0 & e_{12} & \cdots & e_{1n} \\ 0 & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & e_{n-1,n} \\ 0 & \cdot & \cdot & 0 \end{pmatrix}, \quad \alpha = [\alpha_1, \cdots, \alpha_n]^T.$$

由(5.5)式可以看出, 误差量(5.4)式的作用相当于在(1.1)的右端加上扰动量  $E\alpha$ 。这也说明, 递推算法中影响解的两个因素是  $E, \alpha$ , 即(5.3)式的破坏程度及  $\{\alpha_i\}$  的排列次序。

综上所述, (5.3)的条件对递推算法是极为重要的, 新算法的基本思想是引进非奇异上三角阵  $W$ , 使  $AW$  的列向量有较强的线性独立性, 据[5]可知, 这样能使(5.3)式不致严重破坏, 使解有较高的精度, §6的数值结果也说明了这一点。

## §6 数值结果

为了检验不同算法抗病态问题的能力, 下列四个算法在南京大学数学系计算数学实验室 MC 68000 微机上用双精度进行了计算, 从大量的数值结果中选用一部分予以比较。为了与前面的记号一致, 各种算法的意义为:

**算法 I** 首先对  $A$  作直交分解得到  $R(A)$  的直交基,  $p_1, p_2, \cdots, p_n$ , 以此构造递推算法;

**算法 II** 就是本文讨论的算法 取  $W$  为非奇异上三角阵(这里取  $W = R_1^{-1}$ )。然后确定  $p_1, \cdots, p_n$  再构造递推算法。

**算法 V** 与 §4 节给出的算法 V 相同。

**直交化算法** 就是传统的处理方法, 对  $n \times n$  矩阵  $A^T$  作直交分解  $A^T = Q_1 R_1$ , 由  $R_1^T x = Q_1^T b$  得到解  $x$ 。

所解的向题是  $A^T x = b$ , 其中  $A^T$  为下列三种情况:

情况 1:  $A^T = [a_{ij}]$ ,  $a_{ij} = 1.0 / (i + j - 1.0)$ ,  
 $i, j = 1, 2, \cdots, n$ ;  $n = 5, 10, 20, 30, 40$ ;

情况 2:  $A^T = [a_{ij}]$ ,  $a_{ij} = \max(i, j)$   
 $i, j = 1, 2, \cdots, n$ ;  $n = 5, 10, 20, 30, 40$ ;

情况 3:  $A^T = [a_{ij}]$ ,  $a_{in} = a_{ni} = 0.5$ ,  $i = 1, 2, \cdots, n$   
 $a_{ij} = a_{i+1, j} + a_{i, j+1}$ ,  $i, j = 1, 2, \cdots, n$ ;  $n = 5, 10, 20, 30, 40$ ,

上面三种情况的右端向量为  $b = [b_1, b_2, \cdots, b_n]^T$ , 其中

$$b_i = \sum_{j=1}^n a_{ij} \times j \quad i = 1, 2, \cdots, n$$

在上面三个向题中, 当  $n$  稍大时(如  $n \geq 10$ ), 情况 1 和情况 3 是极端坏条件向题, 情况 2 是好条件向题。

下列表中  $A$  表示算法;  $P$  表示解的相对精度;  $N$  为方程组的阶数。表中“没有精度”是指解的相对误差大于 1; “没有误差”是指解的相对误差接近于机器零。

表1 对情况1的精度比较表

$P \backslash N$	A	直交化算法	算法 I	算法 IV	算法 V
5		$0.415917E-06$	$0.873737E-08$	$0.970667E-12$	$0.981205E-12$
10		没有精度	$0.133390E-02$	$0.187779E-07$	$0.230986E-07$
20		没有精度	没有精度	$0.396569E-07$	$0.926750E-07$
30		没有精度	$0.245479E-01$	$0.896361E-07$	$0.113388E-06$
40		没有精度	$0.230835E-01$	$0.973126E-07$	$0.249898E-06$

表2 对情况2的精度比较表

$P \backslash N$	A	直交化算法	算法 I	算法 IV	算法 V
5		$0.111916E-12$	没有误差	$0.341324E-14$	没有误差
10		$0.101130E-12$	误有误差	没有误差	没有误差
20		$0.259641E-10$	没有误差	$0.828951E-16$	$0.3^3 1580E-16$
30		$0.198133E-09$	没有误差	没有误差	没有误差
40		$0.769324E-09$	没有误差	$0.222250E-15$	$0.291851E-12$

从表1可以看出, 算法IV、V对极病态的问题(Hilbert矩阵的一部分)有较高的精度, 优于传统的直交化方法。

表2说明对好条件问题, 所列的算法都有较高的精度。

表3 对情况3的精度比较表

$P \backslash N$	A	直交化方法	算法 I	算法 IV	算法 V
5		$0.418514E-08$	$0.359577E-10$	$0.150551E-13$	$0.100420E-13$
10		没有精度	$0.351512E-02$	$0.167809E-07$	$0.301305E-07$
20		没有精度	没有精度	$0.122031E-06$	$0.444713E-07$
30		没有精度	没有精度	$0.454497E-06$	$0.644640E-07$
40		没有精度	没有精度	$0.166855E-05$	$0.160371E-06$

前面已经指出, 在算法IV中, 对角线条数的不同选取对解的精度是有影响的。对极病态的问题1和问题3(取 $n=20$ )我们给出下列比较表(见表4)。

从表4可以看出, 对选取不同的 $k$ 值, 解的精度也不同, 但一般总比取 $W=I$ (即 $k=0$ , 传统的直交化方法)时精度有较大的提高, 说明本文给出的算法为解病态问解提

供了较有效的可供选择的方法。

表4 对角线数  $k$  对解的精度影响 ( $n=20$ )

$k$	$P/A$	情况 1	情况 3
0		没有精度	没有精度
2		0.169481E-01	0.224965E-01
5		0.516895E-02	0.777550E-01
8		0.542695E-02	0.542695E-02
14		0.524998E-03	0.119325E-02
17		0.517806E-04	0.351137E-04
20		0.396569E-07	0.122031E-06

下面给出在情况 1 中取  $n=60$  (即系数矩阵为 60 阶的 Hilbert 矩阵) 时用算法 IV 得到的解向量, 精确解为  $x^* = (1, 2, \dots, 60)^T$ 。

表5, 情况 1 ( $n=60$ ) 由算法 IV 得到的解向量

.1000000E01	.2000000E01	.3000000E01	.3999994E01	.5000008E01
.5999998E01	.7000003E01	.7999994E01	.8999987E01	.1000002E02
.1100000E02	.1200000E02	.1300000E02	.1400000E02	.1500000E02
.1600000E02	.1699999E02	.1799999E02	.1900000E02	.1999999E02
.2100000E02	.2200001E02	.2300001E02	.2400001E02	.2500000E02
.2600002E02	.2700000E02	.2799999E02	.2900001E02	.3000001E02
.3100000E02	.3200000E02	.3299997E02	.3399999E02	.3499998E02
.3599998E02	.3699999E02	.3800000E02	.3900002E02	.4000002E02
.4100003E02	.4200000E02	.4300001E02	.4399998E+02	.4500001E02
.4599999E02	.4700000E02	.4800004E02	.4900000E02	.5000001E02
.5099999E02	.5199999E02	.5300001E02	.5399998E02	.5499999E02
.5599998E02	.5700000E02	.5799997E02	.5899998E02	.6000006E02

表5说明, 尽管60阶的 Hilbert 矩阵是极端坏条件的, 但由算法 IV 得到的解向量仍有 6 位有效数字, 这是传统算法所难以达到的。

本文是在何旭初先生的指导下完成的, 笔者深表谢意。

## 参 考 文 献

- [1] Huang, H. Y., A direct method for the general solution of a system of linear equation. JOTA, 16, 429—445, 1975.
- [2] Abaffy, J., et al. A class of direct methods for linear systems, Num. Math. 45, 361—376, 1984.
- [3] 何旭初, 广义逆矩阵的基本理论与计算方法, 上海科技出版社, 1985.
- [4] 赵金熙, 解相容线性方程组的高精度算法, 南京大学数学系科研报告, 1985.
- [5] Ake, Björck, Solving linear least squares problems by Gram-Schmidt orthogonalization, BIT 7 (1967).
- [6] 赵金熙, 相容线性方程组的 Huang 方法及其推广, 高等学校计算数学学报, Vol. 3, No. 1, 8—17, 1981.

## A CLASS OF DIRECT METHODS FOR SOLVING ILL-CONDITIONED LINEAR SYSTEMS

Zhao Jinxi

(Nanjing University)

### Abstract

In this paper, a class of direct methods for solving ill-conditioned linear systems is given. A nonsingular upper triangular matrix  $W$  is introduced so that linear independence of  $AW$ 's column vectors are strong. So we can obtain a "good" orthogonal basis of  $R(AW)$ . After that we used it to construct recursion algorithms for solving linear systems. Numerical examples show that the class of methods is very efficient.