

5.3 向量和矩阵的范数

朱升峰

华东师范大学 数学科学学院

2022 年 11 月

目录

- 向量范数
- 矩阵范数

向量范数

为研究线性方程组近似解的误差估计和迭代法的收敛性, 对 \mathbb{R}^n 中向量 (或 $\mathbb{R}^{n \times n}$ 中矩阵) 的“大小” 引进某种度量——向量 (或矩阵) 范数的概念. 向量范数的概念是二维、三维欧氏空间中向量长度的推广.

首先将向量长度概念推广到 \mathbb{R}^n (或 \mathbb{C}^n) 中

定义 1

设 $\boldsymbol{x} = (x_1, x_2, \dots, x_n)^T$, $\boldsymbol{y} = (y_1, y_2, \dots, y_n)^T \in \mathbb{R}^n$ (或 \mathbb{C}^n). 将实数 $(\boldsymbol{x}, \boldsymbol{y}) = \boldsymbol{y}^T \boldsymbol{x} = \sum_{i=1}^n x_i y_i$ (或复数 $(\boldsymbol{x}, \boldsymbol{y}) = \boldsymbol{y}^H \boldsymbol{x} = \sum_{i=1}^n x_i \bar{y}_i$) 称为向量 $\boldsymbol{x}, \boldsymbol{y}$ 的数量积. 将非负实数 $\|\boldsymbol{x}\|_2 = (\boldsymbol{x}, \boldsymbol{x})^{\frac{1}{2}} = \left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}}$ (或 $\|\boldsymbol{x}\|_2 = (\boldsymbol{x}, \boldsymbol{x})^{\frac{1}{2}} = \left(\sum_{i=1}^n |x_i|^2 \right)^{\frac{1}{2}}$) 称为向量 \boldsymbol{x} 的欧氏范数.

下述定理可在线性代数书中找到.

定理 2

设 $x, y \in \mathbb{R}^n$ (或 \mathbb{C}^n), 则

- (1) $(x, x) \geq 0$, 等号当且仅当 $x = 0$ 时成立;
- (2) $(\alpha x, y) = \alpha(x, y)$, α 为实数 (或 $(x, \alpha y) = \bar{\alpha}(x, y)$, α 为复数);
- (3) $(x, y) = (y, x)$ (或 $(x, y) = \overline{(y, x)}$);
- (4) $(x_1 + x_2, y) = (x_1, y) + (x_2, y)$;
- (5) Cauchy-Schwarz

$$|(x, y)| \leq \|x\|_2 \|y\|_2,$$

等式当且仅当 x 与 y 线性相关时成立;

- (6) 三角不等式

$$\|x + y\|_2 \leq \|x\|_2 + \|y\|_2$$

向量范数的定义

定义 3 (向量的范数)

如果向量 $\boldsymbol{x} \in \mathbb{R}^n$ (或 \mathbb{C}^n) 的某个实值函数 $N(\boldsymbol{x}) = \|\boldsymbol{x}\|$, 满足条件:

(1) $\|\boldsymbol{x}\| \geq 0$ ($\|\boldsymbol{x}\| = 0$ 当且仅当 $\boldsymbol{x} = \mathbf{0}$) (正定条件),

(2) $\|\alpha\boldsymbol{x}\| = |\alpha|\|\boldsymbol{x}\|, \forall \alpha \in \mathbb{R}$ (或 $\alpha \in \mathbb{C}$),

(3) $\|\boldsymbol{x} + \boldsymbol{y}\| \leq \|\boldsymbol{x}\| + \|\boldsymbol{y}\|$ (三角不等式),

则称 $N(\boldsymbol{x})$ 是 \mathbb{R}^n (或 \mathbb{C}^n) 上的一个**向量范数**(或模). 且由 (3) 可推出不等式

(4) $|\|\boldsymbol{x}\| - \|\boldsymbol{y}\|| \leq \|\boldsymbol{x} - \boldsymbol{y}\|$.

常用的向量范数

(1) 向量的 ∞ -范数 (最大范数):

$$\|\boldsymbol{x}\|_{\infty} = \max_{1 \leq i \leq n} |x_i|.$$

容易验证这样定义的向量 \boldsymbol{x} 的函数 $N(\boldsymbol{x}) := \|\boldsymbol{x}\|_{\infty}$ 满足向量范数的三个条件.

(2) 向量的 1-范数:

$$\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|.$$

同样可证 $N(\mathbf{x}) = \|\mathbf{x}\|_1$ 是 \mathbb{R}^n 上的向量范数.

(3) 向量的 2-范数:

$$\|\mathbf{x}\|_2 = (\mathbf{x}, \mathbf{x})^{\frac{1}{2}} = \left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}}.$$

由定理 2 知 $N(\mathbf{x}) = \|\mathbf{x}\|_2$ 是 \mathbb{R}^n 上一个向量范数, 称为向量 \mathbf{x} 的欧氏范数.

(4) 向量的 p -范数:

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

其中 $p \in [1, \infty)$, 可以证明向量函数 $N(\mathbf{x}) \equiv \|\mathbf{x}\|_p$ 是 \mathbb{R}^n 上向量的范数, 上述三种范数是 p -范数的特殊情况 ($\|\mathbf{x}\|_\infty = \lim_{p \rightarrow \infty} \|\mathbf{x}\|_p$).

定义 4

设 $\{\mathbf{x}^{(k)}\}$ 为 \mathbb{R}^n 中一向量序列, $\mathbf{x}^* \in \mathbb{R}^n$, 记 $\mathbf{x}^{(k)} = (x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)})^T$, $\mathbf{x}^* = (x_1^*, x_2^*, \dots, x_n^*)^T$, 如果 $\lim_{k \rightarrow \infty} x_i^{(k)} = x_i^* (i = 1, 2, \dots, n)$, 则称 $\mathbf{x}^{(k)}$ 收敛于向量 \mathbf{x}^* , 记为

$$\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \mathbf{x}^*$$

定理 5 ($N(\mathbf{x})$ 的连续性)

设非负函数 $N(\mathbf{x}) = \|\mathbf{x}\|$ 为 \mathbb{R}^n 上任一向量范数, 则 $N(\mathbf{x})$ 是 \mathbf{x} 的分量 x_1, x_2, \dots, x_n 的连续函数.

定理 6 (向量范数的等价性)

设 $\|\mathbf{x}\|_s, \|\mathbf{x}\|_t$ 为 \mathbb{R}^n 上向量的任意两种范数, 则存在常数 $c_1, c_2 > 0$ 使得对一切 $\mathbf{x} \in \mathbb{R}^n$ 有

$$c_1 \|\mathbf{x}\|_s \leq \|\mathbf{x}\|_t \leq c_2 \|\mathbf{x}\|_s$$

注 定理 ?? 不能推广到无穷维空间, 由定理 ?? 可得到结论: 如果在一种范数意义下向量序列收敛时, 则在任何一种范数意义下该向量序列均收敛.

定理 7

$\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \mathbf{x}^* \Leftrightarrow \lim_{k \rightarrow \infty} \|\mathbf{x}^{(k)} - \mathbf{x}^*\| = 0$, 其中 $\|\cdot\|$ 为向量的任一范数.

矩阵范数

将向量范数推广到矩阵, 视 $\mathbb{R}^{n \times n}$ 中的矩阵为 \mathbb{R}^{n^2} 中的向量, 则由 \mathbb{R}^{n^2} 上的 2-范数可以得到 $\mathbb{R}^{n \times n}$ 中的矩阵的一种范数

$$F(\mathbf{A}) := \|\mathbf{A}\|_F := \left(\sum_{i,j=1}^n a_{ij}^2 \right)^{1/2}$$

称为 \mathbf{A} 的 Frobenius 范数. 显然 $\|\mathbf{A}\|_F$ 满足正定性、齐次性及三角不等式. 下面给出矩阵范数的一般定义

定义 8 (矩阵的范数)

如果矩阵 $\mathbf{A} \in \mathbb{R}^{n \times n}$ 的某个非负实值函数 $N(\mathbf{A}) := \|\mathbf{A}\|$, 满足条件:

- (1) $\|\mathbf{A}\| \geq 0$ ($\|\mathbf{A}\| = 0 \Leftrightarrow \mathbf{A} = \mathbf{0}$) (正定条件);
- (2) $\|c\mathbf{A}\| = |c|\|\mathbf{A}\|$, c 为实数 (齐次条件);
- (3) $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ (三角不等式);
- (4) $\|\mathbf{AB}\| \leq \|\mathbf{A}\|\|\mathbf{B}\|$.

则称 $N(\mathbf{A})$ 是 $\mathbb{R}^{n \times n}$ 上的一个矩阵范数 (或模).

上面我们定义的 $F(\mathbf{A}) = \|\mathbf{A}\|_F$ 就是 $\mathbb{R}^{n \times n}$ 上的一个矩阵范数.

由于在大多数与估计有关的问题中, 矩阵和向量会同时参与讨论, 所以希望引进一种矩阵范数, 使其与向量范数相联系. 如要求对任何向量 $\mathbf{x} \in \mathbb{R}^n$ 及 $\mathbf{A} \in \mathbb{R}^{n \times n}$ 都成立

$$\|\mathbf{A}\mathbf{x}\| \leq \|\mathbf{A}\| \|\mathbf{x}\|.$$

这时称矩阵范数和向量范数**相容**. 为此再引进一种矩阵的范数.

定义 9 (矩阵的算子范数)

设 $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{A} \in \mathbb{R}^{n \times n}$, 给出一种向量范数 $\|\mathbf{x}\|_v$ (如 $v = 1, 2$ 或 ∞), 相应地定义一个矩阵的非负函数

$$\|\mathbf{A}\|_v = \max_{\mathbf{x} \neq 0} \frac{\|\mathbf{A}\mathbf{x}\|_v}{\|\mathbf{x}\|_v}.$$

可验证 $\|\mathbf{A}\|_v$ 满足定义 ??, 所以 $\|\mathbf{A}\|_v$ 是 $\mathbb{R}^{n \times n}$ 上矩阵的一个范数, 称为 \mathbf{A} 的**算子范数**, 也称**从属范数**.

定理 10

设 $\|\mathbf{x}\|_v$ 是 \mathbb{R}^n 上的一个向量范数, 则 $\|\mathbf{A}\|_v$ 是 $\mathbb{R}^{n \times n}$ 上矩阵的范数, 且满足相容性条件

$$\|\mathbf{A}\mathbf{x}\|_v \leq \|\mathbf{A}\|_v \|\mathbf{x}\|_v.$$

这种矩阵的范数 $\|\mathbf{A}\|_v$ 依赖于向量范数 $\|\mathbf{x}\|_v$ 的具体含义, 即当给出一种具体的向量范数 $\|\mathbf{x}\|_v$ 时, 相应的得到了一种矩阵范数 $\|\mathbf{A}\|_v$.

定理 11

设 $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{A} \in \mathbb{R}^{n \times n}$, 则:

(1) $\|\mathbf{A}\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$ (称为 \mathbf{A} 的行范数);

(2) $\|\mathbf{A}\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|$ (称为 \mathbf{A} 的列范数);

(3) $\|\mathbf{A}\|_2 = \sqrt{\lambda_{\max}(\mathbf{A}^T \mathbf{A})}$ (称为 \mathbf{A} 的 2-范数), 其中 $\lambda_{\max}(\mathbf{A}^T \mathbf{A})$ 表示 $\mathbf{A}^T \mathbf{A}$ 的最大征值.

注 对于复矩阵 ($\mathbf{A} \in \mathbb{C}^{n \times n}$), 上述定理中的 (1),(2) 显然也成立, 对于 (3) 应改为

$$\|\mathbf{A}\|_2 = \max_{\mathbf{x} \neq 0} \left(\frac{\mathbf{x}^H \mathbf{A}^H \mathbf{A} \mathbf{x}}{\mathbf{x}^H \mathbf{x}} \right)^{1/2} = \sqrt{\lambda_{\max}(\mathbf{A}^H \mathbf{A})}.$$

定理 12

对任何 $\mathbf{A} \in \mathbb{R}^{n \times n}$, $\|\cdot\|$ 为一种算子范数, 则

$$\rho(\mathbf{A}) \leq \|\mathbf{A}\|, \quad (\text{对 } \|\mathbf{A}\|_{\mathbb{F}} \text{ 也成立.})$$

反之, 对任意实数 $\varepsilon > 0$, 至少存在一种算子范数 $\|\cdot\|_{\varepsilon}$, 使

$$\|\mathbf{A}\|_{\varepsilon} \leq \rho(\mathbf{A}) + \varepsilon.$$

定理 13

如果 $A \in \mathbb{R}^{n \times n}$ 为对称矩阵, 则 $\|A\|_2 = \rho(A)$.

定理 14

如果 $\|B\| < 1$, 则 $I \pm B$ 为非奇异矩阵, 且

$$\|(I \pm B)^{-1}\| \leq \frac{1}{1 - \|B\|},$$

其中 I 是单位矩阵, $\|\cdot\|$ 是矩阵的算子范数.