

第二讲 线性方程组直接解法

- 1 Gauss 消去法和 LU 分解
- 2 特殊方程组的求解
- 3 扰动分析
- 4 误差分析
- 5 解的改进

线性方程组的求解方法



解法概述

 **直接法:** LU 分解, Cholesky 分解, ...

 **迭代法:** 古典迭代法, Krylov 子空间迭代法

直接法

优点: 稳定可靠, 有限步终止 \rightarrow 在工程界很受欢迎

缺点: 运算量大 $O(n^3)$ \rightarrow 不适合大规模问题

(针对特殊结构的快速算法除外)

1 Gauss 消去法和 LU 分解

1.1 LU 分解

1.2 LU 分解的实现

1.3 三角方程求解

1.4 选主元 LU 分解

1.5 矩阵求逆

1.1 LU 分解

考虑线性方程组

$$Ax = b$$

(2.1)

其中 $A \in \mathbb{R}^{n \times n}$ 非奇异, $b \in \mathbb{R}^n$ 为给定的右端项.

Gauss 消去法本质上就是对系数矩阵 A 进行 LU 分解:

$$A = LU$$

(2.2)

其中 L 是单位下三角矩阵, U 为非奇异上三角矩阵.

Gauss 消去法

$$Ax = b \iff \begin{cases} Ly = b, \\ Ux = y. \end{cases} \implies \text{只需求解两个三角方程组}$$

算法 1 Gauss 消去法

- 1: 将 A 进行 LU 分解: $A = LU$;
- 2: 向前回代: 求解 $Ly = b$, 即得 $y = L^{-1}b$;
- 3: 向后回代: 求解 $Ux = y$, 即得 $x = U^{-1}y = (LU)^{-1}b = A^{-1}b$.

LU 分解

定理 (LU 分解的存在性和唯一性) 设 $A \in \mathbb{R}^{n \times n}$. 则存在唯一的单位下三角矩阵 L 和非奇异上三角矩阵 U , 使得 $A = LU$ 的充要条件是 A 的所有顺序主子矩阵 $A_k = A(1:k, 1:k)$ 都非奇异, $k = 1, 2, \dots, n$.

(板书)



A 非奇异, 则解存在唯一, 但并不一定存在 LU 分解!

推论 (LDU 分解) 设 $A \in \mathbb{R}^{n \times n}$ 的所有顺序主子矩阵都非奇异, 则存在单位下三角矩阵 L 和单位上三角矩阵 U , 以及非奇异的对角矩阵 D , 使得 $A = LDU$, 其中 L, U, D 都是唯一的. 反之, 若 A 存在 LDU 分解, 则 A 的所有顺序主子矩阵都非奇异.

对角占优矩阵的 LU 分解

一般的非奇异矩阵不一定存在 LU 分解, 但若 A 对角占优, 则一定存在 LU 分解.

定理 设 $A \in \mathbb{R}^{n \times n}$ 非奇异且列对角占优, 则 A 存在 LU 分解且 L 中的元素的绝对值都不超过 1. (留作练习, 数学归纳法)

如果是严格对角占优的, 则可以给出 $\|A^{-1}\|_1$ 的一个估计.

定理 设 $A \in \mathbb{R}^{n \times n}$ 严格列对角占优, 记 $\delta \triangleq \min_{1 \leq j \leq n} \left(|a_{jj}| - \sum_{i=1}^n |a_{ij}| \right) > 0$, 则 $\|A^{-1}\|_1 \leq \delta^{-1}$.

1.2 LU 分解的实现 — 矩阵初等变换

给定一个矩阵 $A = \begin{bmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \\ a_{n1} & \cdots & a_{nn} \end{bmatrix} \in \mathbb{R}^{n \times n}$.

第一步: 假定 $a_{11} \neq 0$, 构造矩阵 $(l_{i1} = \frac{a_{i1}}{a_{11}}, i = 2, \dots, n)$

$$L_1 = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ l_{21} & 1 & \cdots & 0 \\ \vdots & & \ddots & \vdots \\ l_{n1} & 0 & \cdots & 1 \end{bmatrix}, \quad \text{可得} \quad L_1^{-1} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ -l_{21} & 1 & \cdots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ -l_{n1} & 0 & \cdots & 1 \end{bmatrix}.$$

用 L_1^{-1} 左乘 A , 并将所得到的矩阵记为 $A^{(1)}$, 则

$$A^{(1)} = L_1^{-1}A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ 0 & a_{22}^{(1)} & \cdots & a_{2n}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & a_{n2}^{(1)} & \cdots & a_{nn}^{(1)} \end{bmatrix}.$$

第二步: 将上面的操作作用在 $A^{(1)}$ 的子矩阵 $A^{(1)}(2:n, 2:n)$ 上, 将其第一列除第一个元素外都变为 0: 假定 $a_{22}^{(1)} \neq 0$, 构造矩阵

$$L_2 = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ 0 & 1 & 0 & \cdots & 0 \\ 0 & l_{32} & 1 & \cdots & 0 \\ \vdots & \vdots & & \ddots & \\ 0 & l_{n2} & 0 & \cdots & 1 \end{bmatrix}, \quad \text{其中} \quad l_{i2} = \frac{a_{i2}^{(1)}}{a_{22}^{(1)}}, i = 3, 4, \dots, n.$$

用 L_2^{-1} 左乘 $A^{(1)}$, 并将所得到的矩阵记为 $A^{(2)}$, 则

$$A^{(2)} = L_2^{-1}A = L_2^{-1}L_1^{-1}A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \cdots & a_{1n} \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & \cdots & a_{2n}^{(1)} \\ 0 & 0 & a_{33}^{(2)} & \cdots & a_{3n}^{(2)} \\ \vdots & \vdots & \vdots & \ddots & \\ 0 & 0 & a_{n3}^{(2)} & \cdots & a_{nn}^{(2)} \end{bmatrix} .$$

依此类推, 假定 $a_{kk}^{(k-1)} \neq 0$ ($k = 3, 4, \dots, n-1$),

我们可以构造一系列的矩阵 L_3, L_4, \dots, L_{n-1} , 使得

$$L_{n-1}^{-1} \cdots L_2^{-1} L_1^{-1} A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \cdots & a_{1n} \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & \cdots & a_{2n}^{(1)} \\ 0 & 0 & a_{33}^{(2)} & \cdots & a_{3n}^{(2)} \\ \vdots & \vdots & \vdots & \ddots & \\ 0 & 0 & 0 & \cdots & a_{nn}^{(n-1)} \end{bmatrix} \triangleq U \rightarrow \text{上三角}$$

于是可得 $A = LU$ 其中

$$L = L_1 L_2 \cdots L_{n-1} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ l_{21} & 1 & 0 & \cdots & 0 \\ l_{31} & l_{32} & 1 & \cdots & 0 \\ \vdots & \vdots & & \ddots & \\ l_{n1} & l_{n2} & l_{n3} & \cdots & 1 \end{bmatrix}$$

LU 分解算法

算法 2 LU 分解

```
1: for  $k = 1$  to  $n - 1$  do
2:   for  $i = k + 1$  to  $n$  do
3:      $l_{ik} = a_{ik}/a_{kk}$    % 计算  $L$  的第  $k$  列
4:   end for
5:   for  $j = k$  to  $n$  do
6:      $u_{kj} = a_{kj}$    % 计算  $U$  的第  $k$  行
7:   end for
8:   for  $i = k + 1$  to  $n$  do
9:     for  $j = k + 1$  to  $n$  do
10:       $a_{ij} = a_{ij} - l_{ik}u_{kj}$    % 更新  $A(k + 1 : n, k + 1 : n)$ 
11:    end for
12:   end for
13: end for
```

Gauss 消去法的运算量

由算法 2 可知, LU 分解的运算量 (加减乘除) 为

$$\sum_{i=1}^{n-1} \left(\sum_{j=i+1}^n 1 + \sum_{j=i+1}^n \sum_{k=i+1}^n 2 \right) = \sum_{i=1}^{n-1} (n-i + 2(n-i)^2) = \frac{2}{3}n^3 + \mathcal{O}(n^2).$$

加上回代过程的运算量 $\mathcal{O}(n^2)$, 总运算量为

$$\frac{2}{3}n^3 + \mathcal{O}(n^2)$$

算法评价



评价算法的一个主要指标是**执行时间**,但这依赖于计算机硬件和编程技巧等,因此直接给出算法执行时间是不太现实的.所以我们通常是统计算法中**算术运算(加减乘除)**的次数.



在数值算法中,大多仅仅涉及加减乘除和开方运算.一般地,加减运算次数与乘法运算次数具有相同的量级,而除法运算和开方运算次数具有更低的量级.



为了尽可能地减少运算量,在实际计算中,数,向量和矩阵做乘法运算时的先后执行次序为:先计算数与向量的乘法,然后计算矩阵与向量的乘法,最后才计算矩阵与矩阵的乘法.

矩阵 L 和 U 的存储

当 A 的第 i 列被用于计算 L 的第 i 列后, 在后面的计算中不再被使用.

同样, A 的第 i 行被用于计算 U 的第 i 行后, 在后面计算中也不再使用.

为了节省存储空间, 在计算过程中将 L 的第 i 列存放在 A 的第 i 列, 将 U 的第 i 行存放在 A 的第 i 行, 这样就不需要另外分配空间存储 L 和 U .

用 A 存储 L 和 U

算法 3 LU 分解

```
1: for  $k = 1$  to  $n - 1$  do  
2:   for  $i = k + 1$  to  $n$  do  
3:      $a_{ik} = a_{ik}/a_{kk}$   
4:     for  $j = k + 1$  to  $n$  do  
5:        $a_{ij} = a_{ij} - a_{ik}a_{kj}$   
6:     end for  
7:   end for  
8: end for
```

```
1 % Matlab code : LU 分解
2 function A = mylu(A)
3 n=size(A,1);
4 for k=1:n-1
5     if A(k,k) == 0, return; end
6     for i=k+1:n
7         A(i,k)=A(i,k)/A(k,k);
8         for j=k+1:n
9             A(i,j)=A(i,j)-A(i,k)*A(k,j);
10        end
11    end
12 end
```

为了充分利用 Matlab 向量运算优势, 提高效率, 可改写为

```
1 function A = mylu(A)
2 n=size(A,1);
3 for k=1:n-1
4     if A(k,k) == 0, return; end
5     A(k+1:n,k)=A(k+1:n,k)/A(k,k);
6     A(k+1:n,k+1:n)=A(k+1:n,k+1:n)-A(k+1:n,k)*A(k,k+1:n);
7 end
```

哪种方式合适



- 根据指标的循环次序, 算法 3 也称为 KIJ 型 LU 分解. 实际计算中一般不建议使用: 对指标 k 的每次循环, 都需要更新 A 的第 $k+1$ 至第 n 行, 这种反复读取数据的做法会使得计算效率大大降低.
- 若按行存储, 可采用后面介绍的 IKJ 型 LU 分解.

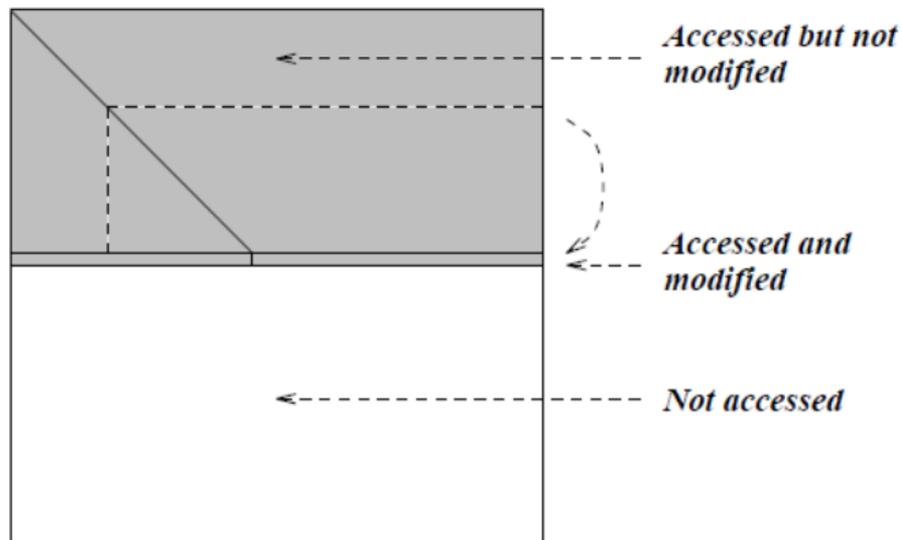
IKJ 型 LU 分解

如果数据是按行存储, 如 C/C++, 可采用下面的 IKJ 型 LU 分解.

算法 4 LU 分解 (IKJ 型)

```
1: for  $i = 2$  to  $n$  do  
2:   for  $k = 1$  to  $i - 1$  do  
3:      $a_{ik} = a_{ik}/a_{kk}$   
4:     for  $j = k + 1$  to  $n$  do  
5:        $a_{ij} = a_{ij} - a_{ik}a_{kj}$   
6:     end for  
7:   end for  
8: end for
```

上述算法可以用下图来描述.



思考: 如果数据按列存储, 如 FORTRAN/MATLAB, 如何设计算法?

1.3 三角方程求解

得到 A 的 LU 分解后, 我们最后需要用回代法求解两个三角方程组

$$Ly = b, \quad Ux = y.$$

算法 5 向前回代求解 $Ly = b$ (假定 L 是一般的非奇异下三角矩阵)

- 1: $y_1 = b_1/l_{11}$
- 2: **for** $i = 2 : n$ **do**
- 3: **for** $j = 1 : i - 1$ **do**
- 4: $b_i = b_i - l_{ij}y_j$
- 5: **end for**
- 6: $y_i = b_i/l_{ii}$
- 7: **end for**

列存储方式

如果数据是按列存储的, 则采用列存储方式效率会高一些.

算法 6 向后回代求解 $Ux = y$

```
1: for  $i = n : -1 : 1$  do  
2:    $x_i = y_i / u_{ii}$   
3:   for  $j = i - 1 : -1 : 1$  do  
4:      $y_j = y_j - x_i u_{ji}$   
5:   end for  
6: end for
```

这两个算法的运算量均为 $n^2 + \mathcal{O}(n)$.

1.4 选主元 LU 分解

为什么要选主元

- 在 LU 分解算法 2 中, 我们称 $a_{kk}^{(k-1)}$ 为主元.
如果 $a_{kk}^{(k-1)} = 0$, 则算法就无法进行下去.
- 即使 $a_{kk}^{(k-1)}$ 不为零, 但如果 $|a_{kk}^{(k-1)}|$ 的值很小, 由于舍入误差的原因, 也可能会给计算结果带来很大的误差.

例 用 LU 分解求解线性方程组 $Ax = b$, 其中

$$A = \begin{bmatrix} 0.02 & 61.3 \\ 3.43 & -8.5 \end{bmatrix}, \quad b = \begin{bmatrix} 61.5 \\ 25.8 \end{bmatrix},$$

要求在运算过程中保留 3 位有效数字.

$(x_1 \approx -20.7, x_2 \approx 1.01)$ (精确解 $x_1 = 10.0$ 和 $x_2 = 1.00$)

(板书)

解. 根据 LU 分解算法 2, 我们可得

$$\begin{aligned}l_{11} &= 1.00, \quad l_{21} = a_{21}/a_{11} = 1.72 \times 10^2, \quad l_{22} = 1.00, \\u_{11} &= a_{11} = 2.00 \times 10^{-2}, \quad u_{12} = a_{12} = 6.13 \times 10, \\u_{22} &= a_{22} - l_{21}u_{12} \approx -8.5 - 1.05 \times 10^4 \approx -1.05 \times 10^4,\end{aligned}$$

即

$$A \approx \begin{bmatrix} 1.00 & 0 \\ 1.72 \times 10^2 & 1.00 \end{bmatrix} \begin{bmatrix} 2.00 \times 10^{-2} & 6.12 \times 10 \\ 0 & -1.05 \times 10^4 \end{bmatrix}.$$

解方程组 $Ly = b$ 可得

$$y_1 = 6.15 \times 10, \quad y_2 = b_2 - l_{21}y_1 \approx -1.06 \times 10^4.$$

解方程组 $Ux = y$ 可得

$$x_2 = y_2/u_{22} \approx 1.01, \quad x_1 = (y_1 - u_{12} * x_2)/u_{11} \approx -0.413/u_{11} \approx -20.7$$

与精确解 $x_1 = 10.0$ 和 $x_2 = 1.00$ 差别很大.



选主元 LU 分解

定理 设 $A \in \mathbb{R}^{n \times n}$ 非奇异, 则存在置换矩阵 P_L, P_R , 以及单位下三角矩阵 L 和非奇异上三角矩阵 U , 使得 $P_L A P_R = LU$, 其中 P_L 和 P_R 中只有一个是必需的.

(板书)

第 k 步时, 如何选取置换矩阵 $P_L^{(k)}$ 和 $P_R^{(k)}$?

选法一. 使得主元为剩下的矩阵中绝对值最大, 这种选取方法称为“全主元 Gauss 消去法”, 简称 GECP (Gaussian elimination with complete pivoting)

选法二. 使得主元为第 k 列的第 k 到第 n 个元素中绝对值最大, 这种选取方法称为“部分选主元 Gauss 消去法”, 简称 GEPP (Gaussian elimination with partial pivoting), 此时 $P_R^{(k)} = I$, 因此也称为列主元 Gauss 消去法.

➤ 在绝大多数情况下, GEPP 是向后稳定的, 但理论上也存在失败的例子.



➤ GECP 比 GEPP 更稳定, 但工作量大.

➤ 事实上, 在大部分实际应用中, GEPP 与 GECP 具有同样的数值稳定性.

算法 7 部分选主元 LU 分解

```
1:  $p = 1 : n$  % 用于记录置换矩阵
2: for  $k = 1$  to  $n - 1$  do
3:    $[a_{\max}, l] = \max_{k \leq i \leq n} |a_{ik}|$  % 选列主元,  $l$  表示主元所在的行
4:   if  $l \neq k$  then
5:     for  $j = 1$  to  $n$  do
6:        $tmp = a_{kj}, a_{kj} = a_{lj}, a_{lj} = tmp$  % 交换两行
7:     end for
8:      $tmp = p(k), p(k) = p(l), p(l) = tmp$  % 更新置换矩阵
9:   end if
10:  for  $i = k + 1$  to  $n$  do
11:     $a_{ik} = a_{ik} / a_{kk}$  % 计算  $L$  的第  $k$  列
12:  end for
13:  for  $i = k + 1$  to  $n$  do
14:    for  $j = k + 1$  to  $n$  do
15:       $a_{ij} = a_{ij} - a_{ik} * a_{kj}$  % 更新  $A(k + 1 : n, k + 1 : n)$ 
16:    end for
17:  end for
18: end for
```

```
1 function [A,p] = myplu(A)
2 [n,n]=size(A); p=1:n;
3 for i=1:n-1
4     [a,k]=max(abs(A(i:n,i)));
5     if a==0
6         error('Error: 第 %d 步的列主元为 0!\n', i);
7     end
8     k=k+i-1;
9     if k~=i
10        tmp=A(i,:); A(i,:)=A(k,:); A(k,:)=tmp;
11        tmp=p(i); p(i)=p(k); p(k)=tmp;
12    end
13    A(i+1:n,i)=A(i+1:n,i)/A(i,i);
14    A(i+1:n,i+1:n)=A(i+1:n,i+1:n)-A(i+1:n,i)*A(i,i+1:n);
15 end
```

例 用部分选主元 LU 分解求解线性方程组 $Ax = b$, 其中

$$A = \begin{bmatrix} 0.02 & 61.3 \\ 3.43 & -8.5 \end{bmatrix}, \quad b = \begin{bmatrix} 61.5 \\ 25.8 \end{bmatrix},$$

要求在运算过程中保留 3 位有效数字.

$(x_1 \approx 10.0, x_2 \approx 0.998)$ (精确解 $x_1 = 10.0$ 和 $x_2 = 1.00$)

(板书)

解. 由于 $|a_{21}| > |a_{11}|$, 因此我们交换第一行与第二行, 即取 $P = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$, 然后计算 $\tilde{A} = PA$ 的 LU 分解, 可得

$$\begin{aligned}l_{11} &= 1.00, \quad l_{21} = \tilde{a}_{21}/\tilde{a}_{11} = 5.83 \times 10^{-3}, \quad l_{22} = 1.00, \\u_{11} &= \tilde{a}_{11} = 3.43, \quad u_{12} = \tilde{a}_{12} = -8.50, \\u_{22} &= \tilde{a}_{22} - l_{21}u_{12} \approx 6.13 \times 10 + 4.96 \times 10^{-2} \approx 6.13 \times 10,\end{aligned}$$

即

$$PA \approx \begin{bmatrix} 1.00 & 0 \\ 5.83 \times 10^{-3} & 1.00 \end{bmatrix} \begin{bmatrix} 3.43 & -8.50 \\ 0 & 6.13 \times 10 \end{bmatrix}.$$

解方程组 $Ly = P^T b$ 可得 $y_1 = 2.58 \times 10$, $y_2 \approx 6.12 \times 10$.

解方程组 $Ux = y$ 可得

$$x_2 = y_2/u_{22} \approx 0.998, \quad x_1 = (y_1 - u_{12} * x_2)/u_{11} \approx 34.3/u_{11} \approx 10.0$$

所以, 数值解具有 3 位有效数字. □

1.5 矩阵求逆

我们可以通过部分选主元 LU 分解来计算矩阵的逆. 设 $PA = LU$, 则

$$A^{-1} = U^{-1}L^{-1}P,$$

等价于求解下面 $2n$ 个三角线性方程组

$$Ly_i = Pe_i, \quad Ux_i = y_i, \quad i = 1, 2, \dots, n.$$

思考: 也可以分别计算 L^{-1} 和 U^{-1} , 然后相乘. 哪种方法划算?

2 | 特殊方程组的求解

2.1 对称正定线性方程组

2.2 对称不定线性方程组

2.3 三对角线性方程组

2.4 带状线性方程组

2.5 Toeplitz 线性方程组

2.1 对称正定线性方程组

Cholesky 分解

定理 (Cholesky 分解) 设 $A \in \mathbb{R}^{n \times n}$ 对称正定, 则存在唯一的对角线元素为正的下三角矩阵 L , 使得

$$A = LL^T.$$

该分解称为 **Cholesky 分解**.

(板书)

Cholesky 分解的实现

设 $A = LL^T$, 即

$$\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} = \begin{bmatrix} l_{11} & & & \\ l_{21} & l_{22} & & \\ \vdots & \vdots & \ddots & \\ l_{n1} & l_{n2} & \cdots & l_{nn} \end{bmatrix} \begin{bmatrix} l_{11} & l_{21} & \cdots & l_{n1} \\ & l_{22} & \cdots & l_{n2} \\ & & \ddots & \vdots \\ & & & l_{nn} \end{bmatrix}.$$

直接比较等式两边的元素可得

$$a_{ij} = \sum_{k=1}^n l_{ik}l_{jk} = l_{jj}l_{ij} + \sum_{k=1}^{j-1} l_{ik}l_{jk}, \quad i, j = 1, 2, \dots, n.$$

Cholesky 分解算法

算法 8 Cholesky 分解算法

1: **for** $j = 1$ to n **do**

$$2: \quad l_{jj} = \left(a_{jj} - \sum_{k=1}^{j-1} l_{jk}^2 \right)^{1/2}$$

3: **for** $i = j + 1$ to n **do**

$$4: \quad \quad l_{ij} = \left(a_{ij} - \sum_{k=1}^{j-1} l_{ik} l_{jk} \right) / l_{jj}$$

5: **end for**

6: **end for**

几点说明

- 与 LU 分解一样, 可以利用 A 的下三角部分来存储 L
- Cholesky 分解算法的运算量为 $\frac{1}{3}n^3 + \mathcal{O}(n^2)$, 大约为 LU 分解的一半
- Cholesky 分解算法是稳定的, 稳定性与全主元 Gauss 消去法相当, 故不需要选主元
- 基于 Cholesky 分解的求解方法称为 **平方根法**

例 已知矩阵 $A = \begin{bmatrix} 4 & 2 & 8 & 0 \\ 2 & 10 & 10 & 9 \\ 8 & 10 & 21 & 6 \\ 0 & 9 & 6 & 34 \end{bmatrix}$, 计算 A 的 Cholesky 分解.

(板书)

解. 设 A 的 Cholesky 分解为 $A = LL^T$, 即

$$A = \begin{bmatrix} 4 & 2 & 8 & 0 \\ 2 & 10 & 10 & 9 \\ 8 & 10 & 21 & 6 \\ 0 & 9 & 6 & 34 \end{bmatrix} = \begin{bmatrix} l_{11} & & & \\ l_{21} & l_{22} & & \\ l_{31} & l_{32} & l_{33} & \\ l_{41} & l_{42} & l_{43} & l_{44} \end{bmatrix} \begin{bmatrix} l_{11} & & & \\ l_{21} & l_{22} & & \\ l_{31} & l_{32} & l_{33} & \\ l_{41} & l_{42} & l_{43} & l_{44} \end{bmatrix}^T.$$

比较等式两边的第一行可得

$$l_{11}^2 = 4 \implies l_{11} = 2, \quad (l_{11} > 0)$$

$$l_{11}l_{21} = 2 \implies l_{21} = 1,$$

$$l_{11}l_{31} = 8 \implies l_{31} = 4,$$

$$l_{11}l_{41} = 0 \implies l_{41} = 0.$$

比较等式两边的第二行可得

$$l_{21}^2 + l_{22}^2 = 10 \implies l_{22}^2 = 9 \implies l_{22} = 3, \quad (l_{22} > 0)$$

$$l_{21}l_{31} + l_{22}l_{32} = 10 \implies l_{32} = (10 - 4)/3 = 2,$$

$$l_{21}l_{41} + l_{22}l_{42} = 9 \implies l_{42} = (9 - 0)/3 = 3.$$

比较等式两边的第三行可得

$$l_{31}^2 + l_{32}^2 + l_{33}^2 = 21 \implies l_{33}^2 = 21 - 16 - 4 = 1 \implies l_{33} = 1 \quad (l_{33} > 0)$$

$$l_{31}l_{41} + l_{32}l_{42} + l_{33}l_{43} = 6 \implies l_{43} = (6 - 0 - 6)/1 = 0.$$

比较等式两边的第四行可得

$$l_{41}^2 + l_{42}^2 + l_{43}^2 + l_{44}^2 = 34 \implies l_{44}^2 = 34 - 0 - 9 - 0 = 25 \implies l_{44} = 5. \quad (l_{44} > 0)$$

所以 A 的 Cholesky 分解为

$$A = \begin{bmatrix} 2 & & & \\ 1 & 3 & & \\ 4 & 2 & 1 & \\ 0 & 3 & 0 & 5 \end{bmatrix} \begin{bmatrix} 2 & & & \\ 1 & 3 & & \\ 4 & 2 & 1 & \\ 0 & 3 & 0 & 5 \end{bmatrix}^T.$$

□

LDLT 分解与改进的平方根法

为了避免开方运算, 我们可以将 A 分解为: $A = LDL^T$, 即

$$\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} = \begin{bmatrix} 1 & & & \\ l_{21} & 1 & & \\ \vdots & & \ddots & \\ l_{n1} & \cdots & l_{n,n-1} & 1 \end{bmatrix} \begin{bmatrix} d_1 & & & \\ & d_2 & & \\ & & \ddots & \\ & & & d_n \end{bmatrix} \begin{bmatrix} 1 & l_{21} & \cdots & l_{n1} \\ & 1 & \cdots & l_{n2} \\ & & \ddots & \vdots \\ & & & 1 \end{bmatrix}$$

通过待定系数法可得

$$a_{ij} = \sum_{k=1}^n l_{ik} d_k l_{jk} = d_j l_{ij} + \sum_{k=1}^{j-1} l_{ik} d_k l_{jk}, \quad i, j = 1, 2, \dots, n.$$

基于该分解的求解对称正定线性方程组的算法称为 **改进的平方根法**

算法9 改进的平方根法

```
1: for  $j = 1$  to  $n$  do    % 先计算分解
2:    $d_j = a_{jj} - \sum_{k=1}^{j-1} l_{jk}^2 d_k$ 
3:   for  $i = j + 1$  to  $n$  do
4:      $l_{ij} = (a_{ij} - \sum_{k=1}^{j-1} l_{ik} d_k l_{jk}) / d_j$ 
5:   end for
6: end for
7:  $y_1 = b_1$     % 解方程组:  $Ly = b$  和  $DL^T x = y$ 
8: for  $i = 2$  to  $n$  do
9:    $y_i = b_i - \sum_{k=1}^{i-1} l_{ik} y_k$ 
10: end for
11:  $x_n = y_n / d_n$ 
12: for  $i = n - 1$  to  $1$  do
13:    $x_i = y_i / d_i - \sum_{k=i+1}^n l_{ki} x_k$ 
14: end for
```

2.2 对称不定线性方程组

$A \rightarrow$ 非奇异, 对称 但 不定

若 A 存在 LU 分解, 即 $A = LU$, 则可写成

$$A = LDL^T$$

 然而, 当 A 不定时, 其 LU 分解不一定存在.

若采用选主元 LU 分解, 则其对称性将被破坏.

LDL^T 分解

为了保持对称性, 在选主元时必须对行列进行同样的置换, 即选取置换矩阵 P , 使得

$$PAP^T = LDL^T. \quad (2.3)$$

通常称 (2.3) 为对称矩阵的 LDL^T 分解.

☹️ 不幸的是, 这样的置换矩阵可能不一定存在, 即分解 (2.3) 不一定存在.

例 设对称矩阵

$$A = \begin{bmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \end{bmatrix}.$$

由于 A 的对角线元素都是 0, 对任意置换矩阵 P , 矩阵 PAP^T 的对角线元素仍然都是 0. 因此, 矩阵 A 不存在 LDL^T 分解.

解决方法：块 LDL^T 分解

设 A 对称非奇异, 则存在置换矩阵 P 使得

$$PAP^T = \begin{bmatrix} B & E^T \\ E & C \end{bmatrix}, \quad B \in \mathbb{R} \text{ 或 } B \in \mathbb{R}^{2 \times 2}, \text{ 且非奇异.}$$

 思考: 如何实现?

块 LDL^T 分解

于是可以对 PAP^T 进行块对角化, 即

$$PAP^T = \begin{bmatrix} I & 0 \\ EB^{-1} & I \end{bmatrix} \begin{bmatrix} B & 0 \\ 0 & C - EB^{-1}E^T \end{bmatrix} \begin{bmatrix} I & B^{-1}E^T \\ 0 & I \end{bmatrix},$$

其中 $C - EB^{-1}E^T$ 是 Schur 补, 对称非奇异.

不断重复以上过程, 就可以得到 A 的块 LDL^T 分解:

$$PAP^T = L\tilde{D}L^T,$$

其中 \tilde{D} 是拟对角矩阵, 即块对角矩阵且对角块的大小为 1×1 或 2×2 .

选主元块 LDL^T 分解

选主元策略

- 全主元策略: 由 Bunch 和 Parlett 于 1971 年提出, 并证明了其稳定性. 但需要进行 $n^3/6$ 次比较运算, 代价比较昂贵.
- 部分选主元策略: 由 Bunch 和 Kaufman 于 1977 年提出, 将比较运算复杂度降低到 $\mathcal{O}(n^2)$ 量级, 而且具有较满意的向后稳定性. 因此被广泛使用.
- Rook 策略: 由 Ashcraft, Grimes 和 Lewis 于 1998 年提出, 整体上与部分选主元类似, 但在选主元时加了一层迭代, 精度更高.

👉 目前大部分软件都采用部分选主元块 LDL^T 分解算法.

2.3 三对角线性方程组

$$A = \begin{bmatrix} b_1 & c_1 & & & \\ a_1 & \ddots & \ddots & & \\ & \ddots & \ddots & c_{n-1} & \\ & & a_{n-1} & b_n & \end{bmatrix}.$$

我们假定

$$|b_1| > |c_1| > 0, |b_n| > |a_{n-1}| > 0, |b_i| \geq |a_{i-1}| + |c_i|, i = 2, \dots, n-1 \quad (2.4)$$

$$a_i c_i \neq 0, \quad i = 1, \dots, n-1. \quad (2.5)$$

即 A 是不可约弱对角占优

 **思考:** 如果 A 可约, 怎么处理? (什么情况下, 三对角矩阵可约?)

此时, 我们可以得到下面的三角分解

$$A = \begin{bmatrix} b_1 & c_1 & & & \\ a_1 & \ddots & \ddots & & \\ & \ddots & \ddots & c_{n-1} & \\ & & a_{n-1} & b_n & \end{bmatrix} = \begin{bmatrix} \alpha_1 & & & & \\ a_1 & \alpha_2 & & & \\ & \ddots & \ddots & & \\ & & a_{n-1} & \alpha_n & \end{bmatrix} \begin{bmatrix} 1 & \beta_1 & & & \\ & 1 & \ddots & & \\ & & \ddots & \beta_{n-1} & \\ & & & 1 & \end{bmatrix} \triangleq LU$$

得递推公式:

$$\alpha_1 = b_1, \quad \beta_1 = c_1/\alpha_1 = c_1/b_1,$$

$$\begin{cases} \alpha_i = b_i - a_{i-1}\beta_{i-1}, \\ \beta_i = c_i/\alpha_i = c_i/(b_i - a_{i-1}\beta_{i-1}), \quad i = 2, 3, \dots, n-1 \end{cases}$$

$$\alpha_n = b_n - a_{n-1}\beta_{n-1}.$$

为了使得算法能够顺利进行下去, 我们需要证明 $\alpha_i \neq 0$.

定理 设三对角矩阵 A 满足条件 (2.4) 和 (2.5). 则 A 非奇异, 且

(1) $|\alpha_1| = |b_1| > 0$;

(2) $0 < |\beta_i| < 1, i = 1, 2, \dots, n - 1$;

(3) $0 < |c_i| \leq |b_i| - |a_{i-1}| < |\alpha_i| < |b_i| + |a_{i-1}|, i = 2, 3, \dots, n$;

(板书)

算法 10 追赶法

- 1: $\beta_1 = c_1/b_1$
- 2: $y_1 = f_1/b_1$
- 3: **for** $i = 2$ to $n - 1$ **do**
- 4: $\alpha_i = b_i - a_{i-1}\beta_{i-1}$
- 5: $\beta_i = c_i/\alpha_i$
- 6: $y_i = (f_i - a_{i-1}y_{i-1})/\alpha_i$
- 7: **end for**
- 8: $\alpha_n = b_n - a_{n-1}\beta_{n-1}$
- 9: $y_n = (f_n - a_{n-1}y_{n-1})/\alpha_n$
- 10: $x_n = y_n$
- 11: **for** $i = n - 1$ to 1 **do**
- 12: $x_i = y_i - \beta_i x_{i+1}$
- 13: **end for**

几点说明

- 📁 追赶法 (也称为 **Thomas 算法**) 的运算量大约为 $8n$.
- 📁 具体计算时, 由于求解 $Ly = f$ 与矩阵 LU 分解是同时进行的, 因此, α_i 可以不用存储. 但 β_i 需要存储.
- 📁 由于 $|\beta_i| < 1$, 因此在回代求解 x_i 时, 误差可以得到有效控制.

列对角占优情形

需要指出的是, 我们也可以考虑下面的分解

$$A = \begin{bmatrix} b_1 & c_1 & & & \\ a_1 & \ddots & \ddots & & \\ & \ddots & \ddots & c_{n-1} & \\ & & a_{n-1} & b_n & \end{bmatrix} = \begin{bmatrix} 1 & & & & \\ \gamma_1 & 1 & & & \\ & \ddots & \ddots & & \\ & & \gamma_{n-1} & 1 & \end{bmatrix} \begin{bmatrix} \alpha_1 & c_1 & & & \\ & \alpha_2 & \ddots & & \\ & & \ddots & c_{n-1} & \\ & & & \ddots & \\ & & & & \alpha_n \end{bmatrix}. \quad (2.6)$$

但此时 $|\gamma_i|$ 可能大于 1. 比如当 $|b_1| < |a_1|$ 时, $|\gamma_1| = |a_1/b_1| > 1$. 所以在回代求解时, 误差可能得不到有效控制. 同时, 计算 γ_i 时也可能会产生较大误差 (大数除小数). **如果 A 列对角占优, 则可以保证 $|\gamma_i| < 1$.**



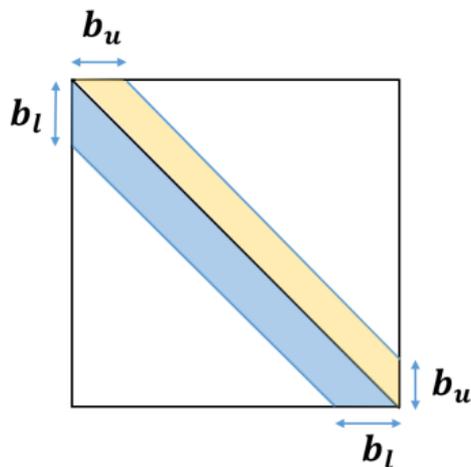
如果 A 是 (行) 对角占优, 则采用前面的分解;

如果 A 是**列对角占优**, 则采用分解 (2.6).

2.4 带状线性方程组

设 $A \in \mathbb{R}^{n \times n}$ 是带状矩阵, 其下带宽为 b_l , 上带宽为 b_u , 即

$$a_{ij} = 0 \quad \text{for} \quad i > j + b_l \quad \text{or} \quad i < j - b_u.$$



带状矩阵的 LU 分解

定理 设 $A \in \mathbb{R}^{n \times n}$ 是带状矩阵, 其下带宽为 b_l , 上带宽为 b_u . 若 $A = LU$ 是不选主元的 LU 分解, 则 L 为下带宽为 b_l 的带状矩阵, U 为上带宽为 b_u 的带状矩阵.

练习: 统计求解带状矩阵 $Ax = b$ 的运算量.

带状矩阵的部分选主元 LU 分解

若采用部分选主元的 LU 分解, 则有

定理 设 $A \in \mathbb{R}^{n \times n}$ 是带状矩阵, 其下带宽为 b_l , 上带宽为 b_u . 若 $PA = LU$ 是部分选主元的 LU 分解, 则 U 为上带宽不超过 $b_l + b_u$ 的带状矩阵, L 为下带宽为 b_l 的“基本带状矩阵”, 即 L 每列的非零元素不超过 $b_l + 1$ 个.

2.5 Toeplitz 线性方程组

Toeplitz 矩阵

$$T_n = \begin{bmatrix} t_0 & t_{-1} & \cdots & t_{-n+1} \\ t_1 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & t_{-1} \\ t_{n-1} & \cdots & t_1 & t_0 \end{bmatrix}$$



易知, T_n 是反向对称 (persymmetric) 矩阵.

反向对称矩阵

记 J_n 为 n 阶 反向单位矩阵:

$$J_n = \begin{bmatrix} & & & 1 \\ & & & & \\ & & & & & \\ & & \dots & & & \\ & & & 1 & & \\ 1 & & & & & \end{bmatrix}$$



易知 $J_n^T = J_n^{-1} = J_n$, $J_n^2 = I_n$.

引理 矩阵 $A \in \mathbb{R}^{n \times n}$ 是反向对称矩阵当且仅当

$$A = J_n A^T J_n \quad \text{或} \quad J_n A = A^T J_n.$$

反向对称矩阵的逆

若 A 可逆, 则可得

$$A^{-1} = J_n^{-1} (A^T)^{-1} J_n^{-1} = J_n (A^{-1})^T J_n,$$

即 **反向对称矩阵的逆也是反向对称矩阵.**

Toeplitz 矩阵的逆

Toeplitz 矩阵的逆是反向对称矩阵, 但不一定是 Toeplitz 矩阵.

Yule-Walker 方程组

假定 T_n 对称正定, 考虑线性方程组

$$T_n x = -r_n$$

其中 $r_n = [t_1, t_2, \dots, t_{n-1}, t_n]^T$. 这类线性方程组称为 Yule-Walker 方程组, 其中 t_n 为任意给定的实数.

对角线元素的缩放

由于 T_n 对称正定, 所以 $t_0 > 0$. 因此我们可以对 T_n 的对角线元素进行单位化.

不失一般性, 我们假定 T_n 的对角线元素为 1, 即

$$T_n = \begin{bmatrix} 1 & t_1 & \cdots & t_{n-1} \\ t_1 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & t_1 \\ t_{n-1} & \cdots & t_1 & 1 \end{bmatrix}.$$

由于方程组右端项的特殊性, 我们可以通过 [递推/递归](#) 技巧来求解.

求解 Yule-Walker 方程组的递推方法

记 $T_k x = -r_k$ 的解为 $x^{(k)} \implies$ 假定已经求出

考虑 $T_{k+1} x = -r_{k+1}$, 设解为 $x^{(k+1)} = \begin{bmatrix} z^{(k)} \\ \alpha_k \end{bmatrix}$.

代入后可得递推公式:

$$\alpha_k = \frac{-t_{k+1} - r_k^\top J_k x^{(k)}}{1 + r_k^\top x^{(k)}}, \quad z^{(k)} = x^{(k)} + \alpha_k J_k x^{(k)} \quad k = 1, 2, \dots$$

因此, 可以从一阶 Yule-Walker 方程出发, 利用递推公式计算 $T_n x = -r_n$ 的解.

 思考: 总的运算量 (乘法与加减运算) 大约是多少?

减少运算量 — 递推方法计算分母

引入辅助变量

$$\beta_k \triangleq 1 + r_k^T x^{(k)}, \text{ 则}$$

$$\begin{aligned}\beta_{k+1} &= 1 + r_{k+1}^T x^{(k+1)} \\ &= 1 + [r_k^T, t_{k+1}] \begin{bmatrix} x^{(k)} + \alpha_k J_k x^{(k)} \\ \alpha_k \end{bmatrix} \\ &= 1 + r_k^T x^{(k)} + \alpha_k (t_{k+1} + r_k^T J_k x^{(k)}) \\ &= (1 - \alpha_k^2) \beta_k.\end{aligned}$$

☞ 总运算量降为 $2n^2$.

算法 11 求解 Yule-Walker 方程组的 Durbin 算法

- 1: 输入数据: $t = [t_1, t_2, \dots, t_n]$ % 注: 这里假定 $t_0 = 1$
- 2: $x(1) = -t_1, \beta = 1, \alpha = -t_1$
- 3: **for** for $k = 1$ to $n - 1$ **do**
- 4: $\beta = (1 - \alpha^2)\beta$
- 5: $\alpha = - \left(t_{k+1} - \sum_{i=1}^k t_{k+1-i}x(i) \right) / \beta$
- 6: $x(1 : k) = x(1 : k) + \alpha x(k : -1 : 1)$
- 7: $x(k + 1) = \alpha$
- 8: **end for**

一般右端项的对称正定 Toeplitz 线性方程组

考虑一般右端项的方程组 $T_n x = b$, 其中 T_n 对称正定.

我们仍然利用递推方法来求解: 假定 $x^{(k)}$ 和 $y^{(k)}$ 是下面两个方程组的解

$$T_k x = [b_1, b_2, \dots, b_k]^T,$$

$$T_k y = -[t_1, t_2, \dots, t_k]^T$$

设 $x^{(k+1)} = \begin{bmatrix} z^{(k)} \\ \mu_k \end{bmatrix}$ 是 $T_{k+1} x = b^{(k+1)}$ 的解, 则可得

$$z^{(k)} = x^{(k)} + \mu_k J_k y^{(k)}, \quad \mu_k = \frac{b_{k+1} - r_k^T J_k x^{(k)}}{1 + r_k^T y^{(k)}}$$

Levinson 算法

先计算 $T_k x = b^{(k)}$ 和 $T_k x = -r_k$ 的解, 再得到 $T_{k+1} x = b^{(k+1)}$ 的解.

算法 12 Levinson 算法 (总运算量约 $4n^2$)

- 1: 输入数据: $t = [t_1, t_2, \dots, t_{n-1}]$ 和 $b = [b_1, b_2, \dots, b_n]$ % 假定 $t_0 = 1$
- 2: $y(1) = -t_1, x(1) = b_1, \beta = 1, \alpha = -t_1$
- 3: **for** $k = 1$ to $n - 1$ **do**
- 4: $\beta = (1 - \alpha^2)\beta, \quad \mu = \left(b_{k+1} - \sum_{i=1}^k t_{k+1-i} x(i) \right) / \beta$
- 5: $x(1:k) = x(1:k) + \mu y(k:-1:1), \quad x(k+1) = \mu$
- 6: **if** $k < n - 1$ **then**
- 7: $\alpha = - \left(t_{k+1} + \sum_{i=1}^k t_{k+1-i} y(i) \right) / \beta$
- 8: $y(1:k) = y(1:k) + \alpha y(k:-1:1), \quad y(k+1) = \alpha$
- 9: **end if**
- 10: **end for**

注记

在数学与工程的许多应用中都会出现 Toeplitz 线性方程组.

Levinson 算法是较早出现的快速算法, 但只具有弱稳定性.

方法	运算量	存储量
Fast stable	$\geq 20n^2$	$\geq n^2/2$
Fast but unstable	$\geq 3n^2$	$\geq 4n$
Superfast and “unstable”	$\mathcal{O}(n \log^2 n)$	$\mathcal{O}(n)$
Superfast preconditioner	$\mathcal{O}(n \log n)$	$\mathcal{O}(n)$

- Fast : Levinson-Durbin (1946), Trench (1964), ...
- Fast stable: Bareiss (1969), Chandrasekaran and Sayed (1998), Gu (1998), ...
- Superfast: Brent, Gustavson and Yun (1980), Bitmead and Anderson (1980), Morf (1980), de Hoog (1987), Ammar and Gragg (1988), ...
- Superfast Preconditioners: Strang, Chan, Chan, Tyrtyshnikov, ...

3 | 扰动分析

3.1 矩阵条件数

3.2 扰动方程

3.3 δx 与 \hat{x} 的关系

3.4 δx 与 x_* 的关系

3.5 δx 与残量的关系

3.6 相对扰动分析

3.1 矩阵条件数

例 考虑线性方程组 $Ax = b$, 其中 $A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix}$, $b = [2, 2.0001]^T$, 可求得其解为

$$x = [1, 1]^T$$

如果 b 的第二个元素出现细微的偏差, 变为 $b = [2, 2]^T$, 则解就变为

$$x = [2, 0]^T$$

由此可见, 当右端项出现细微变化时, 解会出现很大的变化, 因此该线性方程组是病态的.

病态与条件数

定义 (病态问题与良态问题) 考虑线性方程组 $Ax = b$, 如果 A 或 b 的微小变化会导致解的巨大变化, 则称此线性方程组是 **病态** 的, 反之则是 **良态** 的.

定义 (矩阵条件数) 设 A 非奇异, $\|\cdot\|$ 是任一算子范数, 则称

$$\kappa(A) \triangleq \|A^{-1}\| \cdot \|A\|$$

为 A 的 **条件数**.

常用的矩阵条件数有



$$\kappa_2(A) \triangleq \|A^{-1}\|_2 \cdot \|A\|_2, \quad \kappa_1(A) \triangleq \|A^{-1}\|_1 \cdot \|A\|_1, \quad \kappa_\infty(A) \triangleq \|A^{-1}\|_\infty \cdot \|A\|_\infty$$

$\kappa_2(A)$ 也称为 **谱条件数**, 当 A 对称时, 有



$$\kappa_2(A) = \frac{\max_{1 \leq i \leq n} |\lambda_i|}{\min_{1 \leq i \leq n} |\lambda_i|}.$$

一般情况下, 如果没有特别指出, 则 $\kappa(A)$ 指的是矩阵 A 的谱条件数.



条件数是衡量一个矩阵是否病态的主要指标. 当矩阵条件数比较大时, 我们就称这个矩阵是 **病态** 的. 如果矩阵是病态的, 则近似解的误差受数据扰动的影响就可能会很大.

例 $A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix} \implies \kappa_2(A) = 4.0002 \times 10^4$

例 **Hilbert 矩阵** 是一个典型的病态矩阵, 其定义如下:

$$H_n = [h_{ij}]_{i,j=1}^n, \quad \text{其中} \quad h_{ij} = \frac{1}{i+j-1}.$$

可以验证 H_n 是对称正定的, 但随着 n 的增长, 其条件数会快速增长:

n	2	4	6	8	10
$\kappa_2(H_n)$	1.9e+01	1.6e+04	1.5e+07	1.5e+10	1.6e+13

3.2 扰动方程

考虑线性方程组

$$Ax = b$$

设 x_* 是精确解, \hat{x} 是通过数值计算得到的近似解.

向后误差分析

假定 \hat{x} 满足线性方程组

$$(A + \delta A)\hat{x} = b + \delta b$$

下面讨论 $\delta x \triangleq \hat{x} - x_*$ 的大小.

3.3 δx 与 \hat{x} 的关系

定理 设 $\|\cdot\|$ 是任一向量范数（当该范数作用在矩阵上时就是相应的导出范数），则 δx 与 \hat{x} 满足下面的关系式

$$\frac{\|\delta x\|}{\|\hat{x}\|} \leq \|A^{-1}\| \cdot \|A\| \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|A\| \cdot \|\hat{x}\|} \right).$$

当 $\delta b = 0$ 时, 有

$$\frac{\|\delta x\|}{\|\hat{x}\|} \leq \kappa(A) \frac{\|\delta A\|}{\|A\|}$$

(板书)

3.4 δx 与 x_* 的关系

引理 设 $\|\cdot\|$ 是任一算子范数, $B \in \mathbb{R}^{n \times n}$. 若 $\|B\| < 1$, 则 $I - B$ 可逆, 且有

$$(I - B)^{-1} = \sum_{k=0}^{\infty} B^k \quad \text{和} \quad \|(I - B)^{-1}\| \leq \frac{1}{1 - \|B\|}.$$

(板书)

定理 设 $A \in \mathbb{R}^{n \times n}$ 非奇异且 $\|A^{-1}\| \cdot \|\delta A\| < 1$, 则

$$\frac{\|\delta x\|}{\|x_*\|} \leq \frac{\kappa(A)}{1 - \kappa(A) \cdot \frac{\|\delta A\|}{\|A\|}} \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right).$$

如果 $\|\delta A\| = 0$, 则

$$\frac{1}{\kappa(A)} \frac{\|\delta b\|}{\|b\|} \leq \frac{\|\delta x\|}{\|x_*\|} \leq \kappa(A) \frac{\|\delta b\|}{\|b\|}$$

(板书)

定理 设 $A \in \mathbb{R}^{n \times n}$ 非奇异, 则有

$$\min \left\{ \frac{\|\delta A\|_2}{\|A\|_2} : A + \delta A \text{ 奇异} \right\} = \frac{1}{\kappa_2(A)}$$

(留作课外自习)

 上述定理中的结论对所有 p -范数都成立.

度量



$$\text{dist}_p(A) \triangleq \min \left\{ \frac{\|\delta A\|_p}{\|A\|_p} : A + \delta A \text{ 奇异} \right\} = \frac{1}{\kappa_p(A)},$$

表示 A 距离奇异矩阵集合的相对距离.

3.5 δx 与残量的关系

记残量 (残差) 为 $r = b - A\hat{x}$, 则有

$$\delta x = \hat{x} - x_* = \hat{x} - A^{-1}b = A^{-1}(A\hat{x} - b) = -A^{-1}r,$$

所以可得

$$\|\delta x\| \leq \|A^{-1}\| \cdot \|r\|$$

实际计算中 r 是可以计算的, 因此比较实用.

3.6 相对扰动分析

前面给出的误差 δx 与条件数 $\kappa(A)$, δA 和 δb 成比例.

许多情况下, 这个界是令人满意的.

但有时相差很大, 不能很好的反映实际计算中解的误差.

例 设 $A = \begin{bmatrix} \gamma & 0 \\ 0 & 1 \end{bmatrix}$, $b = \begin{bmatrix} \gamma \\ 1 \end{bmatrix}$, 其中 $\gamma > 1$. 则 $Ax = b$ 的精确解为 $x_* = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$, 任何合理的直接法求得的解的误差都很小. 但系数矩阵的谱条件数为 $\kappa_2(A) = \gamma$, 当 γ 很大时, $\kappa_2(A)$ 也很大, 因此前面定理中的上界可以是很大.

按分量分析: 记 $\delta A = \begin{bmatrix} \delta a_{11} & \\ & \delta a_{22} \end{bmatrix}$, $\delta b = \begin{bmatrix} \delta b_1 \\ \delta b_2 \end{bmatrix}$, 并设 $|\delta a_{ij}| \leq \varepsilon |a_{ij}|$, $|\delta b_i| \leq \varepsilon |b_i|$. 则

$$\delta x = \begin{bmatrix} \hat{x}_1 - x_1 \\ \hat{x}_2 - x_2 \end{bmatrix} = \begin{bmatrix} \frac{\delta b_1 + b_1}{\delta a_{11} + a_{11}} - 1 \\ \frac{\delta b_2 + b_2}{\delta a_{22} + a_{22}} - 1 \end{bmatrix} = \begin{bmatrix} \frac{\delta b_1 + \gamma}{\delta a_{11} + \gamma} - 1 \\ \frac{\delta b_2 + 1}{\delta a_{22} + 1} - 1 \end{bmatrix} = \begin{bmatrix} \frac{\delta b_1 - \delta a_{11}}{\delta a_{11} + \gamma} \\ \frac{\delta b_2 - \delta a_{22}}{\delta a_{22} + 1} \end{bmatrix}$$

故 $\|\delta x\|_\infty \leq \frac{2\varepsilon}{1-\varepsilon}$. 如果 $\delta b = 0$, 则 $\|\delta x\|_\infty \leq \frac{\varepsilon}{1-\varepsilon}$.

这个界前面定理中的上界相差约 γ 倍.

相对条件数

为了得到更好误差界, 我们引入**相对条件数** $\kappa_{cr}(A)$, 即

$$\kappa_{cr}(A) \triangleq \| |A^{-1}| \cdot |A| \|,$$

有时也称为 **Bauer 条件数** 或 **Skeel 条件数**.

▣ 假定 δA 和 δb 满足 $|\delta A| \leq \varepsilon|A|$ 和 $|\delta b| \leq \varepsilon|b|$. 由 $(A + \delta A)\hat{x} = b + \delta b$ 可得

$$\begin{aligned} |\delta x| &= |A^{-1}(-\delta A\hat{x} + \delta b)| \\ &\leq |A^{-1}| \cdot (|\delta A| \cdot |\hat{x}| + |\delta b|) \\ &\leq |A^{-1}| \cdot (\varepsilon|A| \cdot |\hat{x}| + \varepsilon|b|) \\ &= \varepsilon|A^{-1}| \cdot (|A| \cdot |\hat{x}| + |b|). \end{aligned}$$

若 $\delta b = 0$, 则有

$$\|\delta x\| = \|\delta x\| \leq \varepsilon \| |A^{-1}| \cdot |A| \cdot \|\hat{x}\| \leq \varepsilon \| |A^{-1}| \cdot |A| \| \cdot \|\hat{x}\|,$$

即

$$\frac{\|\delta x\|}{\|\hat{x}\|} \leq \| |A^{-1}| \cdot |A| \| \cdot \varepsilon = \kappa_{cr}(A) \cdot \varepsilon$$

相对条件数有下列的性质

引理 设 $A \in \mathbb{R}^{n \times n}$ 非奇异, $D \in \mathbb{R}^{n \times n}$ 为非奇异对角矩阵, 则

$$\kappa_{cr}(DA) = \kappa_{cr}(A).$$

定理 设 $A \in \mathbb{R}^{n \times n}$ 非奇异. 使得 $|\delta A| \leq \varepsilon|A|$, $|\delta b| \leq \varepsilon|b|$ 成立, 且满足

$$(A + \delta A)\hat{x} = b + \delta b$$

的最小的 $\varepsilon > 0$ 称为按分量的相对向后误差, 其表达式为

$$\varepsilon = \max_{1 \leq i \leq n} \frac{|r_i|}{(|A| \cdot |\hat{x}| + |b|)_i},$$

其中 $r = b - A\hat{x}$.

更多数值计算稳定性和矩阵扰动分析方面的知识, 可参考相关资料.

4 | 误差分析

4.1 LU 分解的舍入误差分析

4.2 Gauss 消去法的舍入误差分析

4.1 LU 分解的舍入误差分析

关于 LU 分解的舍入误差分析, 我们有下面的结果.

定理 假定 $A \in \mathbb{R}^{n \times n}$ 的所有顺序主子式都不为 0, 则带舍入误差的 LU 分解可表示为

$$A = LU + E,$$

其中误差 E 满足

$$|E| \leq \gamma_n |L| \cdot |U|.$$

这里 $\gamma_n = \frac{n\varepsilon_u}{1 - n\varepsilon_u}$, ε_u 表示机器精度.

4.2 Gauss 消去法的舍入误差分析

引理 设 \hat{y} 和 \hat{x} 分别是由向前回代和向后回代得到的数值解, 则

$$(L + \delta L)\hat{y} = b, \quad |\delta L| \leq \gamma_n |L|$$

$$(U + \delta U)\hat{x} = \hat{y}, \quad |\delta U| \leq \gamma_n |U|.$$

该引理表明, 向前回代算法和向后回代算法都是稳定的.

➤ 在绝大多数情况下, 部分选主元 Gauss 消去法是向后稳定的, 但理论上也存在失败的例子.



➤ 全主元 Gauss 消去法是数值稳定的. 在大部分实际应用中, 部分选主元 Gauss 消去法与全主元 Gauss 消去法具有同样的数值稳定性.

5 | 解的改进

5.1 高精度运算

5.2 矩阵元素缩放 (Scaling)

5.3 迭代改进法

5.1 高精度运算

在计算中, 尽可能采用**高精度**的运算.

比如, 原始数据是单精度的, 但在计算时都采用双精度运算, 或者更高精度的运算. 但更高精度的运算会带来更大的开销.

5.2 矩阵元素缩放 (Scaling)

如果 A 的元素在数量级上相差很大, 则在计算过程中很可能会出现大数与小数的加减运算, 这样就可能会引入更多的舍入误差.

为了避免由于这种情况而导致的舍入误差, 我们可以在求解之前先对矩阵元素进行缩放 (Scaling), 即在矩阵两边同时乘以两个适当的对角矩阵.

$$Ax = b \iff D_r^{-1}AD_c^{-1}y = D_r^{-1}b, \quad x = D_c^{-1}y$$

🚩 缩放技术在工程计算时经常会用到.

5.3 迭代改进法

设近似解 \hat{x} , 如果 \hat{x} 没达到精度要求, 可以考虑对其进行修正

$$\tilde{x} = \hat{x} + z,$$

即加上一个向量 z , 得到新的近似解 \tilde{x} .

怎么选取 z

为了使得 \tilde{x} 尽可能地接近真解, 我们希望 \tilde{x} 能满足 $A\tilde{x} = b$, 即

$$A(\hat{x} + z) = b \iff Az = r \quad \rightarrow \text{残量方程}$$

其中 $r = b - A\hat{x}$ 是残量.

在实际计算中, 我们只能得到近似解 \hat{z} , 但 $\|r - A\hat{z}\|$ 会比较小, 特别地, 应该比 $\|r\|$ 更小. 因此 $\hat{x} + \hat{z}$ 应该比 \hat{x} 更接近精确解.

如果新的近似解 $\tilde{x} \triangleq \hat{x} + \hat{z}$ 还不满足精度要求, 则可重复以上过程. 这就是通过迭代来提高解的精度.

算法 13 通过迭代改进解的精度

- 1: 设 $PA = LU$, \hat{x} 是 $Ax = b$ 的近似解
- 2: **while** 近似解 \hat{x} 不满足精度要求, **do**
- 3: 计算 $r = b - A\hat{x}$
- 4: 求解 $Ly = Pr$, 即 $y = L^{-1}Pr$
- 5: 求解 $Uz = y$, 即 $z = U^{-1}y$
- 6: 令 $\hat{x} = \hat{x} + z$
- 7: **end while**

由于每次迭代只需计算一次残量和求解两个三角线性方程组, 因此运算量为 $O(n^2)$. 所以相对来讲还是比较经济的.



为提高计算精度, 在计算残量 r 时最好使用原始数据 A , 因此对 A 做 LU 分解时需要保留矩阵 A , 不能被 L 和 U 覆盖.



实际计算经验表明, 当 A 病态不是很严重时, 即 $\varepsilon_u \kappa_\infty(A) < 1$, 迭代法可以有效改进解的精度, 最后达到机器精度. 这里 ε_u 表示机器精度.

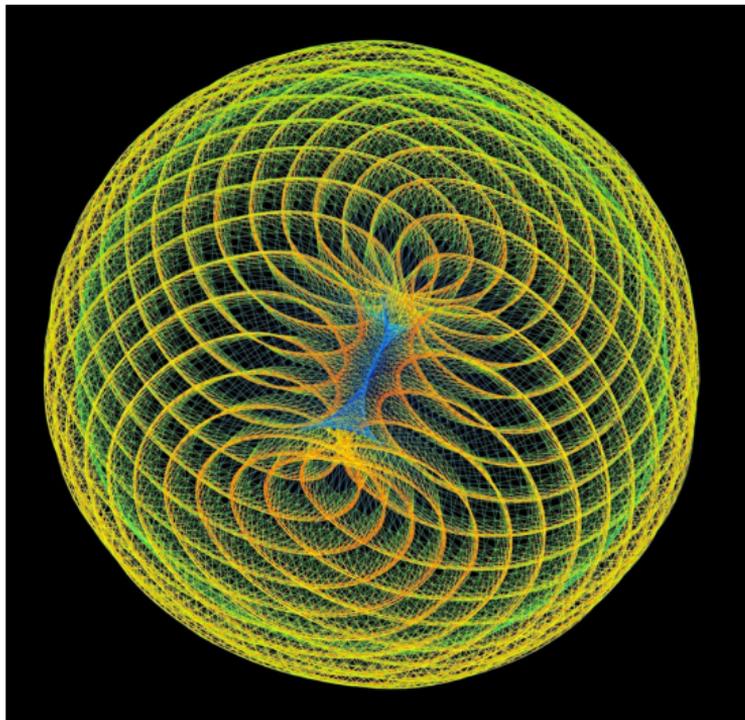
但 $\varepsilon_u \kappa_\infty(A) \geq 1$ 时, 效果可能不佳, 得不到任何改善.

大规模稀疏线性方程组的直接解法

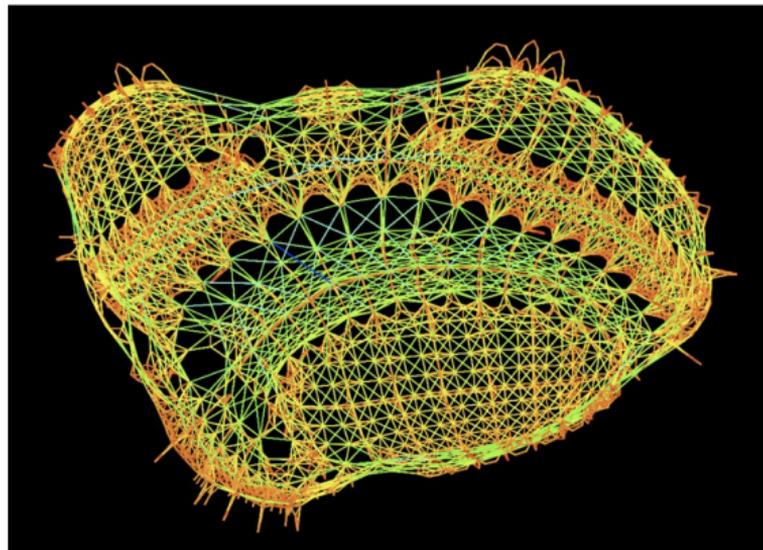
存在的困难

- 规模大, 百万量级以上或以亿为单位.
- LU/Cholesky 分解无法保持充分的稀疏性, 可能出现大量非零元, 导致存储困难, 即存储爆炸, 同时也无法有效降低运算量.

Example sparse matrices from THE SUITESPARSE MATRIX COLLECTION



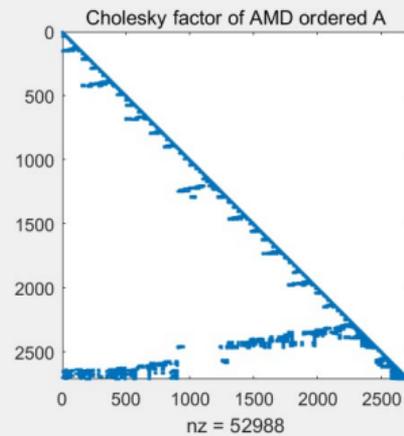
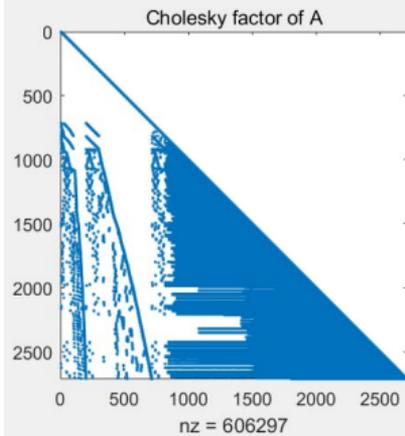
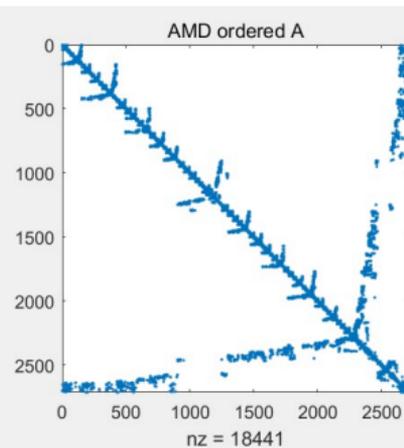
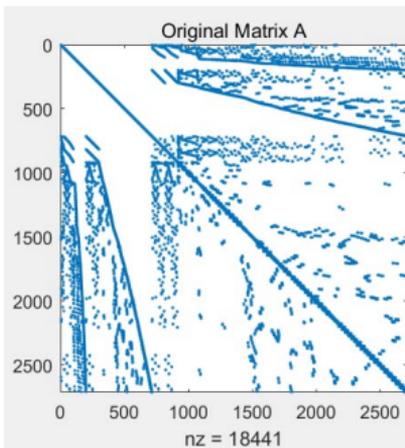
A Barrier Hessian Matrix from Convex Quadratic Programming



The structural loading of an exhibition hall in Beijing

目前的策略

- (1) 对矩阵进行重排序, 使得新矩阵的 LU/Cholesky 分解具有更好的稀疏性.
- (2) 利用稀疏矩阵的重复结构: Supernodal, Frontal, Multifrontal methods
- (3) 并行计算, GPU 加速, 低秩逼近, update/downdate methods



谢谢
THANK YOU

