

统计信号分析

第1章 统计信号处理中的数学知识复习

本章内容

- 1.1 概率论概要
- 1.2 随机过程基础
- 1.3 线性代数导论

1.1 概率论概要

- 1.1.1 随机事件及其概率
- 1.1.2 随机变量及其分布
- 1.1.3 多维随机变量
- 1.1.4 随机变量的数字特征
- 1.1.5 高斯随机变量
- 1.1.6 随机变量函数的分布

确定性现象与随机现象

- **确定性现象**：在一定条件下必然会出现某一结果（或发生某一事件）的现象。
- **随机现象**：在一定条件下可能出现不同结果（或发生不同事件），且不能准确预言究竟出现哪一种结果的现象。

如：掷硬币、抽牌、掷骰子



1.1.1 随机事件及其概率

- 基本事件，记为 ω 。
- 样本空间，记为 Ω 。
- 事件，记为 A, B, C, \dots 。
- 古典概率
- 几何概率
- 统计概率

事件的概率：

设随机试验 E 的样本空间为 Ω ，对于随机试验 E 的每一随机事件 A ，都赋予唯一确定的实数 $P(A)$ ，并且集合函数 $P(\cdot)$ 满足下列条件：

- (1) 非负性：对每一个事件 $A \subset \Omega$ ，都有 $P(A) \geq 0$ ；
- (2) 规范性： $P(\Omega) = 1$ ；
- (3) 可列可加性：对任意互不相容的事件 $A_1, A_2, \dots, A_i, \dots$ ，

有

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$$

条件概率:

设 A 和 B 为任意两个随机事件, 且 $P(B) > 0$, 称

$$P(A|B) = \frac{P(AB)}{P(B)}$$

为事件 B 发生条件下事件 A 发生的**条件概率**, 也称 A 对 B 的概率。

全概率公式:

设某随机试验的样本空间 Ω 中的事件 $A_1, A_2, \dots, A_i, \dots$ (有限个或可列个) 构成一个完备事件组, 且 $P(A_i) > 0, i = 1, 2, \dots$, 则对任一事件 B , 有

$$P(B) = \sum_i P(A_i)P(B|A_i)$$

贝叶斯公式:

设某随机试验的样本空间 Ω 中的事件 $A_1, A_2, \dots, A_i, \dots$ (有限个或可列个) 构成一个完备事件组, 且 $P(A_i) > 0, i = 1, 2, \dots$, 则对任一事件 $B, P(B) > 0$, 有

$$P(A_m|B) = \frac{P(A_m)P(B|A_m)}{\sum_i P(A_i)P(B|A_i)}, \quad m = 1, 2, \dots$$

事件的独立性:

如果随机事件 A 与 B 满足关系 $P(AB) = P(A)P(B)$, 则称事件 A 与 B 是相互独立的。

性质: 若事件 A_1, A_2, \dots, A_n 相互独立, 则有

$$P\left(\bigcap_{i=1}^n A_i\right) = \prod_{i=1}^n P(A_i)$$

1.1.2 随机变量及其分布

随机变量:

设某随机试验的样本空间为 $\Omega = \{\omega\}$, 对于每一个样本点 $\omega \in \Omega$ 都有惟一的实数 $X(\omega)$ 与之对应, 这样就得到一个定义在 Ω 上的单值实函数 $X = X(\omega)$ 。如果对任意实数 x , “ $X(\omega) \leq x$ ” 都是一个随机事件, 并有其确定的概率, 则称 $X = X(\omega)$ 为随机变量。

随机变量 $\left\{ \begin{array}{l} \text{离散型随机变量} \\ \text{连续型随机变量} \end{array} \right.$

离散型随机变量:

随机变量 X 的全部可能取值为有限个或可列个。随机变量 X 所有可能的取值为 $x_i (i = 1, 2, \dots)$, 事件 $X = x_i$ 的概率为 $P(X = x_i) = p_i, i = 1, 2, \dots$ 。上式称为离散型随机变量 X 的**概率分布或分布率**。

设 X 是一个随机变量, 对任意实数 $x (-\infty < x < +\infty)$, 令 $F(x) = P(X \leq x)$ 。则称 $F(x)$ 为随机变量 X 的**概率分布函数**。它的定义域是 $(-\infty, +\infty)$, 值域是 $[0, 1]$ 。

常见的离散型随机变量

0-1分布: 当一个随机试验只有两个可能结果 A 与 \bar{A} 时, 随机变量

$$X = \begin{cases} 0, & \text{当 } \bar{A} \text{ 出现时} \\ 1, & \text{当 } A \text{ 出现时} \end{cases}$$

X 表示在试验中事件 A 出现的次数, 并设 $P(A) = p (0 < p < 1)$, 则 X 的概率分布为

$$P(X = k) = p^k (1-p)^{1-k}, \quad k = 0, 1$$

这时称 X 服从参数为 p 的0-1分布, 记为 $X \sim B(1, p)$ 。

常见的离散型随机变量

泊松分布: 如果随机变量 X 的分布为:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

其中 $\lambda > 0$ 为常数, 则称 X 服从参数为 λ 的泊松分布, 记为 $X \sim P(\lambda)$ 。

连续型随机变量:

如果对于随机变量 X 的分布函数 $F(x)$, 存在一个非负可积函数 $f(x) (-\infty < x < +\infty)$, 有

$$F(x) = \int_{-\infty}^x f(t) dt$$

则称 X 为连续型随机变量, 函数 $f(x)$ 为其概率密度函数。

常见的连续型随机变量

均匀分布: 如果连续型随机变量 X 的概率密度函数为

$$f(x) = \begin{cases} \frac{1}{b-a}, & a \leq x \leq b \\ 0 & \text{其它} \end{cases}$$

其中 a 和 b 为常数, 则称 X 在区间 $[a, b]$ 上服从均匀分布, 记为 $X \sim U(a, b)$ 。

常见的连续型随机变量

高斯分布: 如果连续型随机变量 X 的概率密度函数为

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma_x} \exp\left\{-\frac{(x-m_x)^2}{2\sigma_x^2}\right\}, \quad -\infty < x < +\infty$$

其中 m_x 和 σ_x 为常数, 且 $\sigma_x > 0$, 则称 X 服从参数为 m_x 和 σ_x 的高斯分布(又称正态分布), 记为 $X \sim N(m_x, \sigma_x^2)$ 。

常见的连续型随机变量

瑞利分布: 如果连续型随机变量 X 的概率密度函数为

$$f(x) = \begin{cases} \frac{x}{\mu^2} e^{-\frac{x^2}{2\mu^2}}, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

其中 μ 为常数, 且 $\mu > 0$, 则称 X 服从参数为 μ 的瑞利分布。

常见的连续型随机变量

χ^2 分布: 如果连续型随机变量 X 的概率密度函数为

$$f(x) = \begin{cases} \frac{1}{2^{\frac{n}{2}} \Gamma\left(\frac{n}{2}\right)} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

其中 n 为正整数, 则称 X 服从自由度为 n 的 χ^2 分布。

常见的连续型随机变量

莱斯分布: 如果连续型随机变量 X 的概率密度函数为

$$f(x) = \begin{cases} \frac{x}{\sigma^2} e^{-\frac{(x^2+v^2)}{2\sigma^2}} I_0\left(\frac{xv}{\sigma^2}\right), & x > 0 \\ 0, & x \leq 0 \end{cases}$$

其中 σ 为常数, 且 $\sigma > 0$, $I_0(z)$ 是零阶第一类贝塞尔(Bessel)函数, 则称 X 服从莱斯分布。

1.1.3 多维随机变量

定义:

设某随机试验的样本空间为 $\Omega = \{\omega\}$, 如果每一个样本点 $\omega \in \Omega$, $X_1 = X_1(\omega)$, $X_2 = X_2(\omega)$... $X_n = X_n(\omega)$, 是定义在同一个样本空间 Ω 上的 n 个随机变量, 则 (X_1, X_2, \dots, X_n) 称为 n 维随机变量, 其矢量形式 $[X_1, X_2, \dots, X_n]^T$ 也称为随机矢量。

下面以二维为例进行说明, 更高维以此类推。

1.1.3 多维随机变量

联合分布函数:

设 (X, Y) 是二维随机变量, $F(x, y) = P(X \leq x, Y \leq y)$ 称为二维随机变量 (X, Y) 的分布函数, 或称随机变量 X 和 Y 的联合分布函数。

多维离散型随机变量:

二维随机变量 (X, Y) 所有可能的取值是有限对或可列无限多对, 并且以确定的概率取各个不同的数对

$$P(X = x_i, Y = y_j) = p_{ij}, \quad i, j = 1, 2, \dots$$

称为 (X, Y) 的联合概率分布。

多维连续型随机变量:

二维随机变量 (X, Y) 的分布函数是 $F(x, y)$, 存在非负函数 $f(x, y)$, 使得对任意实数 x, y 有

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) du dv$$

称 $f(x, y)$ 为二维连续型随机变量 (X, Y) 的联合概率密度函数。

边缘分布函数:

二维随机变量 (X, Y) 的分布函数为 $F(x, y)$, 随机变量 X 或 Y 的分布即为二维随机变量的边缘分布。它与二维变量的分布函数具有如下关系:

$$F_X(x) = P(X \leq x, Y < +\infty) = F(x, +\infty)$$

$$F_Y(y) = P(X < +\infty, Y \leq y) = F(+\infty, y)$$

条件概率与条件分布函数:

对二维离散随机变量, 在 $Y = y_i$ 条件下 $X = x_j$ 的条件概率为

$$P(X = x_j | Y = y_i) = \frac{P(X = x_j, Y = y_i)}{P(Y = y_i)}$$

其中 $P(Y = y_i)$ 表示边缘分布函数。

条件概率与条件分布函数:

对二维连续型随机变量, 设 y 是定值, 任意 $\Delta y > 0$, $P(y - \Delta y < Y \leq y + \Delta y) > 0$, 若对任意实数 x , 极限

$$\lim_{\Delta y \rightarrow 0} P(X \leq x | y - \Delta y < Y \leq y + \Delta y)$$

存在, 则称此极限为在 $Y = y$ 条件下 X 的条件分布函数, 记为 $P(X \leq x | Y = y)$ 。

独立性:

若对任意实数 x 和 y , 有 $F(x, y) = F_X(x)F_Y(y)$, 则称随机变量 X 和 Y 是独立的。

若 X 与 Y 独立, 显然有

$$P(X = x_j | Y = y_i) = \frac{P(X = x_j, Y = y_i)}{P(Y = y_i)} = P(X = x_j)$$

1.1.4 随机变量的数字特征 随机变量 X 的数学期望 (均值):

$$E\{X\} = \int_{-\infty}^{+\infty} xf(x)dx$$

基本性质:

- (1) 常量的数学期望等于常量本身。
- (2) 对于常数 a_i ($i=1, 2, \dots, n$) 则

$$E\left\{\sum_{i=1}^n a_i X_i\right\} = \sum_{i=1}^n a_i E\{X_i\}$$

- (3) 若 X_i ($i=1, 2, \dots, n$) 彼此统计独立, 则

$$E\{X_1 X_2 \cdots X_n\} = \prod_{i=1}^n E\{X_i\}$$

随机变量 X 的方差:

$$\begin{aligned} \text{Var}\{X\} &= E\left\{\left[X - E\{X\}\right]^2\right\} \\ &= \int_{-\infty}^{+\infty} (x - E\{X\})^2 f(x)dx \\ &= E\{X^2\} - (E\{X\})^2 \end{aligned}$$

通常称 $\sqrt{\text{Var}\{X\}}$ 为随机变量 X 的均方差或标准差, 习惯上用 σ_X^2 表示 $\text{Var}\{X\}$ 。

方差基本性质:

(1) $Var\{C\} = 0$, C 为常数。

(2) 对于常数 a_i ($i=1, 2, \dots, n$), 则

$$Var\left\{\sum_{i=1}^n a_i X_i\right\} = \sum_{i=1}^n \sum_{j=1}^n a_i a_j E\{(X_i - E\{X_i\})(X_j - E\{X_j\})\}$$

(3) 若 X_i ($i=1, 2, \dots, n$) 彼此统计独立, 那么

$$Var\left\{\sum_{i=1}^n a_i X_i\right\} = \sum_{i=1}^n a_i^2 Var\{X_i\}$$

(4) $E\{(X-C)^2\} \geq Var\{X\}$, C 为任意常数。

协方差:

对多维随机变量 $X = (X_1, X_2, \dots, X_n)$, X_i 与 X_j 的协方差:

$$\begin{aligned} C_{ij} &= Cov\{X_i, X_j\} \\ &= E\{(X_i - E\{X_i\})(X_j - E\{X_j\})\} \\ & \quad i, j = 1, 2, \dots, n \end{aligned}$$

显然

$$Var\{X_i\} = C_{ii}$$

相关系数:

“归一化”的协方差, 称为**相关系数**:

$$\begin{aligned} \rho_{X_i, X_j} &= \frac{E\{(X_i - E\{X_i\})(X_j - E\{X_j\})\}}{\sqrt{E\{(X_i - E\{X_i\})^2\}} \cdot \sqrt{E\{(X_j - E\{X_j\})^2\}}} \\ &= \frac{C_{ij}}{\sqrt{Var\{X_i\}} \cdot \sqrt{Var\{X_j\}}} \end{aligned}$$

协方差和相关系数的性质:

- (1) $Cov\{X, Y\} = Cov\{Y, X\}$ 。
- (2) $Cov\{aX, bY\} = abCov\{X, Y\}$, 其中 a 和 b 为常数。
- (3) $Cov\{X_1 + X_2, Y\} = Cov\{X_1, Y\} + Cov\{X_2, Y\}$ 。
- (4) $|\rho_{XY}| \leq 1$ 。
- (5) 若 X 与 Y 相互独立, 则 X 与 Y 不相关。反之不一定成立。只有 X 与 Y 服从高斯分布时, 统计独立和互不相关才是等价的。

联合分布函数:

对于 n 维随机变量 (X_1, X_2, \dots, X_n) ,

$$F(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$$

关于 X_i 的边缘分布函数:

$$F_{X_i}(x_i) = P(X_1 < +\infty, \dots, X_{i-1} < +\infty, X_i \leq x_i, X_{i+1} < +\infty, \dots, X_n < +\infty)$$

随机变量 X_1, X_2, \dots, X_n 是相互独立的, 若对于所有的 x_1, x_2, \dots, x_n , 有

$$F(x_1, x_2, \dots, x_n) = F_{X_1}(x_1) F_{X_2}(x_2) \cdots F_{X_n}(x_n)$$

特征函数:

若 X 是随机变量, 则称复随机变量 $e^{j\omega X}$ 的均值

$$\varphi(\omega) = E\{e^{j\omega X}\}$$

为 X 的特征函数。

- (1) 若 X 是离散型随机变量, 其可能取值为 x_1, x_2, \dots , 且 $P(X = x_k) = p_k$, 则 $\varphi(\omega) = \sum_k e^{j\omega x_k} p_k$
- (2) 若 X 是连续型随机变量, 其概率密度函数为 $f(x)$, 则 $\varphi(\omega) = \int_{-\infty}^{+\infty} e^{j\omega x} f(x) dx$

特征函数:

同理, 我们可推导出**多维随机变量** (X_1, X_2, \dots, X_n) 的特征函数:

$$\varphi(\omega_1, \omega_2, \dots, \omega_n) = E\left\{e^{j(\omega_1 X_1 + \omega_2 X_2 + \dots + \omega_n X_n)}\right\}$$

特征函数是概率密度函数的傅立叶变换。已知随机变量的特征函数, 可以求出它的各阶矩, 特征函数也被称为**矩生成函数**。

1.1.5 高斯随机变量

1. 一维高斯随机变量

一维高斯随机变量 X 的概率密度函数:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma_x} \exp\left[-\frac{(x-m_x)^2}{2\sigma_x^2}\right], \quad -\infty < x < +\infty$$

如果 $m_x = 0, \sigma_x^2 = 1$, 则

$$f(x) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2}\right], \quad -\infty < x < +\infty$$

2. 多维高斯随机变量

X_1, X_2, \dots, X_n 组成 n 维高斯随机变量, 令 $\mathbf{x} = [X_1, X_2, \dots, X_n]^T$

均值矢量:

$$\mathbf{m}_x = [E\{X_1\}, E\{X_2\}, \dots, E\{X_n\}]^T = [m_{x_1}, m_{x_2}, \dots, m_{x_n}]^T$$

协方差矩阵:

$$\mathbf{C}_x = \begin{bmatrix} E\{(X_1 - m_{x_1})^2\} & \dots & E\{(X_1 - m_{x_1})(X_n - m_{x_n})\} \\ \vdots & & \vdots \\ E\{(X_n - m_{x_n})(X_1 - m_{x_1})\} & \dots & E\{(X_n - m_{x_n})^2\} \end{bmatrix}$$

n 维高斯随机变量的**联合高斯概率密度函数**:

$$f(\mathbf{X}) = \frac{1}{(2\pi)^{n/2} |\mathbf{C}_x|^{1/2}} \exp\left[-\frac{(\mathbf{X} - \mathbf{m}_x)^T \mathbf{C}_x^{-1} (\mathbf{X} - \mathbf{m}_x)}{2}\right]$$

性质:

- (1) n 维高斯随机变量经过线性变换后仍是高斯随机变量。
- (2) n 维互不相关的高斯随机变量一定是彼此统计独立的。
- (3) 一般的 n 维随机变量, 若它们彼此统计独立, 则必然互不相关, 反之, 则不一定成立。

1. 一维随机变量函数的分布

X 是连续型随机变量, 概率密度函数为 $f(x), -\infty < x < +\infty$, $g(x)$ 处处可导且有 $g'(x) > 0$ (或恒有 $g'(x) < 0$), 则 $Y = g(X)$ 也是一个连续型随机变量, 其概率密度函数为

$$f(y) = \begin{cases} f(h(y)) |h'(y)|, & \alpha < y < \beta \\ 0, & \text{其他} \end{cases}$$

其中 $\alpha = \min\{g(-\infty), g(+\infty)\}$, $\beta = \max\{g(-\infty), g(+\infty)\}$, $h(y)$ 是 $g(x)$ 的反函数。

特别地, 若随机变量 $X \sim N(\mu, \sigma^2)$, 令随机变量 $Y = \frac{X - \mu}{\sigma}$, 则 $Y \sim N(0, 1)$ 。

2. 多维随机变量函数的分布

(X_1, X_2, \dots, X_n) 是具有概率密度函数 $f(x_1, x_2, \dots, x_n)$ 的连续型 n 维随机变量, 假设

- (1) $Y_i = g_i(X_1, X_2, \dots, X_n), \dots, Y_n = g_n(X_1, X_2, \dots, X_n)$ 是 n 维实数空间到自身的一对一映射;
- (2) 变换 g 和它的逆 h 都是连续的;
- (3) 偏导数 $\frac{\partial h_j}{\partial y_i}, i=1, 2, \dots, n, j=1, 2, \dots, n$ 存在且连续;
- (4) 逆变换的雅可比行列式

$$J(y_1, y_2, \dots, y_n) = \begin{vmatrix} \frac{\partial h_1}{\partial y_1} & \frac{\partial h_1}{\partial y_2} & \dots & \frac{\partial h_1}{\partial y_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial h_n}{\partial y_1} & \frac{\partial h_n}{\partial y_2} & \dots & \frac{\partial h_n}{\partial y_n} \end{vmatrix} \neq 0$$

则 (Y_1, Y_2, \dots, Y_n) 具有联合概率密度函数

$$f(y_1, y_2, \dots, y_n) = |J| f(h_1(y_1, y_2, \dots, y_n), \dots, h_n(y_1, y_2, \dots, y_n))$$

1.1.7 复随机变量

复随机变量
 $Z = X_1 + jX_2$, 其中, X_1 和 X_2 为两个实随机变量。

概率密度函数
 $f(z) = f(x_1, x_2)$, $f(z)$ 显然是一个实数。

均值
 $m_z = E\{Z\} = E\{X_1 + jX_2\} = \int_{-\infty}^{+\infty} (x_1 + jx_2) f(x_1, x_2) dx_1 dx_2$

方差
 $\sigma_z^2 = E\{|Z - m_z|^2\} = \sigma_{x_1}^2 + \sigma_{x_2}^2 = E\{|Z|^2\} - m_z^2$

对于两个复随机变量 $W = U_1 + jU_2, Z = X_1 + jX_2$,

$$f(w, z) = f(x_1, x_2, u_1, u_2)$$

其协方差为

$$C_{wz} = E\{(W - m_w)(Z - m_z)^*\}$$

相关系数为

$$\rho_{wz} = \frac{C_{wz}}{\sigma_w \sigma_z}$$

对于复随机矢量 w 和 z , 协方差矩阵和互协方差矩阵分别为

$$C_z = E\{(z - m_z)(z - m_z)^H\}$$

$$C_{wz} = E\{(w - m_w)(z - m_z)^H\}$$

复高斯随机矢量的概率密度函数为

$$f(z) = \frac{1}{\pi^n |C_z|} \exp\left[-(z - m_z)^H C_z^{-1} (z - m_z)\right]$$

高斯随机变量的特征函数为

$$\varphi(\omega) = \exp\left(j \operatorname{Re}\{\omega^H m_z\} - \frac{\omega^H C_z \omega}{4}\right)$$

1.2 随机过程基础

1.2.1 平稳与非平稳随机过程

1.2.2 随机过程的统计特性与维纳-辛钦定理

1.2.3 高斯随机过程

1.2.4 随机过程的积分微分特性

自然界存在一类随机现象, 与之相联系的随机事件不能用一般的单维或多维随机变量去描述它。如:

- 用 $x(t)$ 表示 t 时刻以前某通信站接到的呼唤次数, 对于某个固定的 t , $x(t)$ 是一个随机量, 但 $x(t)$ 这类随机量将随着 t 的变化而变化;
- 电网电压可看作随时间变化的随机量 $V(t)$;
- 雷达接收机的噪声输出 $n(t)$ 。

用随机过程才能描述的随机现象, 每做一次随机试验, 随机试验的结果应是某一个随机现实, 每一次随机试验之前, 其试验结果究竟属于哪一种随机现实, 事先不能预测。

设 $T \subset \mathbb{R}^1$, 对于每一个 $t \in T$, $x_t(\omega)$ 为一随机变量。其中 ω 代表某概率空间 (Ω, F, P) 的元素, 则 $\{x_t(\omega), t \in T\}$ 即为 **随机过程**。简记为 $\{x(t), t \in T\}$ 。

1.2.1 平稳与非平稳随机过程

定义:

如果由 $\{x(t)\}$ 所确定的 n 维概率密度函数 $f(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n)$ 满足

$$f(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = f(x_1, x_2, \dots, x_n; t_1 + \tau, t_2 + \tau, \dots, t_n + \tau)$$

称 $\{x(t)\}$ 为**严格平稳随机过程**，又称为**强平稳随机过程**或**狭义平稳随机过程**。

1.2.1 平稳与非平稳随机过程

定义:

当 $E\{x^2(t)\} < +\infty$ 时, 若满足:

$$E\{x(t)\} = E\{x(t+\tau)\}$$

$$E\{x(t_1)x(t_2)\} = E\{x(t_1+\tau)x(t_2+\tau)\}$$

称 $\{x(t)\}$ 为**广义平稳随机过程**，又称为**弱平稳随机过程**或**宽平稳随机过程**。

讨论:

当 $E\{x^2(t)\} < +\infty$ 时, 严格平稳随机过程也是广义平稳的, 但广义平稳随机过程不一定是严格平稳的。

有一类随机过程, 其本质是随机过程, 但其表示形式却类似确定过程, 称为**准随机过程**。

例: $\left\{ \begin{aligned} x(t) &= \sum_{k=0}^{\tau} \xi_k t^k \\ x(t) &= A \sin(\omega_0 t + \theta) \end{aligned} \right\}$, $\xi_k (k=1, 2, \dots, \tau)$ 为随机变量; A, θ 为随机变量。

复随机过程:

$$\{z(t) = x(t) + jy(t)\}$$

其概率密度函数为

$$f(x_1, x_2, \dots, x_n; y_1, y_2, \dots, y_n; t_1, t_2, \dots, t_n)$$

高斯随机过程

任意时刻 t_1, t_2, \dots, t_n , 随机过程 $\{x(t)\}$ 所形成的 n 维随机变量, 其概率密度函数为高斯分布

$$f(x_1, x_2, \dots, x_n; t_1, t_2, \dots, t_n) = \frac{1}{(2\pi)^{n/2} |C_x|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_x)^T C_x^{-1} (\mathbf{x} - \mathbf{m}_x)\right]$$

这时称随机过程 $\{x(t)\}$ 为**高斯过程**。

性质:

- 若高斯随机过程是广义平稳的, 则一定是严格平稳的。
- 高斯随机过程经过线性变换, 其输出仍是高斯随机过程。

1.2.2 随机过程的统计特性与维纳-辛钦定理

1. 随机过程的统计特性

时间平均:

随机过程 $\{x(t)\}$ 的第 k 个现实为 $x^{(k)}(t)$, 相应有:

时间平均均值:

$$\langle x^{(k)}(t) \rangle = \lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^T x^{(k)}(t) dt$$

时间平均二阶矩:

$$\langle [x^{(k)}(t)]^2 \rangle = \lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^T [x^{(k)}(t)]^2 dt$$

时间平均相关函数:

$$\langle x^{(k)}(t)x^{(k)}(t-\tau) \rangle = \lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^T x^{(k)}(t)x^{(k)}(t-\tau) dt$$

时间平均互相关:

$$\langle x^{(k)}(t)y^{(k)}(t-\tau) \rangle = \lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^T x^{(k)}(t)y^{(k)}(t-\tau) dt$$

随机过程统计平均（集平均）

随机过程的均值：

$$E\{x(t)\} = \int_{-\infty}^{+\infty} xf(x;t)dx = m_x(t)$$

随机过程的方差：

$$E\{[x(t) - m_x(t)]^2\} = \int_{-\infty}^{+\infty} [x - m_x(t)]^2 f(x;t)dx = \sigma_x^2(t)$$

随机过程的自相关函数：

$$E\{x(t_1)x(t_2)\} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_1x_2f(x_1, x_2; t_1, t_2)dx_1dx_2 = R_x(t_1, t_2)$$

讨论：随机过程 $\{x(t)\}$ 的自相关函数满足对称性，即

$$R_x(t_1, t_2) = R_x(t_2, t_1)$$

对于非平稳随机过程，其均值、方差及自相关函数都是 t 的函数，其自相关函数可用 $R_x(t, \tau)$ 表示。

• 对于严格平稳随机过程，

$$f(x; t) = f(x; t + \tau) = f(x)$$

$$f(x_1, x_2; t_1, t_2) = f(x_1, x_2; t_1 - t_2 = \tau) = f(x_1, x_2; \tau)$$

值与 t 无关， $R_x(t_1, t_2) = R_x(\tau)$ 只与 $\tau = t_1 - t_2$ 有关。

• 对于广义平稳随机过程，均值与 t 无关，自相关函数是 $\tau = t_1 - t_2$ 的函数。

随机过程的相关系数：

$$\rho_x(t_1, t_2) = \frac{E\{[x(t_1) - m(t_1)][x(t_2) - m(t_2)]\}}{\sigma_1\sigma_2}$$

对于平稳随机过程，有 $\rho_x(\tau) = \frac{R_x(\tau) - m^2}{\sigma^2}$

随机过程的互相关函数：

随机过程 $\{x(t)\}, \{y(t)\}$ ，前者对于后者的互相关函数：

$$R_{xy}(t_1, t_2) = E\{x(t_1)y(t_2)\} = \iint x_1y_2f(x_1, y_2; t_1, t_2)dx_1dy_2$$

后者对于前者的互相关函数：

$$R_{yx}(t_1, t_2) = E\{y(t_1)x(t_2)\} = \iint y_1x_2f(y_1, x_2; t_1, t_2)dy_1dx_2$$

随机过程的协方差函数：

$$C_x(t_1, t_2) = E\{(x(t_1) - m_1)(x(t_2) - m_2)\} = R_x(t_1, t_2) - m_1m_2$$

讨论：协方差函数亦具有对称性。

对于平稳随机过程，

$$C_x(t_1, t_2) = C_x(t_1 - t_2) = C_x(\tau) = R_x(\tau) - m^2$$

对于联合随机过程，互协方差函数为：

$$C_{xy}(t_1, t_2) = E\{[x(t_1) - m_x(t_1)][y(t_2) - m_y(t_2)]\} = R_{xy}(t_1, t_2) - m_x(t_1)m_y(t_2)$$

$$C_{yx}(t_1, t_2) = E\{[y(t_1) - m_y(t_1)][x(t_2) - m_x(t_2)]\} = R_{yx}(t_1, t_2) - m_y(t_1)m_x(t_2)$$

显然，互协方差函数不具有对称性。

随机过程各态历经性

平稳随机过程的所有各类集平均统计特征，以概率1等于由任意实现得到的相应的时间平均特征。

各态历经性的意义：

2. 维纳-辛钦定理

确定信号 $s(t)$ 如满足 $E = \int_{-\infty}^{+\infty} s^2(t)dt < +\infty$ ，则为能量信号。满足 $P = \lim_{T \rightarrow +\infty} \frac{1}{T} \int_{-T/2}^{T/2} s^2(t)dt < +\infty$ 的确定信号为功率信号。

维纳-辛钦定理：

平稳随机信号的功率谱密度是其相关函数的傅里叶变换，即：

$$S_x(\omega) = \int_{-\infty}^{+\infty} R_x(\tau)e^{-j\omega\tau}d\tau \quad R_x(\tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_x(\omega)e^{j\omega\tau}d\omega$$

以上两式成立的条件是

$$\int_{-\infty}^{+\infty} S_x(\omega)d\omega < +\infty, \quad \int_{-\infty}^{+\infty} |R_x(\tau)|d\tau < +\infty$$

1.3 线性代数导论

- 1.3.1 矩阵的概念和基本运算
- 1.3.2 特殊矩阵
- 1.3.3 矩阵的分解
- 1.3.4 子空间
- 1.3.5 矩阵的逆
- 1.3.6 梯度分析

1.3.1 矩阵的概念和基本运算

- 矩阵、矢量概念
- 基本运算
 - 转置
 - 共轭
 - 共轭转置
 - 内积
 - 矩阵的逆（广义逆）

把 n 阶方阵 A 中元素 a_{ij} 所在的第 i 行和第 j 列划去后，剩下的 $n-1$ 阶方阵称为元素 a_{ij} 的余子矩阵，记为 $(-1)^{i+j} \det\{A(i,j)\}$ ， $A(i,j)$ 为元素 a_{ij} 的余子式。
 $\text{cof}(A_{ij}) = \det\{A(i,j)\}$ 称为元素 a_{ij} 的代数余子式，记为 A_{ij} 。

行列式

特别地，当 $\det\{A\} = 0$ 时， A 称为奇异（退化）方阵；否则称为非奇异（非退化）方阵，也称正则矩阵。

设 A 和 B 是 n 阶方阵，则

$$\det\{AB\} = \det\{A\} \det\{B\}$$

设矩阵 $A \in \mathbb{C}^{m \times n}$ 有一个 k 阶子式不等于零，而 A 的所有 $k+1$ 阶子式（若存在）都等于零，则称正整数 k 为矩阵 A 的秩。

若 $m=n=k$ ，则称之为满秩矩阵；

若 $k=0$ ，则称为零秩矩阵。

设矩阵 A 为 n 阶方阵，如对于任意 n 阶非零列矢量 x ，有：

- (1) 当 $\text{Re}\{x^H Ax\} > 0$ 时，则称 A 为**正定矩阵**；
- (2) 当 $\text{Re}\{x^H Ax\} \geq 0$ 时，则称 A 为**半正定（非负定）矩阵**；
- (3) 当 $\text{Re}\{x^H Ax\} < 0$ 时，则称 A 为**负定矩阵**。

如矩阵 A 的某个函数 $\|A\|$ ，满足：

- (1) A 为非零矩阵时， $\|A\| > 0$ ； $A = \mathbf{O}$ 时， $\|A\| = 0$ ；
- (2) 对于任意复数 c 有 $\|cA\| = |c| \|A\|$ ；
- (3) $\|A+B\| \leq \|A\| + \|B\|$ ；
- (4) $\|AB\| \leq \|A\| \|B\|$ 。

则称 $\|A\|$ 是 $\mathbb{C}^{m \times n}$ 上的一个**矩阵范数**。

常用的矩阵范数:

(1) Frobenius范数

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

(2) 行和范数

$$\|A\|_{\text{row}} = \max_{1 \leq i \leq m} \left\{ \sum_{j=1}^n |a_{ij}| \right\}$$

(3) 列和范数

$$\|A\|_{\text{col}} = \max_{1 \leq j \leq n} \left\{ \sum_{i=1}^m |a_{ij}| \right\}$$

施瓦兹不等式:

设 $A \in \mathbb{C}^{m \times n}, B \in \mathbb{C}^{n \times l}$, AA^T 可逆, 则

$$B^T B \geq (AB)^T (AA^T)^{-1} (AB)$$

等号成立的充要条件是存在 $C \in \mathbb{C}^{m \times l}$, 使得

$$B = A^T C.$$

1.3.2 特殊矩阵

- 单位矩阵 反向单位矩阵
- 厄米特矩阵 反厄米特矩阵
- 范德蒙矩阵
- 汉克矩阵
- 托普利兹矩阵
- 正规矩阵
- 酉矩阵
- 正交矩阵

1.3.3 矩阵分解

常用的矩阵分解方法:

- 特征值分解(EVD)
- 奇异值分解(SVD)
- Cholesky分解
- LU分解
- QR分解

1. 特征值分解

特征值与特征矢量

若 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 n 阶方阵 A 的特征值, u_1, u_2, \dots, u_n 分别是与特征值对应的特征矢量, 则

$$A = E \Lambda E^{-1}$$

其中 $E = [u_1, u_2, \dots, u_n]$, $\Lambda = \text{diag} \{ \lambda_1, \lambda_2, \dots, \lambda_n \}$ 。

上述分解称为矩阵 A 的特征值分解。

2. 奇异值分解

对于矩阵 A , λ_i 为 $A^H A$ 的特征值, 则称 $\sigma_i = \lambda_i^{1/2}$ 为 A 的奇异值。

若 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$ 为矩阵 A 的奇异值, 则存在酉

阵 U 和 V , 使得 $A = U \Sigma V^H$, 式 $\Sigma = \begin{bmatrix} \Sigma_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$, 且

$\Sigma_1 = \text{diag} \{ \delta_1, \delta_2, \dots, \delta_r \}$, $|\delta_i| = \sigma_i$ 。上述分解称为矩阵 A 的奇异值分解。

3. Cholesky分解

方阵 A 是正定矩阵, $A = GG^H$ 称为矩阵 A 的 **Cholesky分解**, 其中, G 是一个具有正的对角线元素的下三角矩阵, 即

$$G = \begin{bmatrix} g_{11} & & 0 \\ g_{21} & g_{22} & \\ \vdots & \vdots & \ddots \\ g_{n1} & g_{n2} & \cdots & g_{nn} \end{bmatrix}$$

若 A 是正定矩阵, 则其Cholesky分解是唯一的。

4. LU分解

$A \in \mathbb{C}^{m \times n}$, 则 $A = LU$ 称为**矩阵的LU分解**。其中, L 为 $m \times m$ 单位下三角矩阵(对角线为1的下三角矩阵), U 是 A 的 $m \times n$ 上阶梯型矩阵。

如果 $A \in \mathbb{C}^{n \times n}$ 非奇异, 并且其LU分解存在的话, 则 A 的LU分解是唯一的, 且 $\det\{A\} = u_{11}u_{22} \cdots u_{nn}$ 。

5. QR分解

$A \in \mathbb{C}^{m \times n}$, 且 $m \geq n$, 则存在列正交阵 $Q \in \mathbb{C}^{m \times m}$ 和上三角矩阵 $R \in \mathbb{C}^{n \times n}$, 使得 $A = QR$ 。

当 $m = n$ 时, Q 是正交矩阵。若 A 是非奇异的 $n \times n$ 矩阵, 则 R 的所有对角线元素均为正, 并且在这种情况下, R 和 Q 二者是唯一的。

1.3.4 子空间

n 维复矢量空间 \mathbb{C}^n 是所有 n 维复矢量的集合。令 $m < n$, 则 m 个 n 维复矢量的子集便构成 \mathbb{C}^n 内的一个**矢量子空间**。若 $S = \{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_m\}$ 是矢量空间 V 的矢量子集, 则 $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_m$ 的所有线性组合的集合 W 称为由 $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_m$ 张成的**子空间**, 定义为

$$W = \text{Span}\{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_m\} \\ = \{\mathbf{u} : \mathbf{u} = a_1\mathbf{u}_1 + a_2\mathbf{u}_2 + \cdots + a_m\mathbf{u}_m\}$$

只包含了一个零矢量的矢量子空间称为**平凡子空间**。

子空间 W 的任何一组基的矢量个数称为 W 的**维数**, 用符号 $\dim(W)$ 表示。

若 W 的任何一组基都不是由有限个线性无关的矢量组成时, 则称 W 是**无限维矢量子空间**。

若某一向量与子空间 W 的所有向量都正交, 则称该向量正交于子空间 W 。若 $\forall \mathbf{a}_i \in W_i, \mathbf{a}_j \in W_j (i \neq j)$, 恒有 $\mathbf{a}_i \perp \mathbf{a}_j$, 则称子空间 W_i, W_j 为**正交子空间**, 记作 $W_i \perp W_j (i \neq j)$ 。

特别地, 与子空间 W 正交的所有向量的集合组成的矢量子空间, 称为 W 的**正交补空间**, 记作

$$W^\perp = \{\mathbf{x} | \mathbf{x}^T \mathbf{y} = 0, \forall \mathbf{y} \in W\}$$

1.3.6 梯度分析

$n \times 1$ 矢量 \mathbf{x} 的**梯度算子**记作

$$\nabla_x = \left[\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n} \right]^T = \frac{\partial}{\partial \mathbf{x}}$$

以 $n \times 1$ 实矢量 \mathbf{x} 为变元的实标量函数 $f(\mathbf{x})$ 相对于 \mathbf{x} 的梯度为

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

可见:

- 一个以矢量为变元的标量函数的梯度为一矢量。
- 梯度的每个分量给出了标量函数在该分量方向上的变化率。

类似地，实值函数 $f(\mathbf{x})$ 相对于 $1 \times n$ 行矢量 \mathbf{x}^T 的梯度

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

$1 \times m$ 行矢量函数 $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})]$ 相对于 $n \times 1$ 实矢量 \mathbf{x} 的梯度为

$$\frac{\partial \mathbf{f}(\mathbf{x})}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \frac{\partial f_2(\mathbf{x})}{\partial x_1} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_1} \\ \frac{\partial f_1(\mathbf{x})}{\partial x_2} & \frac{\partial f_2(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_1(\mathbf{x})}{\partial x_n} & \frac{\partial f_2(\mathbf{x})}{\partial x_n} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_n} \end{bmatrix} = \nabla_{\mathbf{x}} \mathbf{f}(\mathbf{x})$$

复矢量函数的梯度

引入复数求导的定义，若 $f(w)$ 是复数 w 的函数，其中

$$w = w_r + jw_i, \text{ 则 } \frac{df(w)}{dw} = \frac{1}{2} \left(\frac{\partial f(w)}{\partial w_r} - j \frac{\partial f(w)}{\partial w_i} \right)$$

$$\frac{df(w)}{dw^*} = \frac{1}{2} \left(\frac{\partial f(w)}{\partial w_r} + j \frac{\partial f(w)}{\partial w_i} \right)$$

那么，目标函数相对于复矢量的梯度定义为

$$\frac{\partial \mathbf{f}(\mathbf{w})}{\partial \mathbf{w}} = \nabla_{\mathbf{w}} \mathbf{f}(\mathbf{w}) = \left[\frac{\partial f_1(\mathbf{w})}{\partial w_1}, \frac{\partial f_2(\mathbf{w})}{\partial w_2}, \dots, \frac{\partial f_m(\mathbf{w})}{\partial w_n} \right]^T$$

共轭梯度（矢量）

$$\frac{\partial \mathbf{f}(\mathbf{w})}{\partial \mathbf{w}^*} = \nabla_{\mathbf{w}^*} \mathbf{f}(\mathbf{w}) = \left[\frac{\partial f_1(\mathbf{w})}{\partial w_1^*}, \frac{\partial f_2(\mathbf{w})}{\partial w_2^*}, \dots, \frac{\partial f_m(\mathbf{w})}{\partial w_n^*} \right]^T$$

若复行矢量函数 $\mathbf{f}(\mathbf{w}) = [f_1(\mathbf{w}), f_2(\mathbf{w}), \dots, f_m(\mathbf{w})]$ ，
则其相对于复列矢量的梯度为

$$\frac{\partial \mathbf{f}(\mathbf{w})}{\partial \mathbf{w}} = \begin{bmatrix} \frac{\partial f_1(\mathbf{w})}{\partial w_1} & \frac{\partial f_2(\mathbf{w})}{\partial w_1} & \dots & \frac{\partial f_m(\mathbf{w})}{\partial w_1} \\ \frac{\partial f_1(\mathbf{w})}{\partial w_2} & \frac{\partial f_2(\mathbf{w})}{\partial w_2} & \dots & \frac{\partial f_m(\mathbf{w})}{\partial w_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_1(\mathbf{w})}{\partial w_n} & \frac{\partial f_2(\mathbf{w})}{\partial w_n} & \dots & \frac{\partial f_m(\mathbf{w})}{\partial w_n} \end{bmatrix}$$

类似地，行矢量函数相对于复共轭列矢量的梯度称为共轭梯度矩阵，定义为

$$\frac{\partial \mathbf{f}(\mathbf{w})}{\partial \mathbf{w}^*} = \begin{bmatrix} \frac{\partial f_1(\mathbf{w})}{\partial w_1^*} & \frac{\partial f_2(\mathbf{w})}{\partial w_1^*} & \dots & \frac{\partial f_m(\mathbf{w})}{\partial w_1^*} \\ \frac{\partial f_1(\mathbf{w})}{\partial w_2^*} & \frac{\partial f_2(\mathbf{w})}{\partial w_2^*} & \dots & \frac{\partial f_m(\mathbf{w})}{\partial w_2^*} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_1(\mathbf{w})}{\partial w_n^*} & \frac{\partial f_2(\mathbf{w})}{\partial w_n^*} & \dots & \frac{\partial f_m(\mathbf{w})}{\partial w_n^*} \end{bmatrix}$$

结论：

任何一个复矢量 \mathbf{w} 和它的共轭矢量 \mathbf{w}^* 都可以当作两个独立的复变元处理，即在求梯度的过程中，复矢量相对于其共轭矢量可视为一常数；反之， \mathbf{w}^* 相对于 \mathbf{w} 也可视为一常数。

本章内容小结

- 1 概率论概要
- 2 随机过程基础
- 3 线性代数导论