

第1章 引 论

学习目标与要求

1. 回顾概率论的基本概念以及相关性质.
2. 理解随机过程的概念、平稳性、独立增量性和平稳增量性.
3. 理解泊松过程的有关概念，并掌握它的重要性质.
4. 理解布朗运动的有关概念，并掌握它的重要性质.

1.1 预备知识

1.1.1 概率空间

在概率论中，通常把按照一定的想法去做的事情称为试验。一个试验，若它的结果预先无法确定，则称之为随机试验，简称为试验。试验的每个可能结果称为样本点，样本点的集合称为样本空间。在本书中，用 Ω 表示样本空间，用 ω 表示样本点，于是

$$\Omega = \{\omega : \omega \text{ 是试验的样本点}\}.$$

样本空间 Ω 中的样本点 ω 也称为基本事件。样本空间的子集，也即由基本事件构成的集合称为事件，通常用大写英文字母 A, B, C 等表示。样本空间 Ω 称为必然事件，空集 \emptyset 称为不可能事件。由样本空间 Ω 中的若干子集构成的集合称为 Ω 的集类，用花写的字母 $\mathcal{A}, \mathcal{B}, \mathcal{C}$ 等表示。显然，样本空间 Ω 的集类就是由一些事件构成的集合。

在实际问题中，人们通常不是对样本空间的所有子集都感兴趣，而是只关心某些事件及其发生的可能性大小。为了方便地在人们感兴趣的事件上定义概率，我们引入如下概念。

定义 1.1 设 \mathcal{F} 是样本空间 Ω 的集类。如果满足：

- (1) $\Omega \in \mathcal{F}$;

(2) 若 $A \in \mathcal{F}$, 则 $A^c = \Omega - A \in \mathcal{F}$;

(3) 若 $A_n \in \mathcal{F}, n \in \mathbb{N}$, 则 $\bigcup_{n=1}^{\infty} A_n \in \mathcal{F}$,

则称 \mathcal{F} 为样本空间 Ω 的一个 σ 域 (或 σ 代数). 将 (Ω, \mathcal{F}) 称为可测空间. \mathcal{F} 中的元素便是人们感兴趣的事件.

容易验证, 若 \mathcal{F} 是样本空间 Ω 的一个 σ 域, 则有: (1) $\emptyset \in \mathcal{F}$; (2) 若 $A, B \in \mathcal{F}$, 则 $A - B \in \mathcal{F}$; (3) 若 $A_n \in \mathcal{F}, n \in \mathbb{N}$, 则 $\bigcap_{n=1}^{\infty} A_n \in \mathcal{F}$.

定义 1.2 设 \mathcal{A} 为样本空间 Ω 的集类, 称一切包含 \mathcal{A} 的 σ 域的交集为由 \mathcal{A} 生成的 σ 域, 或称为包含 \mathcal{A} 的最小 σ 域, 记为 $\sigma(\mathcal{A})$.

例 1.1 容易看出, 样本空间 Ω 的集类 $\mathcal{A}_0 = \{\emptyset, \Omega\}$, $\mathcal{A}_1 = \{\emptyset, A, A^c, \Omega\}$ 和 $\mathcal{A}_2 = \{A : A \subseteq \Omega\}$ 都是 σ 域, 而集类 $\mathcal{C} = \{\emptyset, A, \Omega\}$ 不是 σ 域. 由 \mathcal{C} 生成的 σ 域为 $\sigma(\mathcal{C}) = \{\emptyset, A, A^c, \Omega\}$.

定义 1.3 设 $\Omega = \mathbb{R}$, 集类 $\mathcal{A} = \{(-\infty, x) : x \in \mathbb{R}\}$, 则称由 \mathcal{A} 生成的最小 σ 域 $\sigma(\mathcal{A})$ 为 \mathbb{R} 上的 Borel σ 域, 记为 $\mathcal{B}(\mathbb{R})$. $\mathcal{B}(\mathbb{R})$ 中的元素称为 Borel 集合. 类似地, 可定义 \mathbb{R}^n 上的 Borel σ 域 $\mathcal{B}(\mathbb{R}^n)$.

定义 1.4 设 (Ω, \mathcal{F}) 是一个可测空间, $P(\cdot)$ 是一个定义在 \mathcal{F} 上的集函数. 如果 $P(\cdot)$ 满足以下条件:

(1) 非负性: $P(A) \geq 0, \forall A \in \mathcal{F}$;

(2) 完全性: $P(\Omega) = 1$;

(3) 可列可加性: 对两两互不相容的事件 $A_i \in \mathcal{F}, i = 1, 2, \dots$ (即当 $i \neq j$ 时, $A_i \cap A_j = \emptyset$), 有

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

那么称 P 是 (Ω, \mathcal{F}) 上的一个概率测度, 简称概率. 称 (Ω, \mathcal{F}, P) 为概率空间. 称 $P(A)$ 为事件 A 的概率. 本书约定概率为零的事件的任何子集都属于 \mathcal{F} . 满足这样约定的概率空间通常称为完备的概率空间.

概率具有如下基本性质:

(1) $P(\emptyset) = 0, P(A^c) = 1 - P(A), \forall A \in \mathcal{F}$.

(2) 有限可加性: 如果 $A_i \in \mathcal{F}, i = 1, 2, \dots, n$, 且两两互不相容, 那么

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

(3) 单调性: 如果 $A, B \in \mathcal{F}$, 且 $A \subseteq B$, 那么 $P(A) \leq P(B)$.

(4) 进出公式: 如果 $A_i \in \mathcal{F}, i = 1, 2, \dots, n$, 那么

$$\begin{aligned} P\left(\bigcup_{i=1}^n A_i\right) &= \sum_{i=1}^n P(A_i) - \sum_{1 \leq i < j \leq n} P(A_i A_j) + \sum_{1 \leq i < j < k \leq n} P(A_i A_j A_k) - \dots + \\ &\quad (-1)^{n+1} P(A_1 A_2 \dots A_n). \end{aligned}$$

(5) 次可加性: 如果 $A_i \in \mathcal{F}, i = 1, 2, \dots, n$, 那么

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

下面介绍概率的连续性. 为此引入事件序列的极限.

定义 1.5 若一个事件序列 $\{A_n, n \geq 1\} \subseteq \mathcal{F}$ 满足 $A_n \subseteq A_{n+1}$ (或 $A_n \supseteq A_{n+1}$), $n \geq 1$, 则称该事件序列 $\{A_n, n \geq 1\}$ 为单调递增事件序列(或单调递减事件序列). 若 $\{A_n, n \geq 1\}$ 是一个单调递增事件序列, 则定义 $\lim_{n \rightarrow \infty} A_n = \bigcup_{n=1}^{\infty} A_n$. 若 $\{A_n, n \geq 1\}$ 是

一个单调递减事件序列, 则定义 $\lim_{n \rightarrow \infty} A_n = \bigcap_{n=1}^{\infty} A_n$. 若 $\{A_n, n \geq 1\}$ 是一个事件序列,

则定义 $\limsup_{n \rightarrow \infty} A_n = \bigcap_{n=1}^{\infty} \bigcup_{i=n}^{\infty} A_i$.

(6) 概率的连续性: 如果 $\{A_n, n \geq 1\}$ 是一个单调递增(或单调递减)事件序列, 那么

$$\lim_{n \rightarrow \infty} P(A_n) = P\left(\lim_{n \rightarrow \infty} A_n\right).$$

证明 设 $\{A_n, n \geq 1\}$ 是一个单调递增事件序列, 并令

$$B_1 = A_1, \quad B_n = A_n - A_{n-1}, \quad n \geq 2.$$

显然 $\{B_n, n \geq 1\}$ 两两互不相容, 而且对于每个 $n \geq 1$, 有 $\bigcup_{k=1}^n A_k = \bigcup_{k=1}^n B_k$, 从而
 $\bigcup_{n=1}^{\infty} A_n = \bigcup_{n=1}^{\infty} B_n$. 于是得到

$$\begin{aligned} P\left(\lim_{n \rightarrow \infty} A_n\right) &= P\left(\bigcup_{n=1}^{\infty} A_n\right) = P\left(\bigcup_{n=1}^{\infty} B_n\right) = \sum_{n=1}^{\infty} P(B_n) \\ &= \lim_{n \rightarrow \infty} \sum_{k=1}^n P(B_k) = \lim_{n \rightarrow \infty} P\left(\bigcup_{k=1}^n B_k\right) \\ &= \lim_{n \rightarrow \infty} P\left(\bigcup_{k=1}^n A_k\right) = \lim_{n \rightarrow \infty} P(A_n). \end{aligned}$$

另一种情况的证明, 留给读者练习.

(7) Borel-Cantelli 引理: 如果 $\{A_n, n \geq 1\}$ 是一个事件序列, 且满足 $\sum_{n=1}^{\infty} P(A_n) < \infty$, 那么

$$P\left(\limsup_{n \rightarrow \infty} A_n\right) = 0.$$

证明 显然 $\bigcup_{k=n}^{\infty} A_k (n = 1, 2, \dots)$, 是关于 n 的单调递减事件序列. 根据性质 (5) 和性质 (6) 得

$$0 \leq P\left(\bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} A_k\right) = P\left(\lim_{n \rightarrow \infty} \bigcup_{k=n}^{\infty} A_k\right) = \lim_{n \rightarrow \infty} P\left(\bigcup_{k=n}^{\infty} A_k\right) \leq \lim_{n \rightarrow \infty} \sum_{k=n}^{\infty} P(A_k) = 0.$$

证毕

事件的独立性是事件间的一种重要关系. 下面介绍事件的独立性概念.

定义 1.6 称两个事件 $A, B \in \mathcal{F}$ 相互独立, 如果满足

$$P(AB) = P(A)P(B).$$

称三个事件 $A, B, C \in \mathcal{F}$ 相互独立, 如果满足

$$P(AB) = P(A)P(B), \quad P(AC) = P(A)P(C), \quad P(BC) = P(B)P(C)$$

和

$$P(ABC) = P(A)P(B)P(C).$$

一般地, 称 n 个事件 $A_1, A_2, \dots, A_n \in \mathcal{F}$ 相互独立, 如果对于其中任意 k 个事件 $A_{i_1}, A_{i_2}, \dots, A_{i_k}$ ($1 \leq i_1 < i_2 < \dots < i_k \leq n$), 满足

$$P(A_{i_1} A_{i_2} \cdots A_{i_k}) = P(A_{i_1})P(A_{i_2}) \cdots P(A_{i_k}).$$

称事件序列 $A_1, A_2, \dots, A_n, \dots \in \mathcal{F}$ 相互独立, 如果任取其中有限个均相互独立.

容易证明, 如果事件 A_1, A_2, \dots, A_n 相互独立, 且令 $\mathcal{F}_1 = \sigma(A_k, 1 \leq k \leq m)$, $\mathcal{F}_2 = \sigma(A_k, m+1 \leq k \leq n)$, 那么对于 $B_1 \in \mathcal{F}_1$ 和 $B_2 \in \mathcal{F}_2$, 有 B_1 和 B_2 相互独立.

(8) 如果事件序列 $A_1, A_2, \dots, A_n, \dots$ 相互独立, 且 $\sum_{n=1}^{\infty} P(A_n) = \infty$, 那么

$$P\left(\limsup_{n \rightarrow \infty} A_n\right) = 1.$$

性质 (8) 的证明留给读者.

条件概率是概率论中的重要概念, 用途广泛. 下面介绍一下这个概念.

定义 1.7 设 A 是一个事件, 且 $P(A) > 0$, 则称 $P(AB)/P(A)$ 为事件 A 发生下事件 B 的条件概率, 记为 $P(B|A)$, 即

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

由条件概率的定义, 易得 $P(AB) = P(B|A)P(A)$, 这称为乘法公式. 进一步, 可得更一般的乘法公式

$$P(A_1 A_2 \cdots A_n) = P(A_1)P(A_2|A_1) \cdots P(A_n|A_1 A_2 \cdots A_{n-1}).$$

借助于条件概率的概念, 容易得到下列全概率公式和贝叶斯公式. 设 A_1, A_2, \dots 两两互不相容, 且 $\bigcup_n A_n = \Omega$, 则称 $\{A_n\}$ 为 Ω 的一个分割.

(9) 全概率公式: 如果事件 $\{A_n\}$ 为 Ω 的一个分割, 且 $P(A_n) > 0$, 那么 $\forall B \in \mathcal{F}$,

$$P(B) = \sum_n P(A_n)P(B|A_n).$$

(10) 贝叶斯公式: 如果事件 $\{A_n\}$ 为 Ω 的一个分割, 且 $P(A_n) > 0$, 那么对于事件 $P(A) > 0$,

$$P(A_n|A) = \frac{P(A_n)P(A|A_n)}{\sum_k P(A_k)P(A|A_k)}, \quad n \geq 1.$$

容易看出, 如果记 $P_A(\cdot) = P(\cdot|A)$, 那么 $P_A(\cdot)$ 也是可测空间 (Ω, \mathcal{F}) 上的一个概率测度, 从而 $(\Omega, \mathcal{F}, P_A(\cdot))$ 也构成概率空间, 而且对于任意的 $A, B, C \in \mathcal{F}$, 当 $P(AB) > 0$ 时, 有 $P_A(C|B) = P(C|AB)$; 并且 $P(C|AB) = P(C|A)$ 与 $P(BC|A) = P(B|A)P(C|A)$ 等价. 同样全概率公式也成立, 即如果 $\{B_n\}$ 是 Ω 的一个分割, 那么对于 $C \subseteq \bigcup_n B_n$, 有

$$P_A(C) = \sum_n P_A(B_n)P_A(C|B_n),$$

也即

$$P(C|A) = \sum_n P(B_n|A)P(C|AB_n).$$

1.1.2 随机变量

定义 1.8 设 (Ω, \mathcal{F}, P) 是一个概率空间, X 是定义在 Ω 上, 取值于实数集 \mathbb{R} 的函数. 如果对任意实数 $x \in \mathbb{R}$, $\{\omega : X(\omega) \leq x\} \in \mathcal{F}$, 那么称 $X(\omega)$ 是概率空间 (Ω, \mathcal{F}, P) 上的随机变量, 简称为随机变量. 函数

$$F(x) = P(\{\omega : X(\omega) \leq x\}), \quad -\infty < x < \infty$$

称为随机变量 X 的分布函数.

需要说明的是, 定义中样本点 ω 的集合 $\{\omega : X(\omega) \leq x\}$ 是一个事件, 一般简记为 $\{X \leq x\}$ 或 $\{X \in (-\infty, x]\}$. 容易验证, 对于任意实数 x , $\{X \leq x\}, \{X \geq x\}, \{X < x\}$ 和 $\{X > x\}$ 中只要有一个属于 σ 域 \mathcal{F} , 那么其余的就都属于 \mathcal{F} ; 而且对于两个随机变量 X 和 Y 而言, $\{X < Y\}, \{X \leq Y\}, \{X = Y\}$ 和 $\{X \neq Y\}$ 也都属于 \mathcal{F} . 给定随机变量 X , 称包含所有形如 $\{X \leq x\} (x \in \mathbb{R})$ 的最小 σ 域为由随机变量 X 生成的 σ 域 (或代数), 记为 $\sigma(X)$. 类似地, 可以定义由随机变量 X_1, X_2, \dots, X_n 生成的 σ 域 (或代数).

设 X 和 Y 是同一个概率空间 (Ω, \mathcal{F}, P) 上的两个随机变量, 若 $P(\{X \neq Y\}) = 0$ 成立, 则称它们是几乎必然相等, 记为 $X = Y$, a.s.. 对于随机变量 X 和 Y 而言, $X \pm Y$ 和 XY 也都是随机变量. 不难证明, 如果 $\{X_n\}$ 是一个随机变量序列, 那么 $\sup_n X_n, \inf_n X_n, \limsup_{n \rightarrow \infty} X_n$ 和 $\liminf_{n \rightarrow \infty} X_n$ 都是随机变量.

一般地, 常用的随机变量有两种类型: 离散型随机变量和连续型随机变量.

定义 1.9 若随机变量 X 的可能取值构成一个有限集或可列集, 则称 X 是一个离散型随机变量. 若随机变量 X 的可能取值充满数轴上的一个区间 (a, b) , 则称其为连续型随机变量, 其中 a 可以是 $-\infty$, b 可以是 ∞ .

对于一个离散型随机变量 X 而言, 如果 X 的所有可能取值是 $x_1, x_2, \dots, x_n, \dots$, 那么 X 取 x_i 的概率

$$p_i = P(\{X = x_i\}), \quad i = 1, 2, \dots, n, \dots$$

称为概率分布列或简称分布列, 其分布函数为

$$F(x) = \sum_{x_k \leq x} p_k.$$

对于一个连续型随机变量 X 而言, 存在实数轴上的一个非负可积函数 $f(x)$, 使得其分布函数 $F(x)$ 可表示为

$$F(x) = \int_{-\infty}^x f(t)dt, \quad \forall x \in \mathbb{R}.$$

此时, 称非负可积函数 $f(x)$ 为 X 的概率密度函数, 简称为密度函数或密度. 密度函数 $f(x)$ 的值虽然不是概率, 但是乘以微分元 dx 就可得小区间 $(x, x + dx)$ 上概率的近似值, 即

$$f(x)dx \approx P(x < X < x + dx).$$

将相邻微分元累积起来就得到 X 在 (a, b) 上取值的积分, 此积分值就是 X 在 (a, b) 上取值的概率, 即

$$\int_a^b f(x)dx = P(a < X < b).$$

更一般地, 对于 $(-\infty, \infty)$ 的子集 A , 有

$$P(X \in A) = \int_A f(x)dx.$$

定义 1.10 如果 X_1, X_2, \dots, X_n 都是随机变量, 那么称 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 是 n 维随机向(变)量. 称 \mathbb{R}^n 上的 n 元函数

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

为 \mathbf{X} 的 n 维联合分布函数或 n 维分布函数. 如果有 \mathbb{R}^n 上的非负函数 $f(\mathbf{x}) = f(x_1, x_2, \dots, x_n)$, 使得对于 \mathbb{R}^n 的任何子立方体

$$D = \{(x_1, x_2, \dots, x_n) : a_i < x_i \leq b_i, 1 \leq i \leq n\},$$

有

$$P(\mathbf{X} \in D) = \int_D f(\mathbf{x})dx_1 dx_2 \cdots dx_n, \quad (1.1)$$

那么称 \mathbf{X} 是连续型随机向量, 称函数 $f(\mathbf{x})$ 为 \mathbf{X} 的概率密度函数, 简称为密度函数或密度.

事实上, 可以证明对于 \mathbb{R}^n 的任何子区域 D , (1.1) 式仍然成立. 而且显然

$$F(\mathbf{x}) = \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_n} f(s_1, s_2, \dots, s_n) ds_n \cdots ds_1.$$

若 $F(\mathbf{x})$ 在 \mathbb{R}^n 的开区域 D 中有连续的 n 阶混合偏导数, 且 $P(\mathbf{X} \in D) = 1$, 则

$$f(\mathbf{x}) = \begin{cases} \frac{\partial^n F(\mathbf{x})}{\partial x_n \cdots \partial x_1}, & \mathbf{x} \in D, \\ 0, & \text{其他.} \end{cases}$$

在后面章节里, 要经常用到一个随机向量变换的重要公式, 这就是下面的定理.

定理 1.1 设随机向量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的概率密度函数是 $f(\mathbf{x}) = f(x_1, x_2, \dots, x_n)$, $Y_i = g_i(\mathbf{X}) (i = 1, 2, \dots, n)$ 是 \mathbf{X} 的函数, 且存在唯一的反函数

$X_i = h_i(\mathbf{Y}) = h_i(Y_1, Y_2, \dots, Y_n)$, $i = 1, 2, \dots, n$. 如果 g_i, h_i 有连续偏导数, 那么 $\mathbf{Y} = (Y_1, Y_2, \dots, Y_n)$ 的概率密度函数为

$$g(\mathbf{y}) = \begin{cases} f(\mathbf{x})|\mathbf{J}|, & \text{若 } \mathbf{y} \text{ 属于 } (g_1, g_2, \dots, g_n) \text{ 的值域, 且 } |\mathbf{J}| \neq 0, \\ 0, & \text{其他.} \end{cases}$$

其中, $\mathbf{y} = (y_1, y_2, \dots, y_n)$, $\mathbf{x} = (x_1, x_2, \dots, x_n)$, $x_i = h_i(\mathbf{y})$, 而 \mathbf{J} 为坐标变换的雅可比矩阵, 即

$$\mathbf{J} = \begin{pmatrix} \frac{\partial x_1}{\partial y_1} & \frac{\partial x_1}{\partial y_2} & \cdots & \frac{\partial x_1}{\partial y_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial x_n}{\partial y_1} & \frac{\partial x_n}{\partial y_2} & \cdots & \frac{\partial x_n}{\partial y_n} \end{pmatrix}.$$

由随机向量的联合分布函数, 可以得到如下边际(或边缘)分布函数的概念.

定义 1.11 设 $F(\mathbf{x})$ 为随机向量 \mathbf{X} 的联合分布函数. 对于 $1 \leq i_1 < i_2 < \dots < i_m \leq n$, 我们称如下函数

$$F_{i_1, \dots, i_m}(x_{i_1}, \dots, x_{i_m}) = F(\infty, \dots, \infty, i_1, \infty, \dots, \infty, i_2, \infty, \dots, \infty, i_m, \infty, \dots, \infty)$$

为随机向量 \mathbf{X} 的 m 维边际(或边缘)分布函数.

定义 1.12 设随机向量 $\mathbf{X} = (X_1, X_2, \dots, X_n)$ 的分布函数为 $F(\mathbf{x})$. 若 $\forall \mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$, 有

$$F(\mathbf{x}) = F_1(x_1)F_2(x_2)\cdots F_n(x_n), \quad \text{其中 } F_i(x_i) = P(X_i \leq x_i),$$

则称 X_1, X_2, \dots, X_n 相互独立.

可以证明, 若随机变量 X, Y, Z 相互独立, 则 $X \pm Y, X \cdot Y, X/Y$ ($Y \neq 0$) 均与 Z 相互独立. 更一般地, $g(X, Y)$ 与 $h(Z)$ 相互独立.

下面回顾一下常用随机变量的分布.

(1) 离散型随机变量的典型分布

二项分布 设 $0 \leq p < 1, n \geq 1$. 若随机变量 X 的分布列为

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

则称 X 的分布为参数是 (n, p) 的二项分布, 简记为 $X \sim B(n, p)$.

泊松分布 设 $\lambda > 0$. 若随机变量 X 的分布列为

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, 2, \dots,$$

则称 X 的分布为参数是 λ 的泊松分布, 简记为 $X \sim P(\lambda)$.

几何分布 设 $0 < p < 1$. 若随机变量 X 的分布列为

$$P(X = k) = (1 - p)^{k-1} p, \quad k = 1, 2, \dots,$$

则称 X 的分布为参数是 p 的几何分布, 简记为 $X \sim G(p)$.

(2) 连续型随机变量的典型分布

均匀分布 设 $a < b$. 若随机变量 X 的概率密度函数为

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

则称 X 的分布为 (a, b) 上的均匀分布, 简记为 $X \sim U(a, b)$.

正态分布 设 $\mu \in \mathbb{R}, \sigma > 0$. 若随机变量 X 的概率密度函数为

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\{-(x-\mu)^2/2\sigma^2\},$$

则称 X 的分布为参数是 (μ, σ^2) 的正态分布, 简记为 $X \sim N(\mu, \sigma^2)$.

指数分布 设 $\lambda > 0$. 若随机变量 X 的概率密度函数为

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

则称 X 的分布为参数是 λ 的指数分布, 简记为 $X \sim \text{Exp}(\lambda)$.

n 维正态分布 设 $\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_n)$, $\boldsymbol{\Sigma}$ 是 n 阶正定对称阵, 并且其行列式为 $|\boldsymbol{\Sigma}|$. 如果 n 维随机向量 \mathbf{X} 的概率密度函数为

$$f(\mathbf{x}) = (2\pi)^{-n/2} |\boldsymbol{\Sigma}|^{-1/2} \exp\left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}) \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})^\top\right],$$

其中 $\mathbf{x} = (x_1, x_2, \dots, x_n)$, 那么称 \mathbf{X} 的分布为 n 维正态分布, 简记为 $\mathbf{X} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.

例 1.2 设 Z_1, Z_2, \dots, Z_n 是独立同分布、非负的随机变量, 密度函数为 $f(z)$, 它们相应的次序统计量为 $Z_{(1)} \leq Z_{(2)} \leq \dots \leq Z_{(n)}$, 请写出次序统计量 $Z_{(1)}, Z_{(2)}, \dots, Z_{(n)}$ 的联合概率密度.

解 对于任意给定的正数 $z_1 < z_2 < \dots < z_n$, 取充分小的 $h > 0$, 使得

$$0 < z_1 < z_1 + h < z_2 < z_2 + h < \dots < z_{n-1} + h < z_n < z_n + h.$$

考虑到

$$\{z_k < Z_{(k)} \leq z_k + h, 1 \leq k \leq n\} = \bigcup_{(i_1, i_2, \dots, i_n)} \{z_j < Z_{i_j} \leq z_j + h, 1 \leq j \leq n\},$$

且上式右边事件互不相容, 于是

$$\begin{aligned} & \lim_{h \rightarrow 0} \frac{P(z_1 < Z_{(1)} \leq z_1 + h, z_2 < Z_{(2)} \leq z_2 + h, \dots, z_n < Z_{(n)} \leq z_n + h)}{h^n} \\ &= \lim_{h \rightarrow 0} n! \frac{P(z_1 < Z_{i_1} \leq z_1 + h, z_2 < Z_{i_2} \leq z_2 + h, \dots, z_n < Z_{i_n} \leq z_n + h)}{h^n} \\ &= \lim_{h \rightarrow 0} n! \prod_{j=1}^n \frac{P(z_j < Z_{i_j} \leq z_j + h)}{h} = n! \prod_{j=1}^n f(z_j). \end{aligned}$$

故而 $Z_{(1)}, Z_{(2)}, \dots, Z_{(n)}$ 的联合概率密度为

$$f(z_1, z_2, \dots, z_n) = \begin{cases} n! \prod_{j=1}^n f(z_j), & 0 < z_1 < z_2 < \dots < z_n, \\ 0, & \text{其他.} \end{cases} \quad (1.2)$$

由 (1.2) 式知, 若 $Z_i (1 \leq i \leq n)$ 是独立同分布的随机变量, 而且共同的分布为在 $[0, t]$ 上的均匀分布, 则其顺序统计量 $Z_{(1)}, Z_{(2)}, \dots, Z_{(n)}$ 的联合概率密度为

$$f(z_1, z_2, \dots, z_n) = \begin{cases} \frac{n!}{t^n}, & 0 < z_1 < z_2 < \dots < z_n \leq t, \\ 0, & \text{其他.} \end{cases} \quad (1.3)$$

1.1.3 黎曼-斯蒂尔切斯积分

为了统一表述随机变量的数字特征, 我们引入黎曼-斯蒂尔切斯积分. 设 $G(x)$ 为 $(-\infty, \infty)$ 上单调不减右连续函数, $h(x)$ 为 $(-\infty, \infty)$ 上的单值实函数. 对于 $\forall a < b$, 我们可以如微积分中定义定积分那样定义关于 $G(x)$ 的黎曼-斯蒂尔切斯积分.