

第二讲 线性方程组的直接解法

— 扰动分析与解的改进

- 1 扰动分析: 矩阵条件数
- 2 扰动分析: 条件数与病态之间的关系
- 3 解的改进: 高精度运算
- 4 解的改进: 矩阵元素缩放
- 5 解的改进: 迭代改进法

为什么要考虑扰动分析

在实际应用中, 所给的数据可能是通过实验、测量或观察得来的, 因此通常会带有一定的误差, 这些误差不可避免地会对问题的解产生影响.

考虑线性方程组 $Ax = b$, 如果 A 或 b 的微小变化 (也称为 **扰动**) 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.

例 考虑线性方程组 $Ax = b$, 其中 $A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix}$, $b = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$.

$$\implies \text{解为 } x = \begin{bmatrix} 2 \\ 0 \end{bmatrix}.$$

例 考虑线性方程组 $Ax = b$, 其中 $A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix}$, $b = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$.

$$\implies \text{解为 } x = \begin{bmatrix} 2 \\ 0 \end{bmatrix}.$$

☞ 若 b 的第二个元素出现小扰动, 变为 $b = \begin{bmatrix} 2 \\ 2.0001 \end{bmatrix}$, 则解变为 $x = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

例 考虑线性方程组 $Ax = b$, 其中 $A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix}$, $b = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$.

$$\implies \text{解为 } x = \begin{bmatrix} 2 \\ 0 \end{bmatrix}.$$

☞ 若 b 的第二个元素出现小扰动, 变为 $b = \begin{bmatrix} 2 \\ 2.0001 \end{bmatrix}$, 则解变为 $x = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

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.

例 考虑线性方程组 $Ax = b$, 其中 $A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix}$, $b = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$.

$$\implies \text{解为 } x = \begin{bmatrix} 2 \\ 0 \end{bmatrix}.$$

☞ 若 b 的第二个元素出现小扰动, 变为 $b = \begin{bmatrix} 2 \\ 2.0001 \end{bmatrix}$, 则解变为 $x = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$.

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.

怎样判断一个线性方程组是否病态?

对于线性方程组而言, 问题是否变态主要取决于

系数矩阵是否病态

判断一个矩阵是否病态的一个重要指标是

矩阵条件数

矩阵条件数

定义 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

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

例 计算前例中的系数矩阵 A 的条件数 $\kappa_\infty(A)$ 和 $\kappa_2(A)$. $\left(A = \begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix} \right)$

解. 通过直接计算可得 $A^{-1} = \begin{bmatrix} 10001 & -10000 \\ -10000 & 10000 \end{bmatrix}$. 所以

$$\kappa_\infty(A) = \|A\|_\infty \cdot \|A^{-1}\|_\infty \approx 4 \times 10^4.$$

由于 A 是对称的, 且 A 的特征值为

$$\lambda(A) = \frac{2.0001 \pm \sqrt{2.0001^2 - 0.0004}}{2} > 0,$$

所以

$$\kappa_2(A) = \frac{\lambda_{\max}}{\lambda_{\min}} \approx 4 \times 10^4.$$

□

例 已知矩阵

$$A = \begin{bmatrix} 1 & -0.5 & \cdots & -0.5 \\ & 1 & \ddots & \vdots \\ & & \ddots & -0.5 \\ & & & 1 \end{bmatrix} \in \mathbb{R}^{n \times n}.$$

直接计算可知

$$A^{-1} = \begin{bmatrix} 1 & \frac{1}{2} & \frac{1.5}{2} & \frac{1.5^2}{2} & \cdots & \frac{1.5^{n-2}}{2} \\ & 1 & \frac{1}{2} & \frac{1.5}{2} & \ddots & \vdots \\ & & 1 & \ddots & \ddots & \frac{1.5^2}{2} \\ & & & \ddots & \frac{1}{2} & \frac{1.5}{2} \\ & & & & 1 & \frac{1}{2} \\ & & & & & 1 \end{bmatrix}.$$

因此, $\kappa_1(A)$ 和 $\kappa_\infty(A)$ 是矩阵维数 n 的幂函数. 所以, 随着 n 的增大, 条件数增长会非常快.

下表中是 $n = 10, 20, 30, 40, 50$ 时 $\kappa_1(A)$ 和 $\kappa_2(A)$ 的值.

n	10	20	30	40	50
$\kappa_1(A)$	2.1×10^2	2.3×10^4	2.0×10^6	1.5×10^8	1.1×10^{10}
$\kappa_2(A)$	6.3×10	7.6×10^3	6.8×10^5	5.5×10^7	3.9×10^9

下表中是 $n = 10, 20, 30, 40, 50$ 时 $\kappa_1(A)$ 和 $\kappa_2(A)$ 的值.

n	10	20	30	40	50
$\kappa_1(A)$	2.1×10^2	2.3×10^4	2.0×10^6	1.5×10^8	1.1×10^{10}
$\kappa_2(A)$	6.3×10	7.6×10^3	6.8×10^5	5.5×10^7	3.9×10^9

 条件数是矩阵是否病态的一个重要指标, 但两者并不是完全等价的.

矩阵条件数的基本性质

引理 条件数具有以下性质:

- $\kappa(A) \geq 1, \quad \forall A \in \mathbb{R}^{n \times n}.$
- 对任意非零常数 $\alpha \in \mathbb{R}$, 都有

$$\kappa(\alpha A) = \kappa(A).$$

- 对任意正交矩阵 $Q \in \mathbb{R}^{n \times n}$, 有 $\kappa_2(Q) = 1.$
- 设 Q 是正交矩阵, 则对任意矩阵 A 有

$$\kappa_2(QA) = \kappa_2(A) = \kappa_2(AQ).$$

(证明留作练习)

条件数与病态之间的关系

考虑线性方程组 $Ax = b$.

假定系数矩阵 A 是精确的, 而右端项 b 有个微小扰动 δb .

条件数与病态之间的关系

考虑线性方程组 $Ax = b$.

假定系数矩阵 A 是精确的, 而右端项 b 有个微小扰动 δb .

因此我们实际求解的是线性方程组

$$Ax = b + \delta b$$

我们称这个方程组为 **扰动方程组**, 其解记为 \tilde{x} .

(板书)

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算子范数），若 A 是精确的， b 有个小扰动 δb ，则有

$$\frac{\|\delta x\|}{\|x_*\|} \leq \|A^{-1}\| \cdot \|A\| \cdot \frac{\|\delta b\|}{\|b\|}.$$

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算子范数），若 A 是精确的， b 有个小扰动 δb ，则有

$$\frac{\|\delta x\|}{\|x_*\|} \leq \|A^{-1}\| \cdot \|A\| \cdot \frac{\|\delta b\|}{\|b\|}.$$

该结论表明，由于右端项的扰动而产生的解的相对误差，大约被放大了 $\|A^{-1}\| \cdot \|A\|$ 倍。这个倍数正好是系数矩阵的 **条件数**。

需要指出的是，这是最坏的情况。

A 也有微小扰动的情形

扰动方程组为

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

A 也有微小扰动的情形

扰动方程组为

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

假定 $\|\delta A\|$ 很小, 满足 $\|A^{-1}\| \cdot \|\delta A\| < 1$, 则 $\|A^{-1}\delta A\| \leq \|A^{-1}\| \cdot \|\delta A\| < 1$. 因此 $I + A^{-1}\delta A$ 非奇异, 所以 $A + \delta A = A(I + A^{-1}\delta A)$ 也非奇异.

(板书)

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算子范数），假定 $\|A^{-1}\| \cdot \|\delta A\| < 1$ ，则有

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

当 $\delta b = 0$ 时，有

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

δx 与 \tilde{x} 之间的关系

由于 x_* 通常是未知的, 因此一个更加实际的情况是考虑 δx 与 \tilde{x} 之间的关系.

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算子范数), 则 δx 与 \tilde{x} 满足下面的关系式

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

当 $\delta b = 0$ 时, 有

$$\frac{\|\delta x\|}{\|\tilde{x}\|} \leq \kappa(A) \frac{\|\delta A\|}{\|A\|} \quad (2.1)$$

(板书)

δx 与 残量 之间的关系

上面的结论具有理论指导作用, 但如果无法获得 δA 和 δb 的大小, 则很难用来估计 δx 的大小. 此时, 我们可以通过残量来估计.

δx 与残量之间的关系

上面的结论具有理论指导作用, 但如果无法获得 δA 和 δb 的大小, 则很难用来估计 δx 的大小. 此时, 我们可以通过残量来估计.

记残量 (残差, residual) 为 $r \triangleq b - A\tilde{x}$, 则有

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

所以可得

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

这个估计式的优点是不需要知道 δA 和 δb 的大小. 而且在实际计算中, r 通常是可计算的, 因此该估计式比较实用.

例 Hilbert 矩阵是一个典型的病态矩阵, 其定义如下

$$H_n = \begin{bmatrix} 1 & \frac{1}{2} & \cdots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{n+1} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \cdots & \frac{1}{2n-1} \end{bmatrix}, \quad \text{即} \quad H_n = [h_{ij}], \quad h_{ij} = \frac{1}{i+j-1}, \quad i, j = 1, 2, \dots, n.$$

可以验证 H_n 是对称正定的. 通过计算可知

$$\kappa_\infty(H_2) = 27, \quad \kappa_\infty(H_3) = 748, \quad \kappa_\infty(H_4) = 28375, \quad \kappa_\infty(H_{10}) \approx 3.5 \times 10^{13}.$$

(% 讲义上有笔误)

考虑线性方程组

$$H_n x = b,$$

设精确解为 $x_* = [1, 1, \dots, 1]^T$, 计算出右端项 b , 然后用 Cholesky 分解求解该线性方程组, 求得的近似解记为 \tilde{x} .

考虑线性方程组

$$H_n x = b,$$

设精确解为 $x_* = [1, 1, \dots, 1]^T$, 计算出右端项 b , 然后用 Cholesky 分解求解该线性方程组, 求得的近似解记为 \tilde{x} .

对于不同的 n , 下表中列出了近似解的误差.

n	5	10	20	30
$\ \tilde{x} - x_*\ _\infty$	2.3×10^{-11}	6.2×10^{-4}	> 7.8	> 42.8
$\kappa_\infty(H_n)$	9.4×10^5	3.5×10^{13}	$> 10^{19}$	$> 10^{19}$

由此可知, 当 $n \geq 20$ 时, Cholesky 分解计算出来的近似解已经没有任何意义了.

解的改进 *

当矩阵 A 是病态时, 即使残量 $r = b - A\tilde{x}$ 很小, 所求得的数值解 \tilde{x} 仍可能带有较大的误差. 此时需要通过一些方法来提高解的精度.

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.

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**.

例 考虑线性方程组

$$\begin{bmatrix} -4000 & 2000 & 2000 \\ 2000 & 0.78125 & 0 \\ 2000 & 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 400 \\ 1.3816 \\ 1.9273 \end{bmatrix}.$$

用部分选主元 Gauss 消去法求解, 计算过程中保留 8 位有效数字, 求得的数值解为

$$\tilde{x} = [0.00096365, -0.698496, 0.90042329]^T.$$

例 考虑线性方程组

$$\begin{bmatrix} -4000 & 2000 & 2000 \\ 2000 & 0.78125 & 0 \\ 2000 & 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 400 \\ 1.3816 \\ 1.9273 \end{bmatrix}.$$

用部分选主元 Gauss 消去法求解, 计算过程中保留 8 位有效数字, 求得的数值解为

$$\tilde{x} = [0.00096365, -0.698496, 0.90042329]^T.$$

而精确解为 $x = [1.9273\dots, -0.698496\dots, 0.9004233\dots]^T$.

例 考虑线性方程组

$$\begin{bmatrix} -4000 & 2000 & 2000 \\ 2000 & 0.78125 & 0 \\ 2000 & 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 400 \\ 1.3816 \\ 1.9273 \end{bmatrix}.$$

用部分选主元 Gauss 消去法求解, 计算过程中保留 8 位有效数字, 求得的数值解为

$$\tilde{x} = [0.00096365, -0.698496, 0.90042329]^T.$$

而精确解为 $x = [1.9273\dots, -0.698496\dots, 0.9004233\dots]^T$.

改进措施: 对矩阵元素进行缩放, 两边同乘一个对角矩阵 $D = \text{diag}(0.00005, 1, 1)$:

$$DADy = Db.$$

最后令 $\tilde{x} = Dy$, 即可求得比较精确的数值解.

迭代改进法

设近似解 \tilde{x} , 残量 $r = b - A\tilde{x}$.

基本思想: 构造修正向量 z 使得 $\tilde{x} + z$ 是原问题的精确解, 即

$$A(\tilde{x} + z) = b$$

也就是说, 向量 z 满足方程组

$$Az = b - A\tilde{x} = r.$$

这就是 **残量方程** (右端项是残量).

求得近似解 \tilde{z} , 得到新的近似解 $\tilde{x} + \tilde{z}$.

如果还不满足精度要求, 则可重复以上过程.

算法 2.1 迭代改进法

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

额外的运算量约为 $\mathcal{O}(n^2)$, 所以相对来讲还是比较经济的.

算法 2.2 迭代改进法

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

额外的运算量约为 $\mathcal{O}(n^2)$, 所以相对来讲还是比较经济的.

- 为了提高计算精度, 在计算残量 r 时最好使用原始数据 A , 而不是 $P^T LU$, 因此对 A 做 PLU 分解时需要保留原矩阵 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. 但 $\varepsilon_u \kappa_\infty(A) \geq 1$ 时, 一般没什么效果.