

2.2 多维随机变量(随机向量)

2.2.1 离散型随机向量的分布

随机向量的概念在 2.1 节 2.1.1 段中已提及过了. 一般, 设 $X = (X_1, X_2, \dots, X_n)$ 为一 n 维向量, 其每个分量, 即 X_1, \dots, X_n , 都是一维随机变量, 则称 X 是一个 n 维随机向量或 n 维随机变量.

与随机变量一样, 随机向量也有离散型和连续型之分. 本段先考虑前者, 一个随机向量 $X = (X_1, \dots, X_n)$, 如果其每一个分量 X_i 都是一维离散型随机变量, 则称 X 为离散型的.

定义 2.1 以 $\{a_{i1}, a_{i2}, \dots\}$ 记 X_i 的全部可能值, $i = 1, 2, \dots$, 则事件 $\{X_1 = a_{1j_1}, X_2 = a_{2j_2}, \dots, X_n = a_{nj_n}\}$ 的概率

$$p(j_1, j_2, \dots, j_n) = P(X_1 = a_{1j_1}, X_2 = a_{2j_2}, \dots, X_n = a_{nj_n})$$
$$j_1 = 1, 2, \dots, j_2 = 1, 2, \dots, \dots, j_n = 1, 2, \dots \quad (2.1)$$

称为随机向量 $X = (X_1, \dots, X_n)$ 的概率函数或概率分布, 概率函数应满足条件:

$$p(j_1, j_2, \dots, j_n) \geq 0, \sum_{j_n} \dots \sum_{j_2} \sum_{j_1} p(j_1, j_2, \dots, j_n) = 1 \quad (2.2)$$

例 2.1 图 2.5 所示的二维离散型随机向量 $X = (X_1, X_2)$ 的概率分布为

$$P(X_1 = 2, X_2 = 1) = 1/3$$

$$P(X_1 = 2, X_2 = 2.5) = 1/4$$

$$P(X_1 = 5, X_2 = 3) = 5/12$$

从图上看, X_1 的可能值为 2 和 5, X_2 的可能值为 1, 2.5 和 3. 故形式上看, $X = (X_1, X_2)$ 应有 6 组可能值, 即 $(2, 1), (2, 2.5), (2, 3), (5, 1), (5, 2.5), (5, 3)$. X 的概率分布告诉我们, 实际上只




图 2.5

有第 1, 2, 6 组是真正的可能值, 但这并无关系: 对一组不可能的值, 只要把它的概率定为 0 就行了. 这一做法使我们可以把离散型分布统一写成 (2.1) 的格式, 在理论上有其方便之处. 自然, 在具体例子中, 如例 2.1 并无必要硬凑成那个形式, 只要指出概率大于 0 的那部分就行了.

例 2.2 多项分布.

多项分布是最重要的离散型多维分布. 设 A_1, A_2, \dots, A_n 是某一试验之下的完备事件群, 即事件 A_1, \dots, A_n 两两互斥, 其和为必然事件 (每次试验时, 事件 A_1, \dots, A_n 必发生一个且只发生一个). 分别以 p_1, p_2, \dots, p_n 记事件 A_1, A_2, \dots, A_n 的概率, 则 $p_i \geq 0, p_1 + \dots + p_n = 1$.

现在将试验独立地重复 N 次, 而以 X_i 记在这 N 次试验中事件 A_i 出现的次数, $i = 1, \dots, n$, 则 $X = (X_1, \dots, X_n)$ 为一 n 维随机向量. 它取值的范围是: X_1, \dots, X_n 都是非负整数且其和为 N . X 的概率分布就叫做多项分布, 有时记为 $M(N; p_1, \dots, p_n)$. 为定出这分布, 要计算事件

$$B = \{X_1 = k_1, \dots, X_i = k_i, \dots, X_n = k_n\}$$

的概率, 只须考虑 k_i 都是非负整数且 $k_1 + \dots + k_n = N$ 的情况, 否则 $P(B) = 0$. 为计算 $P(B)$, 从 N 次试验的原始结果 $j_1 j_2 \dots j_N$ 出发, 它表示第一次实验事件 A_{j_1} 发生, 第二次试验 A_{j_2} 发生, 等等. 为使事件 B 发生, 在 j_1, j_2, \dots, j_N 中应有 k_1 个 1, k_2 个 2, \dots 等等. 这种序列的数目, 等于把 N 个相异物体分成 n 堆, 各堆依次有 k_1, k_2, \dots, k_n 件的不同分法. 据第一章 (2.6) 式, 不同分法有 $N! / (k_1! \dots k_n!)$ 个. 其次, 由于独立性, 利用概率乘法定理知, 每个适合上述条件的原始结果序列 $j_1 j_2 \dots j_n$ 出现的概率, 应为 $p_1^{k_1} p_2^{k_2} \dots$

p_n^k . 于是得到

$$P(X_1 = k_1, X_2 = k_2, \dots, X_n = k_n) = \frac{N!}{k_1! k_2! \dots k_n!} p_1^{k_1} p_2^{k_2} \dots p_n^{k_n} \quad (2.3)$$

(k 为非负整数, $k_1 + \dots + k_n = N$)

(2.3) 就是多项分布, 名称的来由是因多项展开式

$$(x_1 + \dots + x_n)^N = \sum^* \frac{N!}{k_1! \dots k_n!} x_1^{k_1} \dots x_n^{k_n} \quad (2.4)$$

\sum^* 表示求和的范围为: k_i 为非负整数, $k_1 + \dots + k_n = N$. 在 (2.4) 中令 $x_i = p_i$ 并利用 $p_1 + \dots + p_n = 1$, 得

$$\sum^* \frac{N!}{k_1! \dots k_n!} p_1^{k_1} \dots p_n^{k_n} = 1$$

这说明分布 (2.3) 适合条件 (2.2).

多项分布在实用上颇常见: 当一个体按某种属性分成几类时, 就会涉及这个分布. 例如, 一种产品分成一等品 (A_1)、二等品 (A_2)、三等品 (A_3) 和不合格品 (A_4) 四类. 若生产该产品的某厂, 其一、二、三等品和不合格品的比率分别为 0.15, 0.70, 0.10 和 0.05, 从该厂产品中抽出 N 个. 若这 N 个只占其产品的极少一部分, 则可以把这 N 个看成一个一个地独立抽出, 且在抽取过程中, 各等品的概率 (即比率) 不变. 在这种情况下, 若分别以 X_1, \dots, X_4 记这 N 个产品中一、二、三等和不合格品的个数, 则 $X = (X_1, \dots, X_4)$ 将有多项分布 $M(N; 0.15, 0.70, 0.10, 0.05)$. 又如在医学上, 一种疾病的患者可按严重的程度分期等等, 都属于这种情况.

如果 $n=2$, 即只有 A_1, A_2 两种可能, 这时 A_2 就是 A_1 的对立事件. 由于这时有 $X_1 + X_2 = N$, X_1 唯一地决定了 X_2 , 我们不必同时考虑 X_1 和 X_2 , 而只须考虑 X_1 就够了, 这就回到二项分布的情形.

2.2.2 连续型随机向量的分布

设 $X = (X_1, \dots, X_n)$ 是一个 n 维随机向量. 其取值可视为 n

维欧氏空间 R^n 中的一个点. 如果 X 的全部取值能充满 R^n 中某一区域, 则称它是连续型的.

与一维连续型变量一样, 描述多维随机向量的概率分布, 最方便的是用概率密度函数. 为此我们引进一个记号: $X \in A$, 读作“ X 属于 A ”或“ X 落在 A 内”, 其中 A 是 R^n 中的集合. $\{X \in A\}$ 是一个随机事件, 因为作了试验以后, X 之值就知道了, 因而也就能知道它是否落在 A 内.

定义 2.2 若 $f(x_1, \dots, x_n)$ 是定义在 R^n 上的非负函数, 使对 R^n 中的任何集合 A , 有

$$P(X \in A) = \int_A \dots \int f(x_1, \dots, x_n) dx_1 \dots dx_n \quad (2.5)$$

则称 f 是 X 的(概率)密度函数.

如果把 A 取成全空间 R^n , 则 $\{X \in A\}$ 为必然事件, 其概率为 1. 因此应有

$$\int_{-\infty}^{\infty} \dots \int f(x_1, \dots, x_n) dx_1 \dots dx_n = 1 \quad (2.6)$$

这是一个概率密度函数必须满足的条件.

例 2.3 考虑二维随机向量 $X = (X_1, X_2)$, 其概率密度函数为

$$f(x_1, x_2) = \begin{cases} 1/[(b-a)(d-c)], & \text{当 } a \leq x_1 \leq b, c \leq x_2 \leq d \\ 0, & \text{其他处} \end{cases}$$

则 f 非负且条件(2.6)满足. 从 f 的形状看出, 它在图 2.6 中那个矩形之外为 0, 说明 (X_1, X_2) 只能取该矩形内的点为值. 在这矩形内, 密度各处一样, 因而全部概率均匀地分布在这矩形内. 从公式(2.5)看出: 若集 A 在矩形内, 则“ X 落在 A 内”的概率 $P(X \in A)$, 与 A 的面积成正比而与其位置及形状无关, 这是均匀性的另一种说法. 以此之故, 人们把本例中 X 的分布称为上述矩形上的均匀分布.

例 2.4 向一个无限平面靶射击, 设命中点 $X = (X_1, X_2)$ 有




图 2.6




图 2.7

概率密度

$$f(x_1, x_2) = \pi^{-1}(1 + x_1^2 + x_2^2)^{-2}$$

从这个函数看出：命中点的密度只与该点与靶心的距离 r 有关。这可以解释为：在图 2.7 中以靶心 O 为中心的圆周上各点有同等被命中的机会。另外， $x_1^2 + x_2^2$ 愈小则 f 愈大，说明与靶心接近之点，较之远离靶心之点，有更大的命中机会。

为验证(2.6)式只须转到极坐标，得

$$\begin{aligned} & \iint_{-\infty}^{\infty} f(x_1, x_2) dx_1 dx_2 \\ &= \int_0^{2\pi} d\theta \int_0^{\infty} \pi^{-1} (1 + r^2)^{-2} r dr \\ &= 2\pi \cdot \pi^{-1} \int_0^{\infty} (1 + t)^{-2} dt / 2 = 1 \end{aligned}$$

而“命中点与靶心之距离不超过 r_0 ”这个事件 A 的概率为

$$\begin{aligned} & \iint_{x_1^2 + x_2^2 \leq r_0^2} f(x_1, x_2) dx_1 dx_2 \\ &= \int_0^{2\pi} d\theta \int_0^{r_0} \pi^{-1} (1 + r^2)^{-2} r dr = r_0^2 / (1 + r_0^2) \end{aligned}$$

例 2.5 二维正态分布.

最重要的多维连续型分布是多维正态分布. 对二维的情况, 其概率密度函数有形式

$$f(x_1, x_2) = (2\pi\sigma_1\sigma_2\sqrt{1-\rho^2})^{-1} \exp\left(-\frac{1}{2(1-\rho^2)}\left(\frac{(x_1-a)^2}{\sigma_1^2} - \frac{2\rho(x_1-a)(x_2-b)}{\sigma_1\sigma_2} + \frac{(x_2-b)^2}{\sigma_2^2}\right)\right) \quad (2.7)$$

这里为书写方便, 引进了一个记号 \exp . 其意义是: $\exp(c) = e^c$. f 中包含了五个常数 $a, b, \sigma_1^2, \sigma_2^2$ 和 ρ , 它们是这个分布的参数, 其可取值的范围为:

$-\infty < a < \infty, -\infty < b < \infty, \sigma_1 > 0, \sigma_2 > 0, -1 < \rho < 1$. 常把这个分布记为 $N(a, b, \sigma_1^2, \sigma_2^2, \rho)$. 这函数(在三维空间中)的图形, 好像一个椭圆切面的钟倒扣在 Ox_1x_2 平面上, 其中心在 (a, b) 点.

为了证明(2.7)式确实是一个密度函数, 还须证明(2.6)式成立. 为此, 作变数代换

$$u = (1-\rho^2)^{-1/2} \frac{x_1-a}{\sigma_1}, v = (1-\rho^2)^{-1/2} \frac{x_2-b}{\sigma_2}$$

得

$$\begin{aligned} & \iint_{-\infty}^{\infty} f(x_1, x_2) dx_1 dx_2 \\ &= \frac{1}{2\pi} \sqrt{1-\rho^2} \iint_{-\infty}^{\infty} \exp\left[-\frac{1}{2}(u^2 - 2\rho uv + v^2)\right] du dv \end{aligned}$$

再作变数代换 $t_1 = u - \rho v, t_2 = \sqrt{1-\rho^2}v$. 注意到 $u^2 - 2\rho uv + v^2 = (u - \rho v)^2 + (1-\rho^2)v^2 = t_1^2 + t_2^2$, 且变换的贾可比行列式为

$$\begin{vmatrix} \partial t_1 / \partial u & \partial t_1 / \partial v \\ \partial t_2 / \partial u & \partial t_2 / \partial v \end{vmatrix} = \begin{vmatrix} 1 & -\rho \\ 0 & \sqrt{1-\rho^2} \end{vmatrix} = \sqrt{1-\rho^2}$$

得

$$\iint_{-\infty}^{\infty} f(x_1, x_2) dx_1 dx_2$$

$$\begin{aligned}
&= \frac{1}{2\pi} \sqrt{1-\rho^2} (\sqrt{1-\rho^2})^{-1} \iint_{-\infty}^{\infty} \exp \cdot \left[-\frac{1}{2}(t_1^2 + t_2^2) \right] dt_1 dt_2 \\
&= (2\pi)^{-1} \int_0^{\infty} e^{-t_1^2/2} dt_1 \int_0^{\infty} e^{-t_2^2/2} dt_2 \\
&= (2\pi)^{-1} \sqrt{2\pi} \sqrt{2\pi} = 1
\end{aligned}$$

这里用到(1.15).

类似地可定义 n 维正态分布的概率密度函数, 这里不细讲了.

在结束这一段之前, 让我们指出几点有关事项:

1. 不论在一维或多维, 在定义连续型随机变量时, 实质之点都在于它有概率密度函数存在, 即存在有函数 f , 满足(1.13)或(2.5)式. 在概率论理论上, 把这一点直接取为连续型随机变量的定义: 它就是有密度函数的随机变量. 至于它可以在一个区间或区域上连续取值倒不是本质的, 甚至也是不确切的.

2. 与离散型随机向量的定义不同, 连续型随机向量不能简单地定义为“其各分量都是一维连续型随机变量的那种随机向量”. 举一个例子: 设 $X_1 \sim R(0, 1)$, $X_2 = X_1$, 则随机向量 (X_1, X_2) 的两个分量 X_1, X_2 都是连续型的. 但 (X_1, X_2) 却只能在图 2.8 中所示的单位正方形的对角线(图中的虚线)上取值. 因而不可能存在一个函数




图 2.8

$f(x_1, x_2)$ 满足(2.6)式(二元函数在平面上任一线段上的积分都是 0), 即 (X_1, X_2) 的概率密度函数不存在.

3. 与一维情况一样, 也可以用概率分布函数去描述多维随机向量的概率分布, 其定义为

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

然而, 在多维情况下, 分布函数极少应用.

2.2.3 边缘分布

设 $X = (X_1, \dots, X_n)$ 为一 n 维随机向量. X 有一定的分布 F , 这是一个 n 维分布. 因为 X 的每个分量 X_i 都是一维随机变量, 故它们都有各自的分布 $F_i, i = 1, \dots, n$, 这些都是一维分布, 称为随机向量 X 或其分布 F 的“边缘分布”. 以下我们要指出: 边缘分布完全由原分布 F 确定, 且从这个事实的讲解中也就悟出“边缘”一词的含义.

表 2.1

$X_1 \backslash X_2$	-1	0	5	行合计
1	0.17	0.05	0.21	0.43
3	0.04	0.28	0.25	0.57
列合计	0.21	0.33	0.46	1.00

例 2.6 表 2.1 以列表的形式, 显示了一个二维随机向量 $X = (X_1, X_2)$ 的概率分布. 比如

$$P(X_1 = 1, X_2 = 5) = 0.21$$

等等. 现在如想求 X_1 的分布, 则先注意到, X_1 只有两个可能值, 即 1 和 3. 而 $\{X_1 = 1\}$ 这个事件可以分解为三个互斥事件

$$\{X_1 = 1, X_2 = -1\}, \{X_1 = 1, X_2 = 0\}, \{X_1 = 1, X_2 = 5\}$$

之和, 故其概率应为上述三事件概率之和, 即

$$P(X_1 = 1) = 0.17 + 0.05 + 0.21 = 0.43$$

类似地得 $P(X_1 = 3) = 0.04 + 0.28 + 0.25 = 0.57$. 用同样的方法确定 X_2 的概率分布为

$$P(X_2 = -1) = 0.21, P(X_2 = 0) = 0.33, P(X_2 = 5) = 0.46$$

注意这两个分布正好是表的中央部分的行和与列和. 它们都处在表的“边缘”位置上. 由此得出边缘分布这个名词. 也有称为边际分布的.

从这个例子就不难悟出,在一般的离散型情况下,怎样去求边缘分布.回到定义 2.1 的记号,以 X_1 为例,它的全部可能值为 $a_{11}, a_{12}, a_{13}, \dots$. 例如,我们要求 $P(X_1 = a_{1k})$. 它等于把(2.1)式那样的概率全加起来,但局限于 $j_1 = k$ (这相当于在上述简例 2.6 中求行和或列和). 得

$$P(X_1 = a_{1k}) = \sum_{j_2, \dots, j_n} p(k, j_2, \dots, j_n), k = 1, 2, \dots \quad (2.8)$$

例 2.7 设 $X = (X_1, \dots, X_n)$ 服从多项分布 $M(N; p_1, \dots, p_n)$, 要求其边缘分布. 例如,考虑 X_1 , 我们把事件 A_1 作为一方, $A_2 + \dots + A_n$ 作为一方(它就是 \bar{A}_1), 见例 2.2 的说明,那么, X_1 就是在 N 次独立试验中,事件 A_1 发生的次数,而在每次试验中 A_1 发生的概率保持为 p_1 , 经过这一分析,不待计算就可以明了: X_1 的分布就是二项分布 $B(N, p_1)$. 应用公式(2.8)也可以得出这个结果:按(2.8),注意到多项分布的形式(2.3),有

$$P(X_1 = k) = \sum'_{k_2, \dots, k_n} \frac{N!}{k_2! \dots k_n!} p_2^{k_2} \dots p_n^{k_n} \cdot p_1^k / k!$$

这里, \sum'_{k_2, \dots, k_n} 表示求和的范围为: k_2, \dots, k_n 都是非负整数,其和为 $N - k$. 令

$$p'_2 = p_2 / (1 - p_1), \dots, p'_n = p_n / (1 - p_1)$$

则 $p'_2 + \dots + p'_n = (p_2 + \dots + p_n) / (1 - p_1) = (1 - p_1) / (1 - p_1) = 1$, 且可把上式改写为

$$P(X_1 = k) = \sum'_{k_2, \dots, k_n} \frac{(N - k)!}{k_2! \dots k_n!} p_2'^{k_2} \dots p_n'^{k_n} \cdot \frac{N!}{k!(N - k)!} p_1^k (1 - p_1)^{N - k}$$

按多项展开式(2.4),上式右边第一因子为

$$(p'_2 + \dots + p'_n)^{N - k} = 1^{N - k} = 1$$

于是得到

$$P(X_1 = k) = \frac{N!}{k!(N - k)!} p_1^k (1 - p_1)^{N - k}$$

$$= b(k; N, p_1), k = 0, 1, \dots, N$$

正是二项分布 $B(N, p_1)$.

现在来考虑连续型随机向量的边缘分布. 为书写简单计, 先考虑二维的情况, 设 $X = (X_1, X_2)$ 有概率密度函数 $f(x_1, x_2)$. 我们来证明: 这时 X_1 和 X_2 都具有概率密度函数.

为证明这一点, 考虑 X_1 的分布函数 $F_1(x_1) = P(X_1 \leq x_1)$. 它可以写为 $P(X_1 \leq x_1, X_2 < \infty)$. 注意到公式(2.5), 得

$$F_1(x_1) = P(X_1 \leq x_1) = \int_{-\infty}^{x_1} dt_1 \int_{-\infty}^{\infty} f(t_1, t_2) dt_2$$

$\int_{-\infty}^{\infty} f(t_1, t_2) dt_2$ 是 t_1 的函数, 记之为 $f_1(t_1)$. 于是上式可写为

$$F_1(x_1) = \int_{-\infty}^{x_1} f_1(t_1) dt_1$$

两边对 x_1 求导数, 得到 X_1 的概率密度函数为

$$dF_1(x_1)/dx_1 = f_1(x_1) = \int_{-\infty}^{\infty} f(x_1, x_2) dx_2 \quad (2.9)$$

这不仅证明了 X_1 的密度函数的存在, 而且还推出了其公式. 同理求出 X_2 的密度函数为

$$f_2(x_2) = \int_{-\infty}^{\infty} f(x_1, x_2) dx_1 \quad (2.10)$$

这个结果很容易推广到 n 维的情形: 设 $X = (X_1, \dots, X_n)$ 有概率密度函数 $f(x_1, \dots, x_n)$. 为求某分量 X_i 的概率密度函数, 只须把 $f(x_1, \dots, x_n)$ 中的 x_i 固定, 然后对 $x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n$ 在 $-\infty$ 到 ∞ 之间作定积分. 例如, X_1 的密度函数为

$$f_1(x_1) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, x_2, \dots, x_n) dx_2 \dots dx_n \quad (2.11)$$

例 2.8 再考虑例 2.3. 用公式(2.9), (2.10)很容易确定, X_1, X_2 的边缘分布分别是均匀分布 $R(a, b)$ 和 $R(c, d)$. 计算很容易, 留给读者.

例 2.9 考虑例 2.4. 按(2.9), X_1 的边缘密度函数为

$$f_1(x_1) = \pi^{-1} \int_{-\infty}^{\infty} (1 + x_1^2 + x_2^2)^{-2} dx_2$$

作变数代换 $t = x_2 / \sqrt{1 + x_1^2}$, 得

$$f_1(x_1) = \pi^{-1} (1 + x_1^2)^{-3/2} \int_{-\infty}^{\infty} (1 + t^2)^{-2} dt = \frac{1}{2} (1 + x_1^2)^{-3/2}$$

积分 $\int_{-\infty}^{\infty} (1 + t^2)^{-2} dt$ 通过变数代换 $t = \tan \theta$ 很易算出.

例 2.10 二维正态分布 $N(a, b, \sigma_1^2, \sigma_2^2, \rho)$ 的边缘分布密度. 若 (X_1, X_2) 有二维正态分布 $N(a, b, \sigma_1^2, \sigma_2^2, \rho)$, 我们来证明: X_1, X_2 的边缘分布分别是一维正态分布 $N(a, \sigma_1^2)$ 和 $N(b, \sigma_2^2)$. 为证

此, 要计算 $\int_{-\infty}^{\infty} f(x_1, x_2) dx_2$, 其中 f 由(2.7)式定义. 注意到

$$\begin{aligned} & \frac{(x_1 - a)^2}{\sigma_1^2} - \frac{2\rho(x_1 - a)(x_2 - b)}{\sigma_1\sigma_2} + \frac{(x_2 - b)^2}{\sigma_2^2} \\ &= (1 - \rho^2) \frac{(x_1 - a)^2}{\sigma_1^2} + \left(\rho \frac{x_1 - a}{\sigma_1} - \frac{x_2 - b}{\sigma_2} \right)^2 \end{aligned}$$

得到

$$\begin{aligned} f_1(x_1) &= \int_{-\infty}^{\infty} f(x_1, x_2) dx_2 = (2\pi\sigma_1\sigma_2\sqrt{1-\rho^2})^{-1} \\ & \quad \cdot \exp\left(-\frac{(x_1 - a)^2}{2\sigma_1^2}\right) C \end{aligned}$$

其中

$$C = \int_{-\infty}^{\infty} \exp\left[-\frac{1}{2(1-\rho^2)} \left(\rho \frac{x_1 - a}{\sigma_1} - \frac{x_2 - b}{\sigma_2}\right)^2\right] dx_2$$

作变数代换(注意 x_1 为常数, 非积分变量)

$$t = \left(\frac{x_2 - b}{\sigma_2} - \rho \frac{x_1 - a}{\sigma_1} \right) / \sqrt{1 - \rho^2}$$

得

$$C = \int_{-\infty}^{\infty} \exp(-t^2/2) dt \cdot \sigma_2 \sqrt{1 - \rho^2} = \sqrt{2\pi}\sigma_2 \sqrt{1 - \rho^2}$$

以此代入前式, 即得

$$f_1(x_1) = (\sqrt{2\pi}\sigma_1)^{-1} \exp\left(-\frac{(x_1 - a)^2}{2\sigma_1^2}\right) \quad (2.12)$$

这正是 $N(a, \sigma_1^2)$ 的概率密度函数.

从这个例子看出一个有趣的事实: 虽则一个随机向量 $X = (X_1, \dots, X_n)$ 的分布 F 足以决定其任一分量 X_i 的(边缘)分布 F_i , 但反过来不对: 即使知道了所有 X_i 的边缘分布 $F_i, i = 1, \dots, n$, 也不足以决定 X 的分布 F . 例如, 考虑两个二维正态分布

$$N(0, 0, 1, 1, 1/3) \text{ 和 } N(0, 0, 1, 1, 2/3)$$

它们的任一边缘分布都是标准正态分布 $N(0, 1)$, 但这两个二维分布是不同的分布, 因为 ρ 的数值不相同. 这个现象的解释是: 边缘分布只分别考虑了单个变量 X_i 的情况, 而未涉及它们之间的关系, 而这个信息却是包含在 (X_1, \dots, X_n) 的分布之内的. 如就本例来说, 在下一章(见第三章 3.3 节)将指出: ρ 这个参数正好刻画了两分量 X_1 和 X_2 之间的关系.

在结束这一节之前, 我们再强调指出: “边缘”分布就是通常的分布, 并无任何特殊的含义. 如果说有什么意思的话, 它不过是强调了: 这个分布是由于 X_i 作为随机向量 (X_1, \dots, X_n) 之一分量, 从后者的分布中派生出的分布而已, 别无其他. 至于“边缘”一词的由来, 已在例 2.6 中解释过了.

与此相应, 为了强调 (X_1, \dots, X_n) 的分布是把 X_1, \dots, X_n 作为一个有联系的整体来考虑, 有时把它称为 X_1, \dots, X_n 的“联合分布”.

另外, 边缘分布也可以不只是单个的. 例如 $X = (X_1, X_2, X_3)$ 它的分布也决定了其任一部分, 例如 (X_1, X_3) 的二维分布, 这也称为边缘分布. 有关公式也不难导出, 此处不细讲了.