

相关基础知识回顾与补充

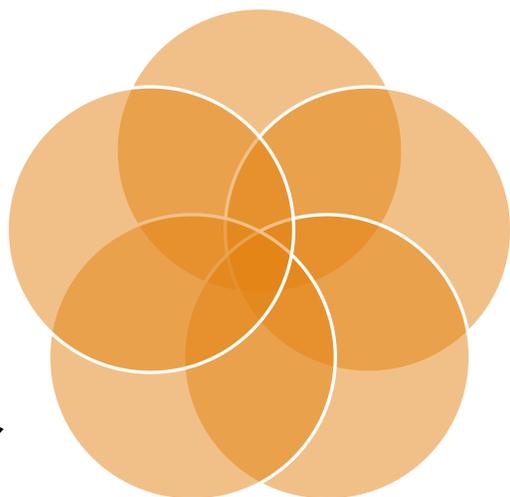
概率论

线性系
统理论

随机过
程

泛函分
析

矩阵分
析



线性系统理论基础

矩阵代数与矩阵微积分

2.1.1 向量与矩阵

Definition 2.1.1. 向量也称为矢量，是由若干标量按行或列排列组成的一组数. 构成向量的标量称为向量的元素，向量中元素的个数称为向量的维数。

一个 n 维列向量可表示为

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (2.1)$$

一个 m 维行向量可表示为

$$\mathbf{y} = [y_1, y_2, \dots, y_m] \quad (2.2)$$

Definition 2.1.2. 矩阵是由标量构成的二维数表. 具有 n 行、 m 列的矩阵称为 $n \times m$ 维矩阵, 可表示为

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \cdots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nm} \end{bmatrix} \quad (2.3)$$

行数 n 和列数 m 相等的矩阵称为 方阵.

Definition 2.1.3. 所有元素为 0 的矩阵 (向量) 称为 零矩阵 (零向量), 简记为 $\mathbf{0}$.

Definition 2.1.4. 如果方阵 I 对角线元素为 1、其他元素为 0 的对称方阵, 即

$$I = \begin{bmatrix} 1 & 0 & \cdots & \cdots & 0 \\ 0 & 1 & 0 & \cdots & 0 \\ \vdots & & \ddots & & \vdots \\ 0 & 0 & \cdots & & 1 \end{bmatrix} = [\delta_{ij}] \quad (2.4)$$

- ◆ 有时用下标表示**单位矩阵**的维数，例如 I_n 表示 $n \times n$ 维单位矩阵.
- ◆ 向量可以视为退化了的矩阵.
- ◆ 构成矩阵的标量称为矩阵的元素，可以是实数(R),也可以是复数(C).
- ◆ 对于式(2.3)所示矩阵 A ,如果 $\forall a \in R$, 那么通常记为 $A = [a_{ij}] \in R^{n \times m}$.
- ◆ 类似地，实向量记为 $\mathbf{x} \in R^{n \times 1} := R^n (\forall x_i \in R)$, $\mathbf{y} \in R^{1 \times m} (\forall y_i \in R)$.
- ◆ (2.3)所示矩阵 A 可以认为是由 n 个行向量 $\bar{A}_i = [a_{i1}, a_{i2}, \dots, a_{im}] (i = 1, \dots, n)$ 构成的，也可以认为是由 m 个列向量 $A_i (i = 1, 2, \dots, m)$ 构成的.即

$$A = [A_1, A_2, \dots, A_m] = \begin{bmatrix} \bar{A}_1 \\ \bar{A}_2 \\ \vdots \\ \bar{A}_n \end{bmatrix}$$

Definition 2.1.5. 对一组向量 $\{\boldsymbol{x}_1, \boldsymbol{x}_2, \cdots, \boldsymbol{x}_n\}$, 如果存在一组不全为零的标量 $\{c_1, c_2, \cdots, c_n\}$, 使得

$$c_1\boldsymbol{x}_1 + c_2\boldsymbol{x}_2 + \cdots + c_n\boldsymbol{x}_n = 0 \quad (2.6)$$

那么称向量组 $\{\boldsymbol{x}_1, \boldsymbol{x}_2, \cdots, \boldsymbol{x}_n\}$ 是线性相关的. 否则, 称该向量组是线性无关的. 线性无关又称为线性独立.

例如, 向量 $\begin{bmatrix} 1 \\ 2 \end{bmatrix}$ 和 $\begin{bmatrix} 2 \\ 4 \end{bmatrix}$ 是线性相关的, 因为 $2 \begin{bmatrix} 1 \\ 2 \end{bmatrix} - \begin{bmatrix} 2 \\ 4 \end{bmatrix} = 0$. 而 $\begin{bmatrix} 1 \\ 0 \end{bmatrix}$ 和 $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$ 则是线性无关的. 行向量 $[1, 0, 0], [0, 1, 0], [0, 0, 1]$, 三者也是线性无关的.

Definition 2.1.6. 对于任意的矩阵 A , 其中线性无关行向量的个数定义为矩阵 A 的秩, 记为 $\rho(A)$.

可以证明, 矩阵 A 的秩也等于 A 中线性无关列向量的个数.

Theorem 2.1.1. $n \times m$ 维矩阵 A 的秩总是小于或等于矩阵的行数 n 或列数 m , 即

$$\rho(A) \leq \min(n, m) \quad (2.7)$$

如果 $\rho(A) = \min(n, m)$, 那么称 A 是满秩的.

Theorem 2.1.2. $n \times m$ 维矩阵 A 的零度定义为 $[m - \rho(A)]$.

把一个矩阵 (A) 的所有行变为列、所有列变为行, 所得的新矩阵称为原矩阵的转置, 记为 A^T . 例如矩阵 (2.3) 的转置为

$$A^T = \begin{bmatrix} a_{11} & a_{21} & \cdots & a_{n1} \\ a_{12} & a_{22} & \cdots & a_{n2} \\ \vdots & \vdots & \cdots & \vdots \\ a_{1m} & a_{2m} & \cdots & a_{nm} \end{bmatrix} \quad (2.8)$$

2.1.2 矩阵代数

Definition 2.1.7. 具有相同维数的矩阵 $A = [a_{ij}]$ 和 $B = [b_{ij}]$, 两者之间的加法和减法分别定义为

$$A + B = [a_{ij} + b_{ij}] \quad (2.12)$$

$$A - B = [a_{ij} - b_{ij}] \quad (2.13)$$

Definition 2.1.8. 矩阵 $A = [a_{ij}]$ 与标量 k 之间的乘法 (数乘) 定义为

$$kA = Ak = [ka_{ij}] \quad (2.14)$$

Definition 2.1.9. 矩阵 A ($n \times r$ 维) 和矩阵 B ($r \times m$ 维) 之积(乘法) 记为 $C = AB = [c_{ij}]$, 其中

$$c_{ij} = \sum_{k=1}^r a_{ik} b_{kj} \quad i = 1, \dots, n \quad j = 1, \dots, m \quad (2.15)$$

显然, A 列数和 B 的行数需要相等, AB 才有定义. 另外, 一般地 $AB \neq BA$.

Definition 2.1.10. 设 \boldsymbol{x} 和 \boldsymbol{y} 是相同维数的向量, 标量 $\boldsymbol{x}^T \boldsymbol{y}$ 称为 \boldsymbol{x} 和 \boldsymbol{y} 之间的 内积或点积. 假设 \boldsymbol{x} 和 \boldsymbol{y} 的维数为 n , 那么

$$\boldsymbol{x}^T \boldsymbol{y} = x_1 y_1 + x_2 y_2 + \cdots + x_n y_n \quad (2.16)$$

如果 $\boldsymbol{x}^T \boldsymbol{y} = 0$, 称两者是 正交的.

Definition 2.1.11. $\sqrt{\boldsymbol{x}^T \boldsymbol{x}}$ 称为 \boldsymbol{x} 的 2-范数, 记为

$$\|\boldsymbol{x}\|_2 = \sqrt{x_1^2 + x_2^2 + \cdots + x_n^2} \quad (2.17)$$

向量的 2-范数也称为 欧几里得范数, 另外经常简记为 $\|\boldsymbol{x}\|$.

Definition 2.1.12. 向量 $\boldsymbol{x} \in R^n$ 与 $\boldsymbol{y} \in R^m$ 的 外积 定义为 $\boldsymbol{x}\boldsymbol{y}^T$, 这是一个如下形式的矩阵:

$$\boldsymbol{x}\boldsymbol{y}^T = \begin{bmatrix} x_1 y_1 & x_1 y_2 & \cdots & x_1 y_m \\ x_2 y_1 & x_2 y_2 & \cdots & x_2 y_m \\ \vdots & \vdots & \ddots & \vdots \\ x_n y_1 & x_n y_2 & \cdots & x_n y_m \end{bmatrix} \quad (2.18)$$

$$\begin{aligned}
PHP^T &= \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \vdots & \ddots & \vdots \\ p_{p1} & \cdots & p_{pn} \end{bmatrix} \begin{bmatrix} h_{11} & \cdots & h_{1p} \\ \vdots & \ddots & \vdots \\ h_{n1} & \cdots & h_{np} \end{bmatrix} \begin{bmatrix} p_{11} & \cdots & p_{p1} \\ \vdots & \ddots & \vdots \\ p_{1n} & \cdots & p_{pn} \end{bmatrix} \\
&= [P_1, \cdots, P_n] \begin{bmatrix} h_{11} & \cdots & h_{1p} \\ \vdots & \ddots & \vdots \\ h_{n1} & \cdots & h_{np} \end{bmatrix} \begin{bmatrix} P_1^T \\ \vdots \\ P_n^T \end{bmatrix} \\
&= \left[\sum_{i=1}^n P_i h_{i1}, \cdots, \sum_{i=1}^n P_i h_{ip} \right] \begin{bmatrix} P_1^T \\ \vdots \\ P_n^T \end{bmatrix} \\
&= \sum_{i=1}^n \sum_{j=1}^n P_i h_{ij} P_j^T
\end{aligned}$$

Definition 2.1.14. 设 $A = [a_{ij}] \in R^{n \times n}$, 下式 (对 $\forall i \in [1, n]$ 均成立)

$$\det(A) := |A| := \sum_{j=1}^n (-1)^{i+j} a_{ij} |A_{ij}| \quad (2.24)$$

称为矩阵 A 的行列式. 式中 $A_{ij} \in R^{(n-1) \times (n-1)}$ 表示 A 矩阵删除第 i 行和第 j 列后, 剩余元素构成的矩阵. 式 (2.24) 称为矩阵 A 沿第 i 行的拉普拉展开 (*Laplace expansion*).

与 (2.24) 类似, 我们有

$$|A| = \sum_{i=1}^n (-1)^{i+j} a_{ij} |A_{ij}| \quad (2.25)$$

Theorem 2.1.3. 如果 A 和 B 是具有相同维数的两个方阵，那么

$$|AB| = |A||B|$$

Definition 2.1.15. 设 $A \in R^{n \times n}$ ，如果

$$Av = \lambda v$$

那么 $\lambda \in R$ 称为 A 的一个特征值， $v \in R^n$ 称为 λ 对应的特征向量。

$n \times n$ 维矩阵具有 n 个特征值，可能有相同取值。

Theorem 2.1.4. 设 λ_i 是矩阵 $A \in R^{n \times n}$ 的特征根，那么

$$|A| = \prod_{i=1}^n \lambda_i$$

Definition 2.1.16. 对于矩阵 $A \in R^{n \times n}$, 如果存在矩阵 $A^{-1} \in R^{n \times n}$, 使得

$$AA^{-1} = A^{-1}A = I \quad (2.29)$$

那么 A^{-1} 称为 A 的逆矩阵.

一般地, $(AB)^{-1} = B^{-1}A^{-1}$ (假设对应的逆存在). 此外, $(A^T)^{-1} = (A^{-1})^T$.

如果一个矩阵不存在逆矩阵, 那么称该矩阵不可逆, 或者说是奇异的. 可逆矩阵又称非奇异矩阵, 非奇异矩阵一定是方阵, 反之则不然. 可以利用向量线性无关的概念, 矩阵非奇异也可以定义为矩阵的任意行 (或列) 不是其他行 (或列) 的线性组合. 此外, 矩阵非奇异也可以定义为矩阵的行列式不等于零, 即 $|A| \neq 0$.

Definition 2.1.17. 如果 $A^T = A^{-1}$, 那么 A 称为 正交矩阵 (或旋转矩阵).

Theorem 2.1.5. 如果 A 是正交矩阵, 那么 $|A| = 1$ 或 -1 .

Theorem 2.1.6. 假设 $A \in R^{n \times n}$, 那么如下说法是等价的:

- $\rho(A) = n$.
- A 是非奇异的.
- A^{-1} 存在.
- 构成 A 的所有列向量是线性无关的.
- 构成 A 的所有行向量是线性无关的.
- $|A| \neq 0$.
- 对于任意的 $b \in R^n$, 代数方程组 $Ax = b$ 具有唯一解 x .
- 0 不是 A 的特征值.

Definition 2.1.18. 对于矩阵 $A \in R^{n \times n}$, 它的迹 (*trace*) 定义为矩阵 A 对角元素之和. 即

$$\underline{tr(A) = \sum_{i=1}^n a_{ii}} \quad (2.37)$$

根据 2-范数的定义, 不能发现 $tr(\mathbf{x}\mathbf{x}^T) = \|\mathbf{x}\|_2^2$. 对于适当维数的矩阵 A 和 B , 有 $tr(AB) = tr(BA)$.

Property 2.1.1. 设 λ_i 是矩阵 $A \in R^{n \times n}$ 的第 i 个特征值, 那么

$$\underline{tr(A) = \sum_{i=1}^n \lambda_i} \quad (2.38)$$

Definition 2.1.19. 设 $A = A^T$, 对任意非零的 x , 如果

$$x^T Ax > 0$$

那么称 A 是正定的, 记为 $A > 0$; 如果

$$x^T Ax \geq 0$$

那么称 A 是半正定或非负定的, 记为 $A \geq 0$; 如果

$$x^T Ax < 0$$

那么称 A 是负定的, 记为 $A < 0$; 如果

$$x^T Ax \leq 0$$

那么称 A 是半负定或非正定的, 记为 $A \leq 0$; 如果 A 既非正定, 也非负定, 那么称 A 是不定的.

Theorem 2.1.7. $\lambda(A)$ 表示 A 的所有特征值:

- 如果 $A > 0$, 那么 $\lambda(A) > 0$ (正的实数), 而且 A^{-1} 存在且 $A^{-1} > 0$;
- 如果 $A \geq 0$, 那么 $\lambda(A) \geq 0$ (非负的实数);
- 如果 $A < 0$, 那么 $\lambda(A) < 0$ (负的实数), 而且 A^{-1} 存在且 $A^{-1} < 0$;
- 如果 $A \leq 0$, 那么 $\lambda(A) \leq 0$ (非正的实数);
- 如果 A 是不定的, 那么 A 的特征值有的为正、有的为负。

Definition 2.1.20. 向量 $\boldsymbol{x} \in R^n$ 的 Q 加权 2-范数 定义为

$$\|\boldsymbol{x}\|_Q = \sqrt{\boldsymbol{x}^T Q \boldsymbol{x}} \quad (2.43)$$

其中, $Q = Q^T > 0 (\in R^{n \times n})$.

Definition 2.1.21. 矩阵 $A \in R^{n \times m}$ 的 奇异值 $\sigma(A)$ 定义为 $A^T A$ 或 AA^T 非零部分特征值, 可表示为

$$\sigma(A) = \sqrt{\lambda(A^T A)} = \sqrt{\lambda(AA^T)} \quad (2.44)$$

矩阵 A 奇异值的个数为 $\min(n, m)$.

根据向量的 2-范数，我们也可以定义矩阵的大小（范数）。

Definition 2.1.22. 矩阵 A 的 2-范数定义为

$$\|A\|_2 = \max_{\forall \mathbf{x} \neq \mathbf{0}} \frac{\|A\mathbf{x}\|_2}{\|\mathbf{x}\|_2} = \sup_{\|\mathbf{x}\|=1} \|A\mathbf{x}\|_2$$

Theorem 2.1.8.

$$\|A\|_2 = \sigma_{max}(A)$$

式中， $\sigma_{max}(A)$ 表示矩阵 A 的最大奇异值。

Theorem 2.1.9. 【矩阵求逆引理】 设 A_{11} 和 A_{22} 是可逆方阵, A_{12} 和 A_{21} 是适当维数的矩阵, 那么

$$(A_{11} - A_{12}A_{22}^{-1}A_{21})^{-1} = A_{11}^{-1} + A_{11}^{-1}A_{12}(A_{22} - A_{21}A_{11}^{-1}A_{12})^{-1}A_{12}A_{11}^{-1} \quad (2.47)$$

【证明】 设分块表示的矩阵 $\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}$ 的逆矩阵为 $\begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}$, 那么

$$\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} = \begin{bmatrix} A_{11}B_{11} + A_{12}B_{21} & A_{11}B_{12} + A_{12}B_{22} \\ A_{21}B_{11} + A_{22}B_{21} & A_{21}B_{12} + A_{22}B_{22} \end{bmatrix} = \begin{bmatrix} I & \mathbf{0} \\ \mathbf{0} & I \end{bmatrix} \quad (2.48)$$

$$A_{21}B_{11} + A_{22}B_{21} = \mathbf{0} \Rightarrow B_{21} = -A_{22}^{-1}A_{21}B_{11}$$

$$A_{11}B_{11} + A_{12}B_{21} = I \Rightarrow B_{11} = A_{11}^{-1} - A_{11}^{-1}A_{12}B_{21}$$

$$\Rightarrow B_{21} = -A_{22}^{-1}A_{21}(A_{11}^{-1} - A_{11}^{-1}A_{12}B_{21})$$

$$\Rightarrow B_{21} = -(A_{22} - A_{21}A_{11}^{-1}A_{12})^{-1}A_{21}A_{11}^{-1}$$

$$\Rightarrow B_{11} = A_{11}^{-1} + A_{11}^{-1}A_{12}(A_{22} - A_{21}A_{11}^{-1}A_{12})^{-1}A_{21}A_{11}^{-1}$$

$$\begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} = \begin{bmatrix} B_{11}A_{11} + B_{12}A_{21} & B_{11}A_{12} + B_{12}A_{22} \\ B_{21}A_{11} + B_{22}A_{21} & B_{21}A_{12} + B_{22}A_{22} \end{bmatrix} = \begin{bmatrix} I & \mathbf{0} \\ \mathbf{0} & I \end{bmatrix}$$

$$B_{12} = -B_{11}A_{12}A_{22}^{-1}$$

$$B_{11} = A_{11}^{-1} - B_{12}A_{21}A_{11}^{-1} \Rightarrow B_{11} = A_{11}^{-1} + B_{11}A_{12}A_{22}^{-1}A_{21}A_{11}^{-1}$$

$$\Rightarrow B_{11} = (A_{11} - A_{12}A_{22}^{-1}A_{21})^{-1}$$

矩阵求逆引理有时也写为如下等价形式:

$$(A_{11} + A_{12}A_{22}^{-1}A_{21})^{-1} = A_{11}^{-1} - A_{11}^{-1}A_{12}(A_{22} + A_{21}A_{11}^{-1}A_{12})^{-1}A_{12}A_{11}^{-1} \quad (2.53)$$

矩阵求逆引理有广泛的应用,特别是在矩阵求逆时可以大幅度减小计算量。例如,设 $A_{11} = I \in R^{n \times n}$, $A_{22} = D \in R^{q \times q}$, $A_{12} = B \in R^{n \times p}$, $A_{21} = C \in R^{p \times n}$, 式 (2.53) 化为

$$(I + BD^{-1}C)^{-1} = I - B(D + CB)^{-1}C \quad (2.54)$$

上式左端需要对 $n \times n$ 维矩阵求逆,右端仅需要对 $p \times p$ 维矩阵求逆。当 $n \gg p$ 时,右端的计算量会降低很多。

Definition 2.1.25. 方阵 A 的幂指数 e^A 定义为

$$e^A = I + A + \frac{1}{2!}A^2 + \frac{1}{3!}A^3 + \dots$$

其中, $A^2 = AA$, $A^3 = AAA = AA^2 = A^2A$, 等.

Theorem 2.1.12. 对于适当维数的矩阵 A 、 B 和 T , 有

- (1) 若 $AB = BA$, $e^{A+B} = e^A e^B$;
- (2) 当 $|T| \neq 0$, $e^{TAT^{-1}} = T e^A T^{-1}$;
- (3) $|e^A| = e^{\text{tr}(A)}$.

2.1.3 矩阵微积分

Definition 2.1.26. 对于时变矩阵 $A(t) = \begin{bmatrix} a_{11}(t) & \cdots & a_{1m}(t) \\ \vdots & \ddots & \vdots \\ a_{n1}(t) & \cdots & a_{nm}(t) \end{bmatrix}$, 其关于时间的微分和积分

$$\dot{A}(t) = \begin{bmatrix} \dot{a}_{11}(t) & \cdots & \dot{a}_{1m}(t) \\ \vdots & \ddots & \vdots \\ \dot{a}_{n1}(t) & \cdots & \dot{a}_{nm}(t) \end{bmatrix}$$

$$\int A(t)dt = \begin{bmatrix} \int a_{11}(t)dt & \cdots & \int a_{1m}(t)dt \\ \vdots & \ddots & \vdots \\ \int a_{n1}(t)dt & \cdots & \int a_{nm}(t)dt \end{bmatrix}$$

Theorem 2.1.13. 假设 $A(t)$ 是随时间变化的可逆矩阵, 即 $A^{-1}(t)$ 存在, 所有元素光滑可导, 那么

$$\frac{dA^{-1}}{dt} = -A^{-1}\dot{A}A^{-1}$$

Definition 2.1.27. 设 $A = [a_{ij}] \in R^{n \times m}$, $f(A)$ 是关于 A 的标量函数, 那么

$$\frac{\partial f(A)}{\partial A} = \begin{bmatrix} \frac{\partial f}{\partial a_{11}} & \cdots & \frac{\partial f}{\partial a_{1m}} \\ \vdots & \ddots & \vdots \\ \frac{\partial f}{\partial a_{n1}} & \cdots & \frac{\partial f}{\partial a_{nm}} \end{bmatrix}$$

由于 $\mathbf{x}^T \mathbf{y} = x_1 y_1 + \cdots + x_n y_n$, 所以

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{bmatrix}$$

$$\frac{\partial f(\mathbf{x})}{\partial \mathbf{x}^T} = \left[\frac{\partial f(\mathbf{x})}{\partial x_1}, \frac{\partial f(\mathbf{x})}{\partial x_2}, \cdots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right]$$

$$\frac{\partial \mathbf{x}^T \mathbf{y}}{\partial \mathbf{x}} = \mathbf{y}$$
$$\frac{\partial \mathbf{x}^T \mathbf{y}}{\partial \mathbf{y}} = \mathbf{x}$$

Theorem 2.1.14.

$$\frac{\partial \mathbf{x}^T A \mathbf{x}}{\partial \mathbf{x}} = A \mathbf{x} + A^T \mathbf{x}$$

【证明】不失一般性，设 $A \in R^{n \times n}$ ，那么

$$\mathbf{x}^T A \mathbf{x} = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j$$

$$\begin{aligned} \frac{\partial \mathbf{x}^T A \mathbf{x}}{\partial \mathbf{x}} &= \begin{bmatrix} \sum_{j=1}^n a_{1j} x_j & + & \sum_{i=1}^n a_{i1} x_i \\ & \vdots & \\ \sum_{j=1}^n a_{nj} x_j & + & \sum_{i=1}^n a_{in} x_i \end{bmatrix} \\ &= \begin{bmatrix} \sum_{j=1}^n a_{1j} x_j \\ \vdots \\ \sum_{j=1}^n a_{nj} x_j \end{bmatrix} + \begin{bmatrix} \sum_{i=1}^n a_{i1} x_i \\ \vdots \\ \sum_{i=1}^n a_{in} x_i \end{bmatrix} \\ &= A \mathbf{x} + A^T \mathbf{x} \end{aligned}$$

$$\frac{\partial \mathbf{g}(\mathbf{x})}{\partial \mathbf{x}^T} = \begin{bmatrix} \partial g_1(\mathbf{x})/\partial x_1 & \cdots & \partial g_1(\mathbf{x})/\partial x_n \\ \vdots & & \vdots \\ \partial g_m(\mathbf{x})/\partial x_1 & \cdots & \partial g_m(\mathbf{x})/\partial x_n \end{bmatrix}$$

$$\frac{\partial \mathbf{g}^T(\mathbf{x})}{\partial \mathbf{x}} = \left[\frac{\partial \mathbf{g}(\mathbf{x})}{\partial \mathbf{x}^T} \right]^T$$

$$\begin{aligned} \frac{\partial A\mathbf{x}}{\partial \mathbf{x}^T} &= A \\ \frac{\partial \mathbf{x}^T A^T}{\partial \mathbf{x}} &= A^T \end{aligned}$$

Theorem 2.1.15. 设 $A \in R^{m \times n}$, $B \in R^{n \times n}$, 那么

$$\frac{\partial \text{tr}(ABA^T)}{\partial A} = AB^T + AB$$

当 $B = B^T$ 时

$$\frac{\partial \text{tr}(ABA^T)}{\partial A} = 2AB$$

线性动态系统

确定性连续时间系统可描述为

$$\dot{\boldsymbol{x}} = \boldsymbol{A}\boldsymbol{x} + \boldsymbol{B}\boldsymbol{u} \quad (2.87)$$

式中, $\boldsymbol{x} \in R^n$ 是系统的状态向量, $\boldsymbol{u} \in R^m$ 是系统的输入 (控制) 向量. $\boldsymbol{A} \in R^{n \times n}$ 称为系统矩阵, $\boldsymbol{B} \in R^{n \times m}$ 称为输入矩阵. \boldsymbol{A} 和 \boldsymbol{B} 可以是时变矩阵, 此时称为式 (2.87) 为线性时变系统. 当 \boldsymbol{A} 和 \boldsymbol{B} 是常值矩阵时, 式 (2.87) 称为线性时不变系统或线性定常系统.

转移矩阵

$$\dot{\boldsymbol{x}}(t) = A(t)\boldsymbol{x}(t)$$

Theorem 2.2.1. 设初始时刻 t_0 系统状态为 $\boldsymbol{x}(t_0)$, 系统 (2.88) 的解为

$$\boldsymbol{x}(t) = \Phi(t, t_0)\boldsymbol{x}(t_0)$$

式中, $\Phi(t, t_0) \in R^{n \times n}$ 称为系统的转移矩阵, 并满足

$$\frac{d}{dt}\Phi(t, t_0) = A(t)\Phi(t, t_0), \quad \Phi(t_0, t_0) = I$$

Theorem 2.2.2. 对线性时不变系统, $A(t) = A$ 不随时间变化, 有

$$\Phi(t, t_0) = \Phi(t - t_0) = e^{A(t-t_0)}$$

【证明】 将 $\mathbf{x}(t)$ 在时刻 t_0 泰勒级数展开

$$\mathbf{x}(t) = \mathbf{x}(t_0) + \dot{\mathbf{x}}(t_0)(t - t_0) + \ddot{\mathbf{x}}(t_0)\frac{(t - t_0)^2}{2!} + \dots$$

$$\dot{\mathbf{x}}(t_0) = A\mathbf{x}(t_0)$$

$$\ddot{\mathbf{x}}(t_0) = A\dot{\mathbf{x}}(t_0) = A^2\mathbf{x}(t_0)$$

\vdots

$$\begin{aligned}\mathbf{x}(t) &= \mathbf{x}(t_0) + A\mathbf{x}(t_0)(t - t_0) + A^2\mathbf{x}(t_0)\frac{(t - t_0)^2}{2!} + \dots \\ &= \left[I + A(t - t_0) + A^2\frac{(t - t_0)^2}{2!} + \dots \right] \mathbf{x}(t_0)\end{aligned}$$

$$\Phi(t, t_0) = e^{A(t-t_0)}$$

Theorem 2.2.3. 对时不变系统矩阵 A , 有

$$e^{A(t-t_0)} = \mathcal{L}^{-1}[(sI - A)^{-1}]$$

其中 \mathcal{L}^{-1} 表示拉普拉斯逆变换.

【证明】 对 $\dot{\boldsymbol{x}} = A\boldsymbol{x}$ 两端取拉普拉斯变换

$$sX(s) - \boldsymbol{x}(t_0) = AX(s)$$

Theorem 2.2.4. 对于线性时变系统 (2.87), 状态向量的通解为

$$\mathbf{x}(t) = \Phi(t, t_0)\mathbf{x}(t_0) + \int_{t_0}^t \Phi(t, \tau)B(\tau)\mathbf{u}(\tau)d\tau$$

其中, $\mathbf{x}(t_0)$ 为系统状态初值, $\Phi(t, t_0)$ 为系统状态转移矩阵.

Theorem 2.2.5. 对于线性系统 (2.87), 如果 A 和 B 是定常矩阵, 那么

$$\mathbf{x}(t) = e^{A(t-t_0)}\mathbf{x}(t_0) + \int_{t_0}^t e^{A(t-\tau)}B\mathbf{u}(\tau)d\tau$$

其中, $\mathbf{x}(t_0)$ 为系统状态初值, $e^{A(t-t_0)}$ 为此时系统状态转移矩阵.

小扰动线性化

$$\dot{x} = f(x, u)$$

$$f(\mathbf{0}, \mathbf{0}) = \mathbf{0}$$

$$f(x, u) \approx f(\mathbf{0}, \mathbf{0}) + \left. \frac{\partial f(x, u)}{\partial x} \right|_0 x + \left. \frac{\partial f(x, u)}{\partial u} \right|_0 u$$

$$\dot{x} = Ax + Bu$$

$$A = \left. \frac{\partial f(x, u)}{\partial x} \right|_0 = \frac{\partial f(\mathbf{0}, \mathbf{0})}{\partial x}$$
$$B = \left. \frac{\partial f(x, u)}{\partial u} \right|_0 = \frac{\partial f(\mathbf{0}, \mathbf{0})}{\partial u}$$

$$\dot{x}^* = f(x^*, u^*)$$

$$\Delta \dot{x} = A \Delta x + B \Delta u$$

$$\Delta x = x - x^*$$

$$\Delta u = u - u^*$$

$$A = \left. \frac{\partial f(x, u)}{\partial x} \right|_* = \frac{\partial f(x^*, u^*)}{\partial x}$$

$$B = \left. \frac{\partial f(x, u)}{\partial u} \right|_* = \frac{\partial f(x^*, u^*)}{\partial u}$$

采样控制系统

$$\mathbf{x}(t_{k+1}) = \Phi(t_{k+1}, t_k)\mathbf{x}(t_k) + \int_{t_k}^{t_{k+1}} \Phi(t_{k+1}, \tau)B(\tau)\mathbf{u}(\tau)d\tau$$

$$\mathbf{x}_{k+1} = F_k\mathbf{x}_k + G_k\mathbf{u}_k$$

$$F_k = \Phi(t_{k+1}, t_k)$$

$$G_k = \int_{t_k}^{t_{k+1}} \Phi(t_{k+1}, \tau)B(\tau)d\tau$$

在采样间隔充分小的条件下

$$F_k \approx [I + A(t_k)]\Delta t$$

$$G_k \approx B(t_k)\Delta t$$

线性时不变系统

如果系统矩阵 A 非奇异，因为

$$F_k = e^{A(t_{k+1}-t_k)} = e^{A\Delta t}$$
$$G_k = \int_{t_k}^{t_{k+1}} e^{A(t_{k+1}-\tau)} d\tau B = \int_0^{\Delta t} e^{A(\Delta t-\lambda)} d\lambda B$$

$$\int_0^{\Delta t} e^{-A\lambda} d\lambda = \int_0^{\Delta t} (I - A\lambda + \frac{1}{2!}A^2\lambda^2 - \dots) d\lambda$$
$$= [I - e^{-A\Delta t}]A^{-1}$$

$$F_k = F = e^{A\Delta t}$$

$$G_k = G = F[I - e^{-A\Delta t}]A^{-1}B$$

稳定性

Definition 2.5.1. 考虑连续时间线性时不变系统

$$\dot{\boldsymbol{x}} = A\boldsymbol{x} \quad (2.130)$$

对任意有界的初始状态 $\boldsymbol{x}(0)$ ，如果 $\boldsymbol{x}(t)$ ($\forall t > 0$) 有界，那么称系统 (2.130) 是 李雅普诺夫稳定的。

Definition 2.5.2. 对任意有界的初始状态 $\boldsymbol{x}(0)$ ，如果

$$\lim_{t \rightarrow \infty} \boldsymbol{x}(t) = \mathbf{0} \quad (2.131)$$

那么称系统 (2.130) 是 渐进稳定的。

可控性

Definition 2.6.1. 对连续时间系统 $\dot{\boldsymbol{x}} = A(t)\boldsymbol{x} + B(t)\boldsymbol{u}$, 如果存在控制 $\boldsymbol{u}(t)$, 使系统从任何初始状态 $\boldsymbol{x}(0)$, 转移到任何期望的状态 $\boldsymbol{x}(t)$ ($\forall t > 0$), 那么称该系统是可控的.

Definition 2.6.2. 对连续时间系统 $\boldsymbol{x}_{k+1} = F_k\boldsymbol{x}_k + G_k\boldsymbol{u}_k$, 如果存在控制 $\{\boldsymbol{u}_0, \dots, \boldsymbol{u}_k\}$, 使系统从任何初始状态 \boldsymbol{x}_0 , 转移到任何期望的状态, 那么称该系统是可控的.

可观性

$$\begin{cases} \dot{\boldsymbol{x}} = A\boldsymbol{x} + B\boldsymbol{u} \\ \boldsymbol{y} = C\boldsymbol{x} \end{cases} \quad (2.148)$$

其中, $\boldsymbol{x} \in R^n$ 是系统的状态向量, $\boldsymbol{y} \in R^m$ 为系统的输出向量, $\boldsymbol{u} \in R^m$ 是系统的输入 (控制) 向量. $A \in R^{n \times n}$ 是系统矩阵, $B \in R^{n \times m}$ 是输入矩阵, $C \in R^{m \times n}$ 称系统的输出矩阵.

Definition 2.6.3. 如果由系统的输入 $\boldsymbol{u}(\tau)$ 和输出 $\boldsymbol{y}(\tau), \tau \in [0, t](\forall t > 0)$, 可以唯一确定系统的初始状态 $\boldsymbol{x}(0)$, 那么连续时间线性系统 (2.148) 称为可观的.

可镇定性与可检测性

可镇定性 (stabilizability) 和可检测性 (detectability) 与系统的模态有关，同时分别与系统的可控性和可观性密切相关。对线性系统，我们通常可以通过非奇异变化，将系统解耦为不同性质的模态。

Definition 2.6.5. 如果一个系统的不可控模态是稳定的，那么称该系统是可镇定的。

Definition 2.6.6. 如果一个系统是可观的，或者不可观模态是稳定的，那么该系统成为可检测的。

连续时间系统仿真

如果给定控制输入 $\mathbf{u}(t)$, 那么可以表示为

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, t)$$

$$\begin{aligned}\mathbf{x}_{k+1} &= \mathbf{x}_k + \int_{t_k}^{t_{k+1}} \mathbf{f}(\mathbf{x}, t) dt \\ &= \mathbf{x}_k + \mathbf{I}_k\end{aligned}$$

最简单的积分方法是欧拉法，即

$$\mathbf{x}_{k+1} = \mathbf{x}_k + h\mathbf{f}(\mathbf{x}_k, t_k) \quad (2.157)$$

容易看出，此时 $I_k = \mathbf{f}(\mathbf{x}_k, t_k)h + O(h^2)$. 因此，欧拉法是 1 阶收敛的，截断误差是 $O(h^2)$. 只有当积分步长 h 足够小时，欧拉法才能获得足够的数值计算精度.

欧拉法的直接改进是梯形法，即

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \frac{1}{2}(\mathbf{k}_1 + \mathbf{k}_2) \quad (2.158)$$

其中

$$\begin{cases} \mathbf{k}_1 = h\mathbf{f}(\mathbf{x}_k, t_k) \\ \mathbf{k}_2 = h\mathbf{f}(\mathbf{x}_k + \mathbf{h}_1, t_k + h) \end{cases} \quad (2.159)$$

可以验证，梯形法是 2 阶收敛的，截断误差是 $O(h^3)$. 梯形法的计算精度比欧拉法要高，计算量也要大一些.

4 阶龙格-库塔 (Runge-Kutta) 法

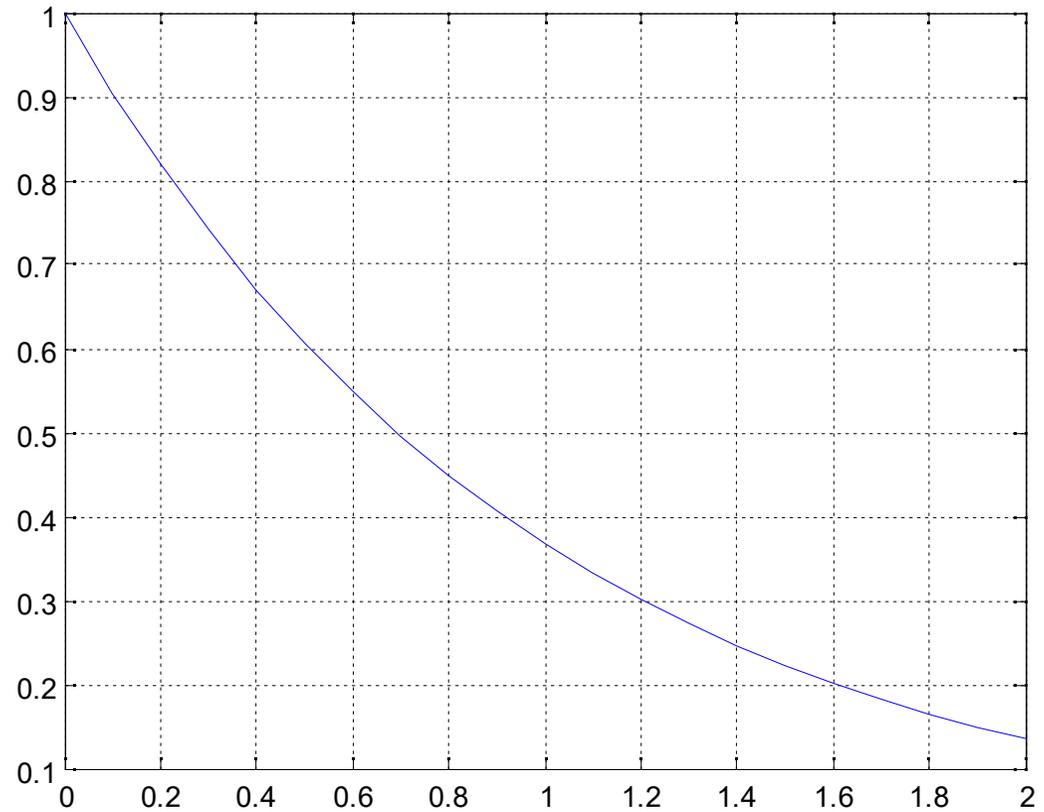
$$\mathbf{x}_{k+1} = \mathbf{x}_k + \frac{1}{6}(\mathbf{k}_1 + 2\mathbf{k}_2 + 2\mathbf{k}_3 + \mathbf{k}_4)$$

$$\begin{cases} \mathbf{k}_1 = h\mathbf{f}(\mathbf{x}_k, t_k) \\ \mathbf{k}_2 = h\mathbf{f}(\mathbf{x}_k + \frac{1}{2}\mathbf{k}_1, t_k + \frac{1}{2}h) \\ \mathbf{k}_3 = h\mathbf{f}(\mathbf{x}_k + \frac{1}{2}\mathbf{k}_2, t_k + \frac{1}{2}h) \\ \mathbf{k}_4 = h\mathbf{f}(\mathbf{x}_k + \mathbf{k}_3, t_k + h) \end{cases}$$

4 阶龙格-库塔法是 4 阶收敛的，截断误差是 $O(h^5)$ 。

仿真算例

$$\begin{cases} \dot{x}_1 = 1, x_1(0) = 0 \\ \dot{x}_2 = -x_2, x_2(0) = 1 \end{cases}$$



****MATLAB ode45****

1. step = 0.1;
2. ts=0:step:2.0;
3. x0=[0,1];
4. [t,x] = ode45(@fct1, ts, x0);
5. xact = exp(-t);
6. [t,x, xact]
7. plot(t,x(:,2)); grid;

fct1.m:

1. %right-hand function
 2. function xdot=fct1(t,x)
 3. xdot = zeros(2,1);
 4. xdot(1) = 1.0;
 5. xdot(2) = ydot(x(2));
-
1. function dy = ydot(x)
 2. dy = -x;