

第三章 线性方程

第 (3) 部分：误差分析

目录

1. 问题背景
2. 线代 (1): 特征值和特征向量
3. 线代 (2): 矩阵的范数
4. 线代 (3): 谱半径
5. 矩阵的条件数和误差分析
6. 总结

问题背景

解 $\mathbf{Ax} = \mathbf{b}$ 时，实际在计算机中存储的 \mathbf{A} 和 \mathbf{b} 未必是真实值。

误差的可能来源：

- ▶ \mathbf{A} 和 \mathbf{b} 中可能带有实验测量造成的误差
- ▶ 计算机存储时，有效数字造成的浮点精度误差
- ▶ ...

我们这一部分探究的核心问题是：误差如何影响真解。

假设真实的方程组是

$$\mathbf{Ax} = \mathbf{b}$$

而我们实际在计算机里解的方程是

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

我们假设误差 $\delta\mathbf{A}$ (或 $\delta\mathbf{b}$) 相对于 \mathbf{A} (或 \mathbf{b}) 很小, 我们希望量化

$$\frac{\text{解的相对误差}}{\text{输入来源的相对误差}} = \frac{\|\tilde{\mathbf{x}} - \mathbf{x}\|/\|\mathbf{x}\|}{\|\delta\mathbf{A}\|/\|\mathbf{A}\| \text{ 或 } \|\delta\mathbf{b}\|/\|\mathbf{b}\|}$$

为实现这个目标, 需要引入一个概念叫做向量和矩阵的“大小”; 这一概念类似于实数的绝对值。

例子 → 现象

我们考虑如下的方程

$$\begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$

其精确解为 $\mathbf{x} = [2 \ 0]^T$

而若我们考虑

$$\begin{bmatrix} 1 & 1 \\ 1 & 1.0001 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 2.0001 \end{bmatrix}$$

得到的解为 $\mathbf{x} = [1 \ 1]^T$

问题：此处我们的计算没有任何的误差，那么为什么会差那么多呢？

现象 → 定义

定义 (定义 7.7)

如果矩阵 \mathbf{A} 或常数项 \mathbf{b} 的微小变化, 引起方程组 $\mathbf{Ax} = \mathbf{b}$ 解的巨大变化, 则称此方程组为**病态方程组**, 矩阵 \mathbf{A} 称为**病态矩阵** (相对于方程组而言), 否则称方程组为**良态方程组**, \mathbf{A} 称为**良态矩阵**。

注: 病态与否是问题本身的问题, 与算法无关。

目标: 理解病态是什么意思, 以及如何使用一个量化工具来刻画它。

目标

我们首先需要回顾和了解三个概念：

- ▶ 特征值和特征向量
- ▶ 矩阵范数
- ▶ 谱半径

然后我们会引入条件数这一概念和量化误差

目录

1. 问题背景
2. 线代 (1): 特征值和特征向量
3. 线代 (2): 矩阵的范数
4. 线代 (3): 谱半径
5. 矩阵的条件数和误差分析
6. 总结

特征值和特征向量

定义 (特征值和特征向量)

- (1) 已知 $\mathbf{A} = (a_{ij})_{n \times n}$, 要求代数方程 $\varphi(\lambda) = \det(\lambda I - \mathbf{A}) = 0$ 的根。 $\varphi(\lambda)$ 称为 \mathbf{A} 的特征多项式。该式子展开即有

$$\varphi(\lambda) = \lambda^n + c_1 \lambda^{n-1} + \cdots + c_n = 0$$

一般 $\varphi(\lambda)$ 有 n 个零点, 称为 \mathbf{A} 的特征值。

- (2) 设 λ 为 \mathbf{A} 的特征值, 要求 $\mathbf{A}\mathbf{x} = \lambda\mathbf{x}$ 的非零解。对应的 \mathbf{x} 被称为特征向量。

回顾练习：请计算特征值和特征向量 $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}$

定理

如果 $\lambda_i (i = 1, 2, \dots, n)$ 是矩阵 \mathbf{A} 的特征值, 则有

- ▶ $\sum_{i=1}^n \lambda_i = \sum_{i=1}^n a_{ii} = \text{tr } \mathbf{A}$;
- ▶ $\det \mathbf{A} = \lambda_1 \lambda_2 \cdots \lambda_n$

课外练习: 请验证

$$\det(\mathbf{A} - \lambda \mathbf{I}) = (-1)^n (\lambda^n - \text{tr}(\mathbf{A})\lambda^{n-1} + \cdots + (-1)^n \det(\mathbf{A}))$$

定理 (定理 9.2; 考虑相似矩阵)

设 \mathbf{A} 与 \mathbf{B} 为相似矩阵 (即存在非奇异阵 \mathbf{T} 使 $\mathbf{B} = \mathbf{T}^{-1}\mathbf{A}\mathbf{T}$), 则

- ▶ \mathbf{A} 与 \mathbf{B} 有相同的特征值;
- ▶ 若 \mathbf{x} 是 \mathbf{B} 的一个特征向量, 则 $\mathbf{T}\mathbf{x}$ 是 \mathbf{A} 的特征向量。

定理 (考虑对称矩阵)

- ▶ 若 \mathbf{A} 为实对称矩阵, 存在互相垂直的向量 u_1, u_2, \dots, u_n 使得 $\mathbf{A}u_i = \lambda_i u_i$, 其中特征向量 $\lambda_i \in \mathbb{R}$ 是实数。

- ▶ 并且若 \mathbf{A}^{-1} 存在 (即若任何特征值皆非零 $\lambda_i \neq 0$), 则 $\mathbf{A}^{-1}u_i = \frac{1}{\lambda_i}u_i$,

即 \mathbf{A}^{-1} 具有特征值 $1/\lambda_i$ 和特征向量 u_i 。

对于向量 \mathbf{x} , $R(\mathbf{x}) = \frac{(\mathbf{A}\mathbf{x}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})}$ 被称为 Rayleigh 商。

问题: 这个量有什么几何含义? 假设我们考虑 \mathbf{x} 是单位向量。

练习：我们考虑 $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}$, $\mathbf{x} = \begin{bmatrix} r \cos(\theta) \\ r \sin(\theta) \end{bmatrix}$

- ▶ 模长 r 对于计算 Rayleigh 商重要吗?
- ▶ 请直接计算 $\min_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \neq 0}} R(\mathbf{x})$ 和 $\max_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \neq 0}} R(\mathbf{x})$, 这里 $n = 2$ 。
- ▶ \mathbf{x} 什么时候使得 $R(\mathbf{x})$ 能取到最小值? \mathbf{x} 什么时候使得 $R(\mathbf{x})$ 能取到最大值? 这些极值和特征值有什么关系?

定理 (定理 9.4)

设 $\mathbf{A} \in \mathbb{R}^{n \times n}$ 为对称矩阵 (其特征值次序记作 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n$, 对应的特征向量 u_1, u_2, \cdots, u_n 组成规范化正交组, 即 $(u_i, u_j) = \delta_{ij}$), 则

▶ 对于任何非零 $\mathbf{x} \in \mathbb{R}^n$:

$$\lambda_n \leq \frac{(\mathbf{Ax}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})} \leq \lambda_1 \quad (1)$$

▶ *Rayleigh* 商的极值分别是最大和最小的特征值:

$$\lambda_1 = \max_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \neq 0}} \frac{(\mathbf{Ax}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})} \quad \lambda_n = \min_{\substack{\mathbf{x} \in \mathbb{R}^n \\ \mathbf{x} \neq 0}} \frac{(\mathbf{Ax}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})}.$$

目录

1. 问题背景
2. 线代 (1): 特征值和特征向量
3. 线代 (2): 矩阵的范数
4. 线代 (3): 谱半径
5. 矩阵的条件数和误差分析
6. 总结

向量的范数

我们先考虑一下向量的范数：

对于一个向量 $\mathbf{x} = [x_1, x_2, \dots, x_n]$

- ▶ 数量积 $(\mathbf{x}, \mathbf{y}) = \sum_i x_i y_i$ (是使用尖括号还是圆括号都可以)
- ▶ $\|\mathbf{x}\|_2 = (\mathbf{x}, \mathbf{x})^{1/2} = (\sum_i x_i^2)^{1/2}$ 为范数 (模)

性质：

- ▶ $(\mathbf{x}, \mathbf{y}) = (\mathbf{y}, \mathbf{x})$
- ▶ Cauchy-Schwarz 不等式: $|(\mathbf{x}, \mathbf{y})| \leq \|\mathbf{x}\|_2 \|\mathbf{y}\|_2$
- ▶ 三角不等式: $\|\mathbf{x} + \mathbf{y}\|_2 \leq \|\mathbf{x}\|_2 + \|\mathbf{y}\|_2$

把范数中下标 2 改为任何的 $p \in [1, \infty)$:

$$\|\mathbf{x}\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} \quad p\text{-范数}$$

例子: $\mathbf{x} = [1, 3]$, 请计算 $\|\mathbf{x}\|_5$, $\|\mathbf{x}\|_{10}$, $\|\mathbf{x}\|_{20}$, 你有什么发现?

把范数中下标 2 改为任何的 $p \in [1, \infty)$:

$$\|\mathbf{x}\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} \quad p\text{-范数}$$

例子: $\mathbf{x} = [1, 3]$, 请计算 $\|\mathbf{x}\|_5$, $\|\mathbf{x}\|_{10}$, $\|\mathbf{x}\|_{20}$, 你有什么发现?

答案: 对于这个例子, 当 $p \rightarrow \infty$, $\|\mathbf{x}\|_p \rightarrow 3$

把范数中下标 2 改为任何的 $p \in [1, \infty)$:

$$\|\mathbf{x}\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p} \quad p\text{-范数}$$

例子: $\mathbf{x} = [1, 3]$, 请计算 $\|\mathbf{x}\|_5$, $\|\mathbf{x}\|_{10}$, $\|\mathbf{x}\|_{20}$, 你有什么发现?

答案: 对于这个例子, 当 $p \rightarrow \infty$, $\|\mathbf{x}\|_p \rightarrow 3$

更一般的, 当 $p \rightarrow \infty$,

$$\lim_{p \rightarrow \infty} \|\mathbf{x}\|_p \stackrel{\text{现象/结论}}{=} \max_i |x_i| \stackrel{\text{定义为}}{=} \|\mathbf{x}\|_\infty$$

$\|\cdot\|$ 是一个函数：输入是一个向量 \mathbf{x} ，输出 $\|\mathbf{x}\|$ 是一个非负实数。

定义 (向量的范数)

我们说它是一个范数如果它满足如下条件：

- ▶ $\|\mathbf{x}\| \geq 0$ ($\|\mathbf{x}\| = 0$ 当且仅当 $\mathbf{x} = 0$)
- ▶ $\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|$ 对于任何一个实数 α
- ▶ $\|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|$

我们使用下标来注明这个范数是什么意义下的。

该量本质是用来描述向量的大小。

对于有限维空间，向量范数具有**连续性**（定理 7.11）和**等价性**（定理 7.12）。

矩阵的范数

对于这样的矩阵

$$\mathbf{A} = \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & & \vdots \\ \vdots & & \vdots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix}$$

目的：是找一个概念来定义矩阵的大小。

我们希望该概念满足一些好的性质：

- ▶ $\|\mathbf{A}\| \geq 0$ （其中 $\|\mathbf{A}\| = 0$ 当且仅当 $\mathbf{A} = 0$ ）（正定条件）
- ▶ $\|c\mathbf{A}\| = |c|\|\mathbf{A}\|$ （齐次条件）
- ▶ $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ （三角不等式）
- ▶ $\|\mathbf{AB}\| \leq \|\mathbf{A}\|\|\mathbf{B}\|$

例 (Frobenius 范数)

视角 1: 把矩阵看成是一个 n^2 维的向量: $F(\mathbf{A}) = \|\mathbf{A}\|_F = \left(\sum_{i,j=1}^n a_{ij}^2\right)^{1/2}$

例 (算子范数)

视角 2: 把矩阵看成是作用在向量上的一个变换:

$$\|\mathbf{A}\|_v := \max_{\mathbf{x} \neq 0} \frac{\|\mathbf{Ax}\|_v}{\|\mathbf{x}\|_v} \quad (2)$$

由于该定义, 我们可知 $\|\mathbf{Ax}\|_v \leq \|\mathbf{A}\|_v \|\mathbf{x}\|_v$; 且我们可以证明 $\|\cdot\|_v$ 是一个合适的矩阵范数。

练习: 请根据定义来证明

$$\|\mathbf{AB}\|_v \leq \|\mathbf{A}\|_v \|\mathbf{B}\|_v \quad (3)$$

矩阵

假设我们考虑 $\mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & 2 \end{bmatrix}$, $\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$.

$$\|\mathbf{Ax}\|_2 = \sqrt{x_1^2 + (2x_2)^2}, \quad \|\mathbf{x}\|_2 = \sqrt{x_1^2 + x_2^2}$$

因此

$$\|\mathbf{A}\|_2 = \max_{\mathbf{x} \neq 0} \frac{\|\mathbf{Ax}\|_2}{\|\mathbf{x}\|_2} = \max_{\mathbf{x} \neq 0} \frac{\sqrt{x_1^2 + 4x_2^2}}{\sqrt{x_1^2 + x_2^2}} \leq \max_{\mathbf{x} \neq 0} \frac{\sqrt{4x_1^2 + 4x_2^2}}{\sqrt{x_1^2 + x_2^2}} = 2.$$

练习题：计算 $\|\mathbf{A}\|_\infty$

定理 (定理 7.15)

我们考虑任意的矩阵 $\mathbf{A} \in \mathbb{R}^{n \times n}$, 我们有如下的结论:

$$\begin{aligned} 1^\circ \quad \|\mathbf{A}\|_1 &= \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \quad (\mathbf{A} \text{ 的列范数}) \\ 2^\circ \quad \|\mathbf{A}\|_2 &= \sqrt{\lambda_{\max}(\mathbf{A}^T \mathbf{A})} \quad (\mathbf{A} \text{ 的2范数}) \\ 3^\circ \quad \|\mathbf{A}\|_\infty &= \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| \quad (\mathbf{A} \text{ 的行范数}) \end{aligned} \tag{4}$$

(具体的证明请见课本或课内。)

不同范数的优势是什么？

$\|\cdot\|_\infty$ 和 $\|\cdot\|_1$ 在实际中比较容易算

$\|\cdot\|_2$ 具有很高的理论价值

定理

- ▶ $\mathbf{A}\mathbf{A}^\top$ 和 $\mathbf{A}^\top\mathbf{A}$ 有同样的特征值 (课后作业第 26 题)
- ▶ $\|\mathbf{A}\|_2 = \|\mathbf{A}^\top\|_2$
- ▶ 若 \mathbf{A}^{-1} 存在, 则

$$\|\mathbf{A}^{-1}\|_2 = \frac{1}{\sqrt{\lambda_{\min}(\mathbf{A}\mathbf{A}^\top)}} \equiv \frac{1}{\sqrt{\lambda_{\min}(\mathbf{A}^\top\mathbf{A})}} \quad (5)$$

证明.

结论一: $\mathbf{A}\mathbf{A}^\top u = \lambda u$ 令 $v = \mathbf{A}^\top u$ 则 $\mathbf{A}^\top\mathbf{A}v = \mathbf{A}^\top\mathbf{A}\mathbf{A}^\top u = \mathbf{A}^\top\lambda u = \lambda v$.

结论二可由结论一和 2 范数的公式(4)得到。

对于结论三,

$$\|\mathbf{A}^{-1}\|_2 \stackrel{\text{公式(4)}}{=} \sqrt{\lambda_{\max}((\mathbf{A}^{-1})^\top\mathbf{A}^{-1})} = \sqrt{\lambda_{\max}((\mathbf{A}\mathbf{A}^\top)^{-1})} = 1/\sqrt{\lambda_{\min}(\mathbf{A}\mathbf{A}^\top)}$$

序列的收敛

实数的收敛：实数序列 $\{x_n\} \subset \mathbb{R}$ 收敛于 x^* 的意思是 $\lim_{n \rightarrow \infty} |x_n - x^*| = 0$

向量的收敛：向量序列 $\{\mathbf{x}_n\} \subset \mathbb{R}^n$ 收敛于 \mathbf{x}^* 的意思是

$$\lim_{n \rightarrow \infty} \|\mathbf{x}_n - \mathbf{x}^*\| = 0$$

(此处选择不同的范数，对于收敛现象无区别，但是范数值还是有区别的)

矩阵的收敛：矩阵序列 $\{\mathbf{A}_n\} \subset \mathbb{R}^{n \times n}$ 收敛于 \mathbf{A}^* 的意思是

$$\lim_{n \rightarrow \infty} \|\mathbf{A}_n - \mathbf{A}^*\| = 0$$

(此处选择不同的范数，对于收敛现象无区别，但是范数值还是有区别的)

目录

1. 问题背景
2. 线代 (1): 特征值和特征向量
3. 线代 (2): 矩阵的范数
4. 线代 (3): 谱半径
5. 矩阵的条件数和误差分析
6. 总结

谱半径

定义 (谱半径)

设 \mathbf{A} 的特征值为 λ_i ($i = 1, 2, \dots, n$), 我们称

$$\rho(\mathbf{A}) \stackrel{\text{定义}}{=} \max_{1 \leq i \leq n} |\lambda_i| \text{ 为 } \mathbf{A} \text{ 的谱半径}$$

定理 (特征值上界)

假设 \mathbf{A} 是 n 阶实矩阵, 则 $\rho(\mathbf{A}) \leq \|\mathbf{A}\|$, 即 \mathbf{A} 的谱半径不超过 \mathbf{A} 的任何一种算子范数。

定理

若 \mathbf{A} 为对称矩阵, 则 $\|\mathbf{A}\|_2 = \rho(\mathbf{A})$ 。(证明: 作业题)

目录

1. 问题背景
2. 线代 (1): 特征值和特征向量
3. 线代 (2): 矩阵的范数
4. 线代 (3): 谱半径
5. 矩阵的条件数和误差分析
6. 总结

情景 1: A 是精确的, b 有误差

定理 (定理 7. 19)

设 A 是非奇异阵, $Ax = b \neq 0$, 且 $A(x + \delta x) = b + \delta b$, 则

$$\underbrace{\frac{\|\delta x\|}{\|x\|}}_{\text{输出误差的相对误差}} \leq \underbrace{\|A^{-1}\| \|A\|}_{\text{误差放大的倍数上界}} \underbrace{\frac{\|\delta b\|}{\|b\|}}_{\text{输入误差的相对误差}}$$

(证明: 参见课本或课内)

定理

若 $\|B\| < 1$ ，则 $I \pm B$ 为非奇异矩阵，且 $\|(I \pm B)^{-1}\| \leq \frac{1}{1 - \|B\|}$ 。其中 $\|\cdot\|$ 可以是任何一种算子范数。

情景 2: b 是精确的, A 有误差

定理 (定理 7.20)

设 A 是非奇异阵, $Ax = b \neq 0$, 且 $(A + \delta A)(x + \delta x) = b$ 。若 $\|A^{-1}\| \|\delta A\| < 1$, 则

$$\underbrace{\frac{\|\delta x\|}{\|x\|}}_{\text{输出误差的相对误差}} \leq \frac{\|A^{-1}\| \|A\| \frac{\|\delta A\|}{\|A\|}}{1 - \|A^{-1}\| \|A\| \frac{\|\delta A\|}{\|A\|}}$$

输出误差的相对误差

定义 (定义 7.8)

设 \mathbf{A} 为非奇异矩阵, 称数 $\text{cond}(\mathbf{A})_v = \|\mathbf{A}^{-1}\|_v \|\mathbf{A}\|_v$ ($v \in [1, \infty]$) 为矩阵 \mathbf{A} 的条件数。

由前面的两个结论可知, 条件数可以作为衡量病态程度的指标。

条件数小 (良态) \longrightarrow 条件数大 (病态)

常用的两种:

- (1) $\text{cond}(\mathbf{A})_\infty := \|\mathbf{A}^{-1}\|_\infty \|\mathbf{A}\|_\infty$
- (2) 谱条件数

$$\text{cond}(\mathbf{A})_2 := \|\mathbf{A}\|_2 \|\mathbf{A}^{-1}\|_2 = \sqrt{\frac{\lambda_{\max}(\mathbf{A}^\top \mathbf{A})}{\lambda_{\min}(\mathbf{A}^\top \mathbf{A})}} \quad (6)$$

证明: 请参考 PPT 内的公式(4)和(5)

条件数的性质

定理

条件数有如下性质:

- (1) 对任何非奇异矩阵 \mathbf{A} , 都有 $\text{cond}(\mathbf{A})_v \geq 1$ 。
- (2) 设 \mathbf{A} 为非奇异矩阵, c 为不等于零的常数, 则 $\text{cond}(c\mathbf{A})_v = \text{cond}(\mathbf{A})_v$ 。
- (3) 如果 \mathbf{A} 为正交矩阵*, 则 $\text{cond}(\mathbf{A})_2 = 1$ 。†
- (4) 如果 \mathbf{A} 为非奇异矩阵, \mathbf{R} 为正交矩阵, 则

$$\text{cond}(\mathbf{R}\mathbf{A})_2 = \text{cond}(\mathbf{A}\mathbf{R})_2 = \text{cond}(\mathbf{A})_2$$

* 若 \mathbf{A} 满足 $\mathbf{A}\mathbf{A}^T = \mathbf{I}$, 则称 \mathbf{A} 为正交矩阵

† 证明: 使用公式(6)

应用：Hilbert 矩阵是病态的

预告：

后面章节会介绍高维 Hilbert 矩阵的条件数过大（不稳定） \implies 正交多项式在计算时的重要性！

$$\mathbf{H}_n = \begin{pmatrix} \frac{1}{1} & \frac{1}{2} & \cdots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{n+1} \\ \vdots & \vdots & \cdots & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \cdots & \frac{1}{2n-1} \end{pmatrix}$$

$$\text{cond}(\mathbf{H}_3)_\infty \approx 748$$

$$\text{cond}(\mathbf{H}_6)_\infty \approx 3 \times 10^6$$

实际中如何判断问题是否病态

- ▶ 三角约化时出现小主元
- ▶ 最大特征值和最小特征值的比值（按照绝对值）过大
- ▶ 系数矩阵的行列式过小，或者系数矩阵的某些行线性相关性比较大
- ▶ 元素间的数量级相差很大，且无规律

则 \mathbf{A} 有很大的概率是病态的矩阵。

定理 (定理 7.21, 事后误差估计)

假设

- ▶ \mathbf{A} 为非奇异矩阵, \mathbf{x} 是精确解, $\mathbf{Ax} = \mathbf{b} \neq \mathbf{0}$;
- ▶ 设 $\bar{\mathbf{x}}$ 是方程组的近似解, 定义残差 $\mathbf{r} = \mathbf{b} - \mathbf{A}\bar{\mathbf{x}}$ 。

则

$$\frac{\|\mathbf{x} - \bar{\mathbf{x}}\|}{\|\mathbf{x}\|} \leq \text{cond}(\mathbf{A}) \cdot \frac{\|\mathbf{r}\|}{\|\mathbf{b}\|}$$

提示:

- ▶ 条件数如果比较大, 则上述估计很难有用;
- ▶ 若条件数比较小, 则残差的大小可以控制方程组解的误差。

目录

1. 问题背景
2. 线代 (1): 特征值和特征向量
3. 线代 (2): 矩阵的范数
4. 线代 (3): 谱半径
5. 矩阵的条件数和误差分析
6. 总结

重点知识总结

- ▶ 病态方程组和病态矩阵的含义
- ▶ Rayleigh 商的定义、计算、以及它和特征值的关系
- ▶ 向量和矩阵范数的定义、性质等；重点需要掌握算子范数
- ▶ 谱半径的定义和性质
- ▶ 对于矩阵误差分析的三个定理
(对应课本里的定理 7.19、定理 7.20、定理 7.21)
- ▶ 条件数的定义、计算和性质