

为了能够顺利阅读后面章节,本章对与本书有关的概率论基本内容作简要介绍.

1.1 概率论的基本概念

定义 1.1 设随机试验 E 的样本空间为 Ω , Ω 的某些子集组成集类 \mathfrak{F} , 称 \mathfrak{F} 为随机试验 E 的事件域, 如果它满足下列条件:

- (1) $\Omega \in \mathfrak{F}$;
- (2) 若 $A \in \mathfrak{F}$, 则 $A^c \in \mathfrak{F}$;
- (3) 若 $A_j \in \mathfrak{F}, j=1, 2, \dots$, 则 $\bigcup_{j=1}^{\infty} A_j \in \mathfrak{F}$.

称 \mathfrak{F} 中的元素为随机事件, 简称事件.

样本空间 Ω 的全体子集构成的集合就是随机试验 E 的一个事件域.

定义 1.2 对事件域 \mathfrak{F} 中的每个事件 A 赋予一个实数, 记为 $P(A)$, 称为事件 A 的概率, 如果集合函数 $P(\cdot)$ 满足下列条件:

- (1) 对任一 $A \in \mathfrak{F}, P(A) \geq 0$;
- (2) $P(\Omega) = 1$;
- (3) 对两两互不相容事件 A_1, A_2, \dots (即当 $j \neq k$ 时, $A_j \cap A_k = \emptyset$) 有

$$P\left(\bigcup_{j=1}^{\infty} A_j\right) = \sum_{j=1}^{\infty} P(A_j).$$

三元组 $(\Omega, \mathfrak{F}, P)$ 称为概率空间.

如果定义在样本空间 Ω 上的单实值函数 ξ , 对任意实函数 $x, \{\omega \mid \xi(\omega) \leq x\}$ (简记为 $\{\xi \leq x\}$) 均为事件, 即 $\{\xi \leq x\} \in \mathfrak{F}$, 则称 ξ 为随机变量. 称 $F(x) = P\{\xi \leq x\}, x \in \mathbb{R}$ 为随机变量 ξ 的分布函数.

设 X, Y 为随机变量, 施瓦茨 (Schwarz) 不等式 $E(|XY|) \leq \sqrt{E(X^2)} \sqrt{E(Y^2)}$ 成立.

1.2 随机变量的特征函数

1.2.1 复随机变量

定义 1.3 如果 X 与 Y 都是实随机变量, 称 $Z = X + iY$ 为复随机变量, 其中 $i = \sqrt{-1}$.

复随机变量 Z 的数学期望定义为 $E(Z) = E(X) + iE(Y)$, 其中 $E(X), E(Y)$ 分别是实随机变量 X, Y 的数学期望.

若 X 是实随机变量, 对任意的实数 t , 显然 e^{itX} 是复随机变量.

1.2.2 特征函数的定义

定义 1.4 设 X 是实随机变量, 则对任意实数 t , 有

$$\varphi(t) = E(e^{itX}) = E(\cos tX + i \sin tX) = E(\cos tX) + iE(\sin tX).$$

称 $\varphi(t)$ 为随机变量 X 的**特征函数**.

设离散型随机变量 X 的分布律为

$$p_k = P\{X = x_k\}, \quad k = 1, 2, \dots,$$

则 X 的特征函数可表示成

$$\varphi(t) = E(e^{itX}) = \sum_{k=1}^{\infty} e^{itx_k} p_k. \quad (1.1)$$

设连续型随机变量 X 的概率密度为 $f(x)$, 则 X 的特征函数可表示为

$$\varphi(t) = E(e^{itX}) = \int_{-\infty}^{+\infty} e^{itx} f(x) dx. \quad (1.2)$$

一般地, 设随机变量 X 的分布函数为 $F(x)$, 则 X 的特征函数可表示为

$$\varphi(t) = E(e^{itX}) = \int_{-\infty}^{+\infty} e^{itx} dF(x). \quad (1.3)$$

由(1.2)式可见, 连续型随机变量的特征函数 $\varphi(t)$ 是概率密度 $f(x)$ 的傅里叶积分, 简称 F 积分. (1.3)式表明随机变量的特征函数 $\varphi(t)$ 是分布函数 $F(x)$ 的傅里叶-斯蒂尔吉斯积分或 F - S 积分.

例 1.1 设离散型随机变量 X 的分布律为

X	-1	0	1
p_k	0.25	0.5	0.25

求 X 的特征函数.

解 $\varphi(t) = E(e^{itX}) = 0.25e^{-it} + 0.5e^{i0t} + 0.25e^{it} = 0.5\cos t + 0.5$.

下面计算一些重要概率分布的特征函数.

1.2.3 重要概率分布的特征函数

例 1.2(二项分布的特征函数) 设随机变量 X 的分布律为 $P\{X = k\} = C_n^k p^k q^{n-k}$, 其中 $0 < p < 1, q = 1 - p, k = 0, 1, 2, \dots, n$, 求随机变量 X 的特征函数.

解 $\varphi(t) = \sum_{k=0}^n e^{itk} C_n^k p^k q^{n-k} = (pe^{it} + q)^n$.

当 $n=1$ 时, X 服从(0-1)分布, 其特征函数为

$$\varphi(t) = pe^{it} + q, \quad t \in \mathbb{R}.$$

例 1.3(泊松分布的特征函数) 设随机变量 X 的分布律为 $P\{X = k\} = \frac{\lambda^k}{k!} e^{-\lambda}$, 其中 $\lambda > 0, k = 0, 1, 2, \dots$, 求随机变量 X 的特征函数.

解 $\varphi(t) = \sum_{k=0}^{\infty} e^{itk} \frac{\lambda^k}{k!} e^{-\lambda} = e^{-\lambda} \sum_{k=0}^{\infty} \frac{(\lambda e^{it})^k}{k!} = e^{-\lambda} e^{\lambda e^{it}} = e^{\lambda(e^{it}-1)}, \quad t \in \mathbb{R}.$

例 1.4(指数分布的特征函数) 设 X 服从参数为 λ 的指数分布, 求 X 的特征函数.

解 X 的概率密度函数为

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

根据特征函数的定义有

$$\begin{aligned} \varphi(t) &= E(e^{itX}) = \int_{-\infty}^{+\infty} e^{itx} f(x) dx \\ &= \int_0^{+\infty} e^{itx} \lambda e^{-\lambda x} dx = \lambda \int_0^{+\infty} e^{(it-\lambda)x} dx = \frac{\lambda}{\lambda - it} = \left(1 - \frac{it}{\lambda}\right)^{-1}, \quad t \in \mathbb{R}. \end{aligned}$$

例 1.5(正态分布的特征函数) 设随机变量 X 服从正态分布 $N(a, \sigma^2)$, 其中 $-\infty < a < +\infty, \sigma > 0$, 求 X 的特征函数.

解 X 的概率密度是

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-a)^2}{2\sigma^2}}, \quad -\infty < x < +\infty,$$

故得

$$\begin{aligned} \varphi(t) &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{+\infty} e^{itx} e^{-\frac{(x-a)^2}{2\sigma^2}} dx \stackrel{\text{令 } u = \frac{x-a}{\sigma}}{=} \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{it(a+\sigma u)} e^{-\frac{u^2}{2}} du \\ &= \frac{1}{\sqrt{2\pi}} e^{ita - \frac{\sigma^2 t^2}{2}} \int_{-\infty}^{+\infty} e^{-\frac{(u-it\sigma)^2}{2}} du \\ &= e^{iat - \frac{1}{2}\sigma^2 t^2}. \end{aligned}$$

特殊地, 标准正态分布 $N(0, 1)$ 的特征函数为

$$\varphi(t) = e^{-\frac{1}{2}t^2}, \quad t \in \mathbb{R}.$$

唯一性定理 分布函数 $F(x)$ 与其特征函数 $\varphi(t)$ 是一一对应的.

例如, 例 1.1 中的特征函数 $\varphi(t) = 0.5 \cos t + 0.5$ 对应的分布律为

X	-1	0	1
p_k	0.25	0.5	0.25

1.2.4 特征函数的性质

性质 1 和性质 6 仅对连续概率分布的情形证明特征函数的性质.

性质 1 $|\varphi(t)| \leq \varphi(0) = 1$.

证明 $\varphi(0) = E(e^{i0X}) = 1$.

$$|\varphi(t)| = |E(e^{itX})| = \left| \int_{-\infty}^{+\infty} e^{itx} f(x) dx \right| \leq \int_{-\infty}^{+\infty} |e^{itx}| f(x) dx = \int_{-\infty}^{+\infty} f(x) dx = 1.$$

性质 2 共轭对称性 $\varphi(-t) = \overline{\varphi(t)}$.

证明 $\varphi(-t) = E(e^{-itX}) = E[\cos(-tX)] + iE[\sin(-tX)]$
 $= E(\cos tX) - iE(\sin tX) = \overline{E(\cos tX) + iE(\sin tX)} = \overline{\varphi(t)}.$

性质 3 特征函数 $\varphi(t)$ 在区间 $(-\infty, +\infty)$ 上一致连续.

证明 略.

性质 4 设随机变量 $Y = aX + b$, 其中 a, b 是常数, 则

$$\varphi_Y(t) = e^{ibt} \varphi_X(at),$$

其中 $\varphi_X(t), \varphi_Y(t)$ 分别表示随机变量 X, Y 的特征函数.

证明 $\varphi_Y(t) = E(e^{itY}) = E(e^{it(aX+b)}) = e^{ibt} E(e^{i(at)X}) = e^{ibt} \varphi_X(at).$

性质 5 设随机变量 X, Y 相互独立, 又 $Z = X + Y$, 则

$$\varphi_Z(t) = \varphi_X(t) \varphi_Y(t).$$

证明 $\varphi_Z(t) = E(e^{itZ}) = E[e^{it(X+Y)}] = E(e^{itX} \cdot e^{itY}) = E(e^{itX}) E(e^{itY}) = \varphi_X(t) \varphi_Y(t).$

性质 6 设随机变量 X 的 n 阶原点矩存在, 则它的特征函数 $\varphi(t)$ 的 k 阶导数 $\varphi^{(k)}(t)$ 存在, 且有

$$\varphi^{(k)}(0) = i^k E(X^k) \text{ 或 } E(X^k) = i^{-k} \varphi^{(k)}(0), \quad k = 1, 2, \dots, n.$$

证明 因 $\varphi(t) = E(e^{itX}) = \int_{-\infty}^{+\infty} e^{itx} f(x) dx$, 故

$$\begin{aligned} \varphi^{(k)}(t) &= \frac{d^k}{dt^k} \int_{-\infty}^{+\infty} e^{itx} f(x) dx = \int_{-\infty}^{+\infty} \frac{d^k}{dt^k} e^{itx} f(x) dx \\ &= \int_{-\infty}^{+\infty} i^k x^k e^{itx} f(x) dx = i^k \int_{-\infty}^{+\infty} x^k e^{itx} f(x) dx. \end{aligned}$$

因而

$$\varphi^{(k)}(0) = i^k \int_{-\infty}^{+\infty} x^k f(x) dx = i^k E(X^k), \quad k = 1, 2, \dots, n.$$

上述推导过程中 $\frac{d^k}{dt^k} \int_{-\infty}^{+\infty} e^{itx} f(x) dx = \int_{-\infty}^{+\infty} \frac{d^k}{dt^k} e^{itx} f(x) dx$ 成立, 需要满足条件

$$\int_{-\infty}^{+\infty} \left| \frac{d^k}{dt^k} e^{itx} \right| f(x) dx < +\infty, \quad \text{即} \int_{-\infty}^{+\infty} |i^k x^k e^{itx}| f(x) dx < +\infty.$$

事实上, 由于 X 的 n 阶原点矩存在, 所以 $E(|X|^k) < +\infty, k = 1, 2, \dots, n$, 从而

$$\int_{-\infty}^{+\infty} \left| \frac{d^k}{dt^k} e^{itx} \right| f(x) dx = \int_{-\infty}^{+\infty} |i^k x^k e^{itx}| f(x) dx \leq \int_{-\infty}^{+\infty} |x|^k f(x) dx < +\infty.$$

此性质表明, 随机变量的各阶原点矩可由其特征函数在原点的相应阶导数得到.

例 1.6 若随机变量 X 和 Y 相互独立, 且分别服从参数为 λ_1 和 λ_2 的泊松分布. 试用特征函数求随机变量 $Z = X + Y$ 的概率分布.

解 由泊松分布特征函数有 $\varphi_X(t) = e^{\lambda_1(e^{it}-1)}, \varphi_Y(t) = e^{\lambda_2(e^{it}-1)}$.

利用特征函数性质(5), 有

$$\varphi_Z(t) = e^{\lambda_1(e^{it}-1)} e^{\lambda_2(e^{it}-1)} = e^{(\lambda_1+\lambda_2)(e^{it}-1)}.$$

由唯一性定理得随机变量 Z 为具有参数 $\lambda_1 + \lambda_2$ 的泊松分布.

例 1.7 设 X_1, X_2, \dots, X_n 相互独立, 且 X_j 服从参数为 m_j 和 p 的二项分布, $j = 1, 2, \dots, n$. 证明 $Y = \sum_{j=1}^n X_j$ 服从参数为 $\sum_{j=1}^n m_j$ 和 p 的二项分布.

证明 因为 X_j 服从参数为 m_j 和 p 的二项分布, 故其特征函数分别为

$$\varphi_{X_j}(t) = (pe^{it} + q)^{m_j}, \quad j=1, 2, \dots, n,$$

由 X_1, X_2, \dots, X_n 相互独立得 $Y = \sum_{j=1}^n X_j$ 的特征函数为

$$\varphi_Y(t) = \prod_{j=1}^n \varphi_{X_j}(t) = \prod_{j=1}^n (pe^{it} + q)^{m_j} = (pe^{it} + q)^{\sum_{j=1}^n m_j}.$$

可见, 随机变量 $Y = \sum_{j=1}^n X_j$ 服从参数为 $\sum_{j=1}^n m_j$ 和 p 的二项分布.

例 1.8 利用特征函数求例 1.1 中随机变量的数学期望、方差和三阶原点矩.

解 因为 $\varphi(t) = E(e^{itX}) = 0.5\cos t + 0.5$, 所以

$$\varphi'(t) = -0.5\sin t, \quad \varphi''(t) = -0.5\cos t, \quad \varphi'''(t) = 0.5\sin t.$$

从而 $\varphi'(0) = 0, \varphi''(0) = -0.5, \varphi'''(0) = 0$. 因此, 由性质(6)知

$$E(X) = \frac{1}{i} \varphi'(0) = 0, \quad D(X) = i^{-2} \varphi''(0) - (E(X))^2 = 0.5, \quad E(X^3) = \frac{1}{i^3} \varphi'''(0) = 0.$$

1.3 多元特征函数和 multidimensional normal distribution

1.3.1 多维概率分布及其数字特征

我们学过二维随机变量, 下面把二维随机变量的一些概念推广到多维随机变量.

1. 分布函数

设 n 维随机变量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$, 称

$$F(x_1, x_2, \dots, x_n) = P\{X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n\}, \quad x_1, x_2, \dots, x_n \in \mathbb{R}$$

为 n 维随机变量 (X_1, X_2, \dots, X_n) 的 n 维分布函数, 用向量的形式可表示为 $F(\mathbf{x}) = P\{\mathbf{X} \leq \mathbf{x}\}$, 其中 $\mathbf{x} = (x_1, x_2, \dots, x_n)$, 而 $\mathbf{X} \leq \mathbf{x}$ 理解为 \mathbf{X} 对每一个分量都有 $X_j \leq x_j$.

2. 数字特征

n 维随机变量 (X_1, X_2, \dots, X_n) 的数学期望 $E(\mathbf{X})$ 定义为

$$E(\mathbf{X}) = (E(X_1), E(X_2), \dots, E(X_n)).$$

$E(\mathbf{X})$ 的分量是 \mathbf{X} 各分量的数学期望.

n 维随机变量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的协方差(矩)阵定义为

$$\mathbf{B} = \begin{bmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \text{Cov}(X_2, X_2) & \cdots & \text{Cov}(X_2, X_n) \\ \vdots & \vdots & & \vdots \\ \text{Cov}(X_n, X_1) & \text{Cov}(X_n, X_2) & \cdots & \text{Cov}(X_n, X_n) \end{bmatrix},$$

其中, $\text{Cov}(X_j, X_k) = E[(X_j - E(X_j))(X_k - E(X_k))]$, $j, k = 1, 2, \dots, n$.

当 $j \neq k$ 时, $\text{Cov}(X_j, X_k)$ 是随机变量 X_j 和 X_k 的协方差.

当 $j = k$ 时, $\text{Cov}(X_j, X_j)$ 是随机变量 X_j 的方差.

n 维随机向量 \mathbf{X} 的协方差阵刻画了它的各个分量概率分布的分散程度, 以及各分量之

间线性联系的密切程度,它的主对角线是 \mathbf{X} 的各分量的方差.

协方差阵也可以表示为

$$\mathbf{B} = E \begin{bmatrix} [X_1 - E(X_1)]^2 & [X_1 - E(X_1)][X_2 - E(X_2)] & \cdots & [X_1 - E(X_1)][X_n - E(X_n)] \\ [X_2 - E(X_2)][X_1 - E(X_1)] & [X_2 - E(X_2)]^2 & \cdots & [X_2 - E(X_2)][X_n - E(X_n)] \\ \vdots & \vdots & \ddots & \vdots \\ [X_n - E(X_n)][X_1 - E(X_1)] & [X_n - E(X_n)][X_2 - E(X_2)] & \cdots & [X_n - E(X_n)]^2 \end{bmatrix}$$

$$= E[\mathbf{X} - E(\mathbf{X})][\mathbf{X} - E(\mathbf{X})]^T.$$

定理 1.1 协方差(矩)阵是对称的非负定矩阵.

证明 由协方差的性质 $\text{Cov}(X_j, X_k) = \text{Cov}(X_k, X_j)$ 知,协方差(矩)阵为对称矩阵.

再证协方差矩阵为非负定矩阵.事实上,对于任意 n 个实数 t_1, t_2, \dots, t_n ,有

$$\begin{aligned} \sum_{k=1}^n \sum_{j=1}^n \text{Cov}(X_j, X_k) t_j t_k &= \sum_{k=1}^n \sum_{j=1}^n E[X_j - E(X_j)][X_k - E(X_k)] t_j t_k \\ &= E \left\{ \sum_{k=1}^n \sum_{j=1}^n t_j [X_j - E(X_j)] \cdot t_k [X_k - E(X_k)] \right\} \\ &= E \left\{ \sum_{j=1}^n t_j [X_j - E(X_j)] \right\}^2 \geq 0, \end{aligned}$$

所以协方差矩阵为非负定矩阵.

1.3.2 多元特征函数及其性质

$n(n > 1)$ 维随机变量的特征函数称为多元特征函数,它是一维随机变量的特征函数的推广.多元特征函数的某些性质与一元特征函数的性质类似.

定义 1.5 设 n 维随机变量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$, 称

$$\varphi(t_1, t_2, \dots, t_n) = E(e^{i(t_1 X_1 + t_2 X_2 + \cdots + t_n X_n)})$$

为 n 维随机变量 \mathbf{X} 的特征函数,其中 $i = \sqrt{-1}$, $t_1, t_2, \dots, t_n \in \mathbb{R}$.

记 $\mathbf{t} = (t_1, t_2, \dots, t_n)$, 则 n 元特征函数可以简单地表示为

$$\varphi(\mathbf{t}) = E(e^{i\mathbf{t}\mathbf{X}^T}) = E(e^{i\mathbf{X}\mathbf{t}^T}).$$

当 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 是离散型随机变量, \mathbf{X} 的特征函数表示为

$$\varphi(t_1, t_2, \dots, t_n) = \sum_{x_1} \sum_{x_2} \cdots \sum_{x_n} e^{i(t_1 x_1 + t_2 x_2 + \cdots + t_n x_n)} P\{X_1 = x_1, X_2 = x_2, \dots, X_n = x_n\}.$$

当 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 具有概率密度 $f(x_1, x_2, \dots, x_n)$ 时, \mathbf{X} 的特征函数表示为

$$\varphi(t_1, t_2, \dots, t_n) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \cdots \int_{-\infty}^{+\infty} e^{i(t_1 x_1 + t_2 x_2 + \cdots + t_n x_n)} f(x_1, x_2, \dots, x_n) dx_1 dx_2 \cdots dx_n.$$

唯一性定理 n 维随机变量的分布函数与其特征函数是一一对应的.

n 维随机变量的特征函数有以下性质:

(1) $|\varphi(t_1, t_2, \dots, t_n)| \leq \varphi(0, 0, \dots, 0) = 1$.

(2) $\varphi(-t_1, -t_2, \dots, -t_n) = \overline{\varphi(t_1, t_2, \dots, t_n)}$.

(3) $\varphi(t_1, t_2, \dots, t_n)$ 在 n 维欧几里得空间 \mathbb{R}^n 上一致连续.

(4) 若 $\varphi(t_1, t_2, \dots, t_n)$ 是 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的特征函数, 则 $k(k \in \{1, 2, \dots, n\})$ 维随机变量 (X_1, X_2, \dots, X_k) 的特征函数为

$$\varphi_{X_1, X_2, \dots, X_k}(t_1, t_2, \dots, t_k) = \varphi(t_1, t_2, \dots, t_k, 0, \dots, 0).$$

此性质表明,如果要获得 n 维随机变量 \mathbf{X} 的 k 维边缘概率分布的特征函数,只要在原来的特征函数中保留自变量 t_1, t_2, \dots, t_k , 其他自变量置零即可.

(5) 若 $\varphi(t_1, t_2, \dots, t_n)$ 是 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的特征函数, 则随机变量

$$Y = a_1 X_1 + a_2 X_2 + \dots + a_n X_n$$

的特征函数为

$$\varphi_Y(t) = \varphi(a_1 t, a_2 t, \dots, a_n t).$$

(6) 若 $\varphi(t_1, t_2, \dots, t_n)$ 是 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的特征函数, 而随机变量 X_j 的特征函数是 $\varphi_{X_j}(t)$, $j=1, 2, \dots, n$, 则随机变量 X_1, X_2, \dots, X_n 相互独立的充分必要条件是

$$\varphi(t_1, t_2, \dots, t_n) = \varphi_{X_1}(t_1) \varphi_{X_2}(t_2) \dots \varphi_{X_n}(t_n).$$

(7) 如果矩 $E(X_1^{k_1} X_2^{k_2} \dots X_n^{k_n})$ 存在, 则

$$E(X_1^{k_1} X_2^{k_2} \dots X_n^{k_n}) = i^{-\sum_{j=1}^n k_j} \left[\frac{\partial^{k_1+k_2+\dots+k_n} \varphi(t_1, t_2, \dots, t_n)}{\partial t_1^{k_1} \partial t_2^{k_2} \dots \partial t_n^{k_n}} \right]_{t_1=t_2=\dots=t_n=0}.$$

1.3.3 n 维正态随机变量及其性质

n 维正态分布在概率论、数理统计和随机过程中占有重要的位置.

若二维随机变量 (X_1, X_2) 的概率密度为

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{(x_1-a_1)^2}{\sigma_1^2} - 2\rho \frac{(x_1-a_1)(x_2-a_2)}{\sigma_1\sigma_2} + \frac{(x_2-a_2)^2}{\sigma_2^2} \right] \right\},$$

$$-\infty < x_1 < +\infty, -\infty < x_2 < +\infty$$

则称随机变量 (X_1, X_2) 为二维正态随机变量, 该概率密度称为二维正态概率密度, 其中

$$a_1 = E(X_1), \quad a_2 = E(X_2), \quad \sigma_1^2 = D(X_1), \quad \sigma_2^2 = D(X_2),$$

ρ 是随机变量 X_1 与 X_2 的相关系数.

$$\text{令 } \mathbf{B} = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}, \mathbf{a} = (a_1, a_2), \mathbf{x} = (x_1, x_2), \text{ 则有 } |\mathbf{B}| = (1-\rho^2)\sigma_1^2\sigma_2^2,$$

$$\mathbf{B}^{-1} = \frac{1}{(1-\rho^2)\sigma_1^2\sigma_2^2} \begin{pmatrix} \sigma_2^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & \sigma_1^2 \end{pmatrix} = \frac{1}{1-\rho^2} \begin{pmatrix} \frac{1}{\sigma_1^2} & -\rho \frac{1}{\sigma_1\sigma_2} \\ -\rho \frac{1}{\sigma_1\sigma_2} & \frac{1}{\sigma_2^2} \end{pmatrix},$$

从而

$$(\mathbf{x}-\mathbf{a})\mathbf{B}^{-1}(\mathbf{x}-\mathbf{a})^T = \frac{1}{1-\rho^2} \left[\frac{(x_1-a_1)^2}{\sigma_1^2} - 2\rho \frac{(x_1-a_1)(x_2-a_2)}{\sigma_1\sigma_2} + \frac{(x_2-a_2)^2}{\sigma_2^2} \right],$$

由此可知二维正态概率密度可以表示为

$$f(\mathbf{x}) = \frac{1}{2\pi|\mathbf{B}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2}(\mathbf{x}-\mathbf{a})\mathbf{B}^{-1}(\mathbf{x}-\mathbf{a})^T \right].$$

可以将二维正态概率密度推广到 n 维正态概率密度.

定义 1.6 如果 n 维随机变量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的分布密度为

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} |\mathbf{B}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{a}) \mathbf{B}^{-1} (\mathbf{x} - \mathbf{a})^T \right],$$

其中 $\mathbf{x} = (x_1, x_2, \dots, x_n)$, $\mathbf{a} = E(\mathbf{X}) = (E(X_1), E(X_2), \dots, E(X_n))$,

$$\mathbf{B} = \begin{bmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \text{Cov}(X_2, X_2) & \cdots & \text{Cov}(X_2, X_n) \\ \vdots & \vdots & & \vdots \\ \text{Cov}(X_n, X_1) & \text{Cov}(X_n, X_2) & \cdots & \text{Cov}(X_n, X_n) \end{bmatrix},$$

且矩阵 \mathbf{B} 是正定的, 称 \mathbf{X} 为 n 维正态随机变量. $f(\mathbf{x})$ 称为 n 维正态概率密度. n 维正态分布记为 $N(\mathbf{a}, \mathbf{B})$.

可以证明, n 维正态分布 $N(\mathbf{a}, \mathbf{B})$ 的特征函数是

$$\varphi(\mathbf{t}) = \exp \left(i \mathbf{a} \mathbf{t}^T - \frac{1}{2} \mathbf{t} \mathbf{B} \mathbf{t}^T \right).$$

定义 1.7 如果 n 维随机变量 \mathbf{X} 的特征函数是

$$\varphi(\mathbf{t}) = \exp \left(i \mathbf{a} \mathbf{t}^T - \frac{1}{2} \mathbf{t} \mathbf{B} \mathbf{t}^T \right),$$

其中 \mathbf{a} 是 n 维行向量, \mathbf{B} 是 n 阶非负定矩阵, 那么称 \mathbf{X} 的概率分布是 n 维正态分布 $N(\mathbf{a}, \mathbf{B})$.

当 $|\mathbf{B}| = 0$, 即 \mathbf{B} 不可逆时, 定义 1.7 也是有意义的, 而用定义 1.6 定义 n 维正态分布则要求 $|\mathbf{B}| > 0$. 所以, 用多维特征函数定义 n 维正态分布更为一般. 显然, 在 $|\mathbf{B}| > 0$ 的情况下两种定义方式是等价的. $|\mathbf{B}| > 0$ 时的 n 维正态分布也称为非退化的 n 维正态分布.

下面介绍 n 维正态分布的性质.

性质 1 若 n 维正态随机变量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的 m ($m < n$) 个分量构成 m 维随机变量 $\tilde{\mathbf{X}} = (X_1, X_2, \dots, X_m)$, 则它是 m 维正态随机变量, 且其数学期望为 $\tilde{\mathbf{a}} = (a_1, a_2, \dots, a_m)$, 协方差阵为

$$\tilde{\mathbf{B}} = \begin{bmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_m) \\ \text{Cov}(X_2, X_1) & \text{Cov}(X_2, X_2) & \cdots & \text{Cov}(X_2, X_m) \\ \vdots & \vdots & & \vdots \\ \text{Cov}(X_m, X_1) & \text{Cov}(X_m, X_2) & \cdots & \text{Cov}(X_m, X_m) \end{bmatrix}.$$

特别地, 当 $m=1$ 时, 可得随机变量 X_1 服从正态分布 $N(a_1, D(X_1))$. 一般有随机变量 X_j 服从正态分布 $N(a_j, D(X_j))$, $j=1, 2, \dots, n$.

证明 记 $\tilde{\mathbf{t}} = (t_1, t_2, \dots, t_m)$, 利用特征函数的性质(4), 有

$$f_{X_1, X_2, \dots, X_m}(t_1, t_2, \dots, t_m) = f(t_1, t_2, \dots, t_m, 0, \dots, 0) = e^{i \mathbf{a} \mathbf{t}^T - \frac{1}{2} \mathbf{t} \mathbf{B} \mathbf{t}^T} \Big|_{t_{m+1} = \dots = t_n = 0},$$

其中 $\mathbf{a} \mathbf{t}^T \Big|_{t_{m+1} = \dots = t_n = 0} = a_1 t_1 + a_2 t_2 + \dots + a_m t_m = (a_1, a_2, \dots, a_m)(t_1, t_2, \dots, t_m)^T = \tilde{\mathbf{a}} \tilde{\mathbf{t}}^T$,

$$\begin{aligned}
& \mathbf{t} \mathbf{B} \mathbf{t}^T \Big|_{t_{m+1}=\cdots=t_n=0} \\
&= (t_1, t_2, \cdots, t_m, 0, \cdots, 0) \begin{pmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \text{Cov}(X_2, X_2) & \cdots & \text{Cov}(X_2, X_n) \\ \vdots & \vdots & & \vdots \\ \text{Cov}(X_n, X_1) & \text{Cov}(X_n, X_2) & \cdots & \text{Cov}(X_n, X_n) \end{pmatrix} \begin{pmatrix} t_1 \\ \vdots \\ t_m \\ 0 \\ \vdots \\ 0 \end{pmatrix} \\
&= \sum_{k=1}^m \sum_{j=1}^m \text{Cov}(X_j, X_k) t_j t_k \\
&= (t_1, t_2, \cdots, t_m) \begin{pmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_m) \\ \text{Cov}(X_2, X_1) & \text{Cov}(X_2, X_2) & \cdots & \text{Cov}(X_2, X_m) \\ \vdots & \vdots & & \vdots \\ \text{Cov}(X_m, X_1) & \text{Cov}(X_m, X_2) & \cdots & \text{Cov}(X_m, X_m) \end{pmatrix} \begin{pmatrix} t_1 \\ t_2 \\ \vdots \\ t_m \end{pmatrix} = \tilde{\mathbf{t}} \tilde{\mathbf{B}} \tilde{\mathbf{t}}^T,
\end{aligned}$$

所以

$$f_{X_1, X_2, \cdots, X_m}(t_1, t_2, \cdots, t_m) = f(t_1, t_2, \cdots, t_m, 0, \cdots, 0) = \exp\left(i \tilde{\mathbf{a}} \tilde{\mathbf{t}}^T - \frac{1}{2} \tilde{\mathbf{t}} \tilde{\mathbf{B}} \tilde{\mathbf{t}}^T\right),$$

这是 m 维正态分布的特征函数.

由唯一性定理, m 维正态随机变量 $\tilde{\mathbf{X}} = (X_1, X_2, \cdots, X_m)$ 服从正态分布 $N(\tilde{\mathbf{a}}, \tilde{\mathbf{B}})$.

性质 2 设 $\mathbf{X} = (X_1, X_2, \cdots, X_n)$ 是 n 维正态随机变量, 则随机变量 X_1, X_2, \cdots, X_n 相互独立的充分必要条件是它们两两不相关.

证明 必要性. 设随机变量 X_1, X_2, \cdots, X_n 相互独立, 则其中任意两个随机变量 X_j 与 X_k ($j \neq k$) 相互独立, 进而 X_j 与 X_k 不相关, 所以 X_1, X_2, \cdots, X_n 两两不相关.

充分性. 因为 $\text{Cov}(X_j, X_k) = 0, j \neq k$, 故 $\mathbf{X} = (X_1, X_2, \cdots, X_n)$ 的协方差阵为

$$\mathbf{B} = \begin{pmatrix} D(X_1) & 0 & \cdots & 0 \\ 0 & D(X_2) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & D(X_n) \end{pmatrix},$$

因此 \mathbf{X} 的特征函数

$$\varphi(t_1, t_2, \cdots, t_n) = \exp\left(i \sum_{j=1}^n a_j t_j - \frac{1}{2} \sum_{j=1}^n D(X_j) t_j^2\right) = \prod_{j=1}^n \exp\left(i a_j t_j - \frac{1}{2} D(X_j) t_j^2\right) = \prod_{j=1}^n f_{X_j}(t_j).$$

由多元特征函数的性质(6)得随机变量 X_1, X_2, \cdots, X_n 相互独立.

性质 3 $\mathbf{X} = (X_1, X_2, \cdots, X_n)$ 服从 n 维正态分布 $N(\mathbf{a}, \mathbf{B})$ 当且仅当对任意常数

l_1, l_2, \cdots, l_n , 随机变量 $Y = \sum_{j=1}^n l_j X_j$ 服从一维正态分布

$$N\left(\sum_{j=1}^n l_j a_j, \sum_{j=1}^n \sum_{k=1}^n l_j l_k \text{Cov}(X_j, X_k)\right).$$

证明 充分性. 令 $\mathbf{l} = (l_1, l_2, \cdots, l_n)$, $\mathbf{a} = (a_1, a_2, \cdots, a_n)$, 若

$$Y = \sum_{j=1}^n l_j X_j \sim N\left(\sum_{j=1}^n l_j a_j, \sum_{j=1}^n \sum_{k=1}^n l_j l_k \text{Cov}(X_j, X_k)\right),$$

则有

$$E(e^{iY}) = E(e^{iX^T}) = \exp\left(ial^T t - \frac{1}{2}lBl^T t^2\right),$$

其中 $B = (\text{Cov}(X_j, X_k))$ 为 $X = (X_1, X_2, \dots, X_n)$ 的协方差矩阵.

$$\text{令 } t=1, \text{ 得 } E(e^{iX^T}) = \exp\left(ial^T - \frac{1}{2}lBl^T\right).$$

由 l 的任意性, 知 $X = (X_1, X_2, \dots, X_n)$ 的特征函数

$$\varphi(l) = \exp\left(ial^T - \frac{1}{2}lBl^T\right).$$

由特征函数的唯一性定理知, $X = (X_1, X_2, \dots, X_n) \sim N(a, B)$.

必要性. 若 X 服从 n 维正态分布 $N(a, B)$, 则其特征函数 $E(e^{iX^T}) = \exp\left(ial^T - \frac{1}{2}lBl^T\right)$,

由多元特征函数性质(5), Y 的特征函数

$$\varphi_Y(t) = \varphi(l_1 t, l_2 t, \dots, l_n t) = \exp\left[ial^T t - \frac{1}{2}t^2 \sum_{j=1}^n \sum_{k=1}^n \text{Cov}(X_j, X_k) l_j l_k\right],$$

这是正态分布 $N\left(\sum_{j=1}^n l_j a_j, \sum_{j=1}^n \sum_{k=1}^n l_j l_k \text{Cov}(X_j, X_k)\right)$ 的特征函数.

由唯一性定理, $Y \sim N\left(\sum_{j=1}^n l_j a_j, \sum_{j=1}^n \sum_{k=1}^n l_j l_k \text{Cov}(X_j, X_k)\right)$.

性质 4 若 $X = (X_1, X_2, \dots, X_n)$ 服从 n 维正态分布 $N(a, B)$, 又 m 维随机变量 $Y = XC$, 其中 C 是 $n \times m$ 矩阵, 则 Y 服从 m 维正态分布 $N(aC, C^T B C)$.

证明 Y 的特征函数为

$$\begin{aligned}\varphi(t) &= E(e^{iY^T}) = E(e^{i(XC)^T}) = E(e^{i(C^T)^T X^T}) \\ &= \exp\left(ia(C^T)^T t - \frac{1}{2}(C^T)^T B C t^T\right) \\ &= \exp\left(ia(C^T)^T t - \frac{1}{2}t(C^T B C)t^T\right).\end{aligned}$$

这是 m 维正态分布 $N(aC, C^T B C)$ 的特征函数, 由唯一性定理得证.

性质 4 表明, 正态随机变量经过线性变换后仍为正态随机变量.

例 1.9 设 $X = (X_1, X_2)$, $X \sim N(0, B)$, $B = \begin{pmatrix} 1 & 2 \\ 2 & 1 \end{pmatrix}$, $Y_1 = 2X_1 + 3X_2$, $Y_2 = X_2$, 求:

(1) $Y = (Y_1, Y_2)$ 的特征函数; (2) $Y_3 = X_1 + 2X_2$ 的分布.

$$\text{解 } A = \begin{pmatrix} 2 & 0 \\ 3 & 1 \end{pmatrix}, Y = XA, E(Y) = (0, 0) \begin{pmatrix} 2 & 0 \\ 3 & 1 \end{pmatrix} = (0, 0),$$

$$B_Y = A^T B A = \begin{pmatrix} 2 & 0 \\ 3 & 1 \end{pmatrix}^T \begin{pmatrix} 1 & 2 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} 2 & 0 \\ 3 & 1 \end{pmatrix} = \begin{pmatrix} 37 & 7 \\ 7 & 1 \end{pmatrix}.$$

故 Y 的特征函数为

$$\varphi_Y(t) = \exp\left(-\frac{1}{2}tB_Y t^T\right) = \exp\left[-\frac{1}{2}(37t_1^2 + t_2^2 + 14t_1 t_2)\right].$$