

概率论:Week 11

1 分布

性质 (测度的性质). 设 $(\Omega, \mathcal{F}, \nu)$ 是一个测度空间.

1. (单调性). 如果 $A \subset B$, 那么 $\nu(A) \leq \nu(B)$.

2. (次可加性). 对于任意序列 A_1, A_2, \dots ,

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

3. (连续性). 如果 $A_1 \subset A_2 \subset A_3 \subset \dots$ (或者 $A_1 \supset A_2 \supset A_3 \supset \dots$ 且 $\nu(A_1) < \infty$), 那么

$$\nu\left(\lim_{n \rightarrow \infty} A_n\right) = \lim_{n \rightarrow \infty} \nu(A_n),$$

其中

$$\lim_{n \rightarrow \infty} A_n = \bigcup_{i=1}^{\infty} A_i \quad \left(\text{或} = \bigcap_{i=1}^{\infty} A_i \right).$$

设 P 是一个概率测度, P 的累积分布函数定义为:

$$F(x) = P((-\infty, x]), \quad x \in \mathbb{R}$$

1. 设 F 是 \mathbb{R} 上的一个 c.d.f., 那么

(a) $F(-\infty) = \lim_{x \rightarrow -\infty} F(x) = 0$;

(b) $F(\infty) = \lim_{x \rightarrow \infty} F(x) = 1$;

(c) F 是非降的, 即若 $x \leq y$ 则 $F(x) \leq F(y)$;

(d) F 是右连续的, 即 $\lim_{y \rightarrow x, y > x} F(y) = F(x)$.


2. 假设 \mathbb{R} 上的实值函数 F 满足上述的四个条件, 那么 F 是 $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 上唯一的概率测度的 c.d.f.

注记 (对应关系). 概率的基本性质和分布函数的基本性质对应.

定义 (随机变量). 从可测空间 (Ω, \mathcal{F}) 到可测空间 $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 上的可测映射 X 被称为随机变量. 即 $X^{-1}(B) \in \mathcal{F}, \forall B \in \mathcal{B}(\mathbb{R})$, 或记为 $X^{-1}(\mathcal{B}(\mathbb{R})) \subset \mathcal{F}$. $X^{-1}(\mathcal{B}(\mathbb{R}))$ 是使随机变量 X 可测的最小 σ 代数.

之前, 我们说明了随机变量怎么产生一个分布函数(distribution function). 并说明了分布函数满足的一些条件: 单调非增, 规范性, 右连左极(书上是左连右极).

注记 (c.a.d.l.a.g.), *a càdlàg* (French: "continue à droite, limite à gauche"), *RCLL* ("right continuous with left limits"), or *corlol* ("continuous on (the) right, limit on (the) left") function is a function defined on the real numbers (or a subset of them) that is everywhere right-continuous and has left limits everywhere.



例 1 (实轴上的测度). $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 上的测度可以由一个 *Stieltjes* 测度函数 F 定义, *Stieltjes* 测度函数 F 是指

1. F 是单调非增的
2. F 是右连续的.

我们不加证明的给出以下的结论:

存在唯一的一个 $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 上的测度 μ 满足 $\mu((a, b]) = F(b) - F(a)$.
当 $F(x) = x$ 时, 得到的测度 μ 是 *Lebesgue* 测度.

现在我们反过来说: 满足上述三个条件, 一定可以定义一个分布函数.

定理. 如果函数(右连左极) F 满足单调非增, 规范性, 右连左极, 则函数 F 是某个随机变量 X 的分布函数.

证明. 令 $\Omega = (0, 1)$, \mathcal{F} 是上面的 *Borel* 集, 即 $\mathcal{F} = \mathcal{B}(\mathbb{R}) \cap (0, 1)$. 令 P 是一个 *Lebesgue* 测度(直线上的长度). 若 $\omega \in (0, 1)$, 定义

$$X(\omega) = \sup\{y : F(y) < \omega\}$$

只需证

$$\{\omega : X(\omega) \leq x\} = \{\omega : \omega \leq F(x)\}$$

因为 $P(\omega : \omega \leq F(x)) = F(x)$.

事实上, 一方面, 若 $\omega \in \{\omega : \omega \leq F(x)\}$, 即 $\omega \leq F(x)$, 则有 $X(\omega) \leq x$. 因为

$$\begin{aligned} X(\omega) &= \sup\{y : F(y) < \omega\} \\ &\leq \sup\{y : F(y) < F(x)\} \\ &= x \end{aligned}$$

另一方面, 由于 $X(\omega) \leq x$, 即 $\sup\{y : F(y) < \omega\} \leq x = \sup\{y : F(y) < F(x)\}$, 根据 F 是右连左极的, 因此 $\omega \leq F(x)$.

□

注记 (分布函数的逆). 书上直接定义

$$F^{-1}(y) = \inf\{x : F(x) > y\}$$

在 $0 < y < 1$ 时,

$$F^{-1}(F(y_0)) = \inf\{x : F(x) > F(y_0) = F(y_0 - 0)\}$$

若 $F(y_0) = F(y_0+)$, 则 $F^{-1}(F(y_0)) = y_0$; 若 $F(y_0) < F(y_0+)$, 则 $F^{-1}(F(y_0)) \geq y_0$. 上述逆也被称为“右连续逆”(right-continuous(RC) inverse), 也被记为 F^{-} .

若是右连左极的, 只需要把严格不等号改为不严格的.

$$F^{-1}(y) = \inf\{x : y \leq F(x)\}.$$

上述逆也被称为“左连续逆”(left-continuous(LC) inverse), 也被记为 F^{-} .

注记 (两种证明方法的等价性). 定义 $\sup\{\emptyset\} = 0$, 则

$$\inf\{x : F(x) > s\} = \sup\{x : F(x) \leq s\} \quad \inf\{x : F(x) \geq s\} = \sup\{x : F(x) < s\}$$

记 $A = \inf\{x : F(x) > s\}$, 则当 $F(x) > s, x \geq A, \forall \epsilon, \exists x_\epsilon, A < x + \epsilon$, 把 ϵ 移项即由定义可得.

如果 X 和 Y 能推出相同的分布 μ 在 $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ 上, 则称 X 和 Y 是“依分布相等”(equal in distribution) 的. 根据测度的生成, 依分布相等等价于 $P(X \leq x) = P(Y \leq x), \forall x$. 记之为

$$X =_d Y$$

例 2 (正态分布尾概率界的估计). 对于任意的 $x > 0$, 有

$$(x^{-1} - x^{-3}) \exp(-x^2/2) \leq \int_x^\infty \exp(-y^2/2) dy \leq x^{-1} \exp(-x^2/2)$$

证明. 对于上界, 写 $y = x + z$, 有

$$\begin{aligned} \int_x^\infty \exp(-y^2/2) dy &= \int_x^\infty \exp(-(x+z)^2/2) dz \\ &= \int_x^\infty \exp(-x^2/2 - xz - z^2/2) dz \\ &= \exp(-x^2/2) \int_0^\infty \exp(-xz) dz = x^{-1} \exp(-x^2/2) \end{aligned}$$

对于下界, 由于

$$\int_x^\infty (1 - 3y^{-4}) \exp(-y^2/2) dy = (x^{-1} - x^{-3}) \exp(-x^2/2)$$


即得. □

例 3 (练习: 正态分布的尾概率). 用上述的上下界估计 $P(N(0, 1) > 4)$.

```

1 > x=4
2 > {(1-pnorm(x))*sqrt(2*pi)}
3 [1] 7.938803e-05
4 > {x^(-1) * exp(-(x^2)/2)}
5 [1] 8.386566e-05
6 > {(x^(-1) - x^(-3)) * exp(-(x^2)/2)}
7 [1] 7.862405e-05

```



2 随机变量

在上一节, 我们介绍了一些具体的随机变量. 在这一节, 我们将梳理一些随机变量的具体性质.

定理. 若 $\{\omega : X(\omega) \in A\} \in \mathcal{F}, \forall A \in \mathcal{A}$, 且 $S = \sigma(\mathcal{A})$. 则 X 是可测的.

证明. 简写 $\{\omega : X(\omega) \in A\}$ 为 $\{X \in B\}$, 则有

$$\{X \in \cup_i B_i\} = \cup_i \{X \in B_i\}$$

$$\{X \in B^c\} = \{X \in B\}^c$$

于是集合系 $\mathcal{B} = \{B : \{X \in B\} \in \mathcal{F}\}$ 是一个 σ 域, $\mathcal{B} \supset \mathcal{A}, S = \sigma(\mathcal{A})$, 从而 $\mathcal{B} \supset S$ □

上述结论表明了, 如果 S 是一个 σ 域, 则 $\{\{X \in B\} : B \in S\}$ 也是一个 Ω 上的 σ 域, 它是 ω 上最小的保证 X 可测的结构, 也称它是“由随机变量 X 生成的 σ 域”.

$$\sigma(X) = \{\{X \in B\} : B \in S\}$$

例 4 (随机变量的证明). 假设 X 和 Y 是定义在概率空间 (Ω, \mathcal{F}, P) , 当 $A \in \mathcal{F}$ 上的随机变量. 定义 $Z(\omega)$, 对于 $\omega \in A$ 时, $Z(\omega) = X(\omega)$, 对于 $\omega \in A^c$ 时, $Z(\omega) = Y(\omega)$, 证明 Z 是一个随机变量.

证明.

$$\begin{aligned} Z^{-1}(B) &= [Z^{-1}(B) \cap A] \cup [Z^{-1}(B) \cap A^c] \\ &= [X^{-1}(B) \cap A] \cup [Y^{-1}(B) \cap A^c] \\ &\in \mathcal{B}(\mathbb{R}) \end{aligned}$$

□

例 5. 证明: 分布函数只有至多可列的间断点.

证明. 设 A 是分布函数 F 的不连续点构成的集合, 则 $\forall x < y \in A, F(x-) < F(x), F(y-) < F(y)$, 特别的, 我们取 $y-$ 充分靠近 y , 即 $x < y-$. 根据单调非降, 有

$$F(x-) < F(x) \leq F(y-) < F(y)$$

再根据有理数的稠密性, $\exists q_y \in (F(y-), F(y))$. 对每一个 A 中的元素重复上述操作. 定义 $\phi: A \rightarrow \mathbb{Q}, x \mapsto \phi(x) = q_x$, 则 ϕ 是一个到有理数上的单射, 因此 $|A| \leq \aleph_0$, 从而间断点至多可列. □

例 6 (正变换法). 之前我们介绍分布函数定义随机变量的方法, 链接起了均匀分布和一般分布函数之间的关系, 现在我们要说明: 随机变量有统一的方法变换为 $(0, 1)$ 上的均匀分布. 即取 $Y = F(X)$. 我们对 F 是连续函数的情况加以证明. 根据分布函数的连续性, 我们有

$$\{F^{-1}(F(X)) \leq F^{-1}(y)\} = \{X \leq F^{-1}(y)\}$$

因此

$$\begin{aligned} P(F(X) \leq y) &= P(F^{-1}(F(X)) \leq F^{-1}(y)) \\ &= P(X \leq F^{-1}(y)) \\ &= F(F^{-1}(y)) \\ &= y \end{aligned}$$

对于 $y = 0, P(F(X) \leq 0) = \lim_n P(F(X) \leq \frac{1}{n}) = \lim_n \frac{1}{n} = 0$. 对于 $y = 1, P(F(X) \leq 1) = \lim_n P(F(X) \leq 1 - \frac{1}{n}) = \lim_n 1 - \frac{1}{n} = 1$.

定理 (随机变量的可测变换还是随机变量). 若 $X: (\Omega, \mathcal{F}) \rightarrow (S, \mathcal{S})$ 和 $f: (S, \mathcal{S}) \rightarrow (T, \mathcal{T})$ 是两个可测映射, 那么 $f(X)$ 是 (Ω, \mathcal{F}) 到 (T, \mathcal{T}) 的可测映射.

证明. 取 $B \in \mathcal{T}, \{\omega: f(X(\omega)) \in B\} = \{\omega: X(\omega) \in f^{-1}(B)\} \in \mathcal{F}$, 根据 f 的可测性: $f^{-1}(B) \in \mathcal{S}$. □

3 随机变量独立性

注记 (A history of the symbol). *Graham, Knuth, and Patashnik proposed using \perp for relatively prime numbers in their book Concrete Mathematics, at least by the second edition (1994).*

Philip Dawid proposed a similar symbol $\perp\!\!\!\perp$ for (conditionally) independent random variables in 1979.

目前教材中共提到过四种独立性, 在此加以梳理

1. 事件的独立性
2. 随机变量的独立性
3. 随机向量的独立性
4. 试验的独立性

定义 (事件的独立性). 若两事件满足 $P(AB) = P(A)P(B)$ 则称两事件 A, B 独立.

定义 (随机变量的独立性). 两个随机变量 X, Y 相互独立是指对于直线上任意两个 *Borel* 点集 A, B , $P(X \in A, Y \in B) = P(X \in A)P(Y \in B)$. 即事件 $\{X \in A\}$ 和 $\{Y \in B\}$ 是独立的事件.

注记. 由于 A, B 是任意两个 *Borel* 点集, 因此可以这样通俗理解: 随机变量的独立性是指由他们生成的所有的事件都独立.

注记. $P(A) = P(I_A = 1)$, 事件独立也可以写成这种随机变量的形式, 显然 I_A, I_B 独立则事件 A, B 独立, 反过来由事件独立性能推对立事件的独立性, 从而 I_A, I_B 独立.

书上直接给出多元的情况,

定义 (随机变量的独立性*). 设 ξ_1, \dots, ξ_n 为 n 个随机变量, 若对于任意的 x_1, \dots, x_n 成立

$$P\{\xi_1 < x_1, \dots, \xi_n < x_n\} = P\{\xi_1 < x_1\} \cdots P\{\xi_n < x_n\}$$

则称 ξ_1, \dots, ξ_n 是相互独立的. 若 ξ_i 的分布函数为 $F_i(x), i = 1, 2, \dots, n$, 它们的联合分布函数为 $F(x_1, \dots, x_n)$, 则随机变量的独立性等价于对一切 x_1, \dots, x_n 成立

$$F(x_1, \dots, x_n) = F_1(x_1) \cdots F_n(x_n)$$

在离散和连续的情况下又分别等价于概率质量的乘积, 概率密度的乘积.

最后教材给出随机变量(向量)函数的独立性,

定理. 若 ξ_1, \dots, ξ_n 是相互独立的随机变量, 则 $f_1(\xi_1), \dots, f_n(\xi_n)$ 也是相互独立的, 这里 $f_i (i = 1, \dots, n)$ 是任意的一元 *Borel* 函数.

证明. 对任意的一维 *Borel* 点集 A_1, \dots, A_n 有

$$\begin{aligned} & P\{f_1(\xi_1) \in A_1, \dots, f_n(\xi_n) \in A_n\} \\ &= P\{\xi_1 \in f_1^{-1}(A_1), \dots, \xi_n \in f_n^{-1}(A_n)\} \\ &= P\{\xi_1 \in f_1^{-1}(A_1)\} \cdots P\{\xi_n \in f_n^{-1}(A_n)\} \\ &= P\{f_1(\xi_1) \in A_1\} \cdots P\{f_n(\xi_n) \in A_n\} \end{aligned}$$

□

4 随机变量函数的分布

4.1 卷积公式

首先说明离散卷积公式若 $Z = X + Y$ 可取 $0, 1, 2, \dots$ 所有非负整数. 而事件 $\{Z = k\}$ 是如下不相容事件

$$\{X = i, Y = k - i\}, \quad i = 0, 1, \dots, k$$

的并, 再考虑到独立性, 则对任意非负整数 k , 有

$$P(Z = k) = \sum_{i=0}^k P(X = i)P(Y = k - i).$$

这个概率等式被称为离散卷积公式.

在连续场合下, 若 ξ_1, ξ_2 相互独立, 则 $\eta = \xi_1 + \xi_2$ 的密度函数为

$$q(y) = \int_{-\infty}^{\infty} p_1(u)p_2(y-u)du = \int_{-\infty}^{\infty} p_1(y-u)p_2(u)du$$

离散型应用: p 相同情况下的二项分布, 不同参数的Poisson分布的可加性. 即:

$$Poi(\lambda_1) * Poi(\lambda_2) = Poi(\lambda_1 + \lambda_2)$$

$$b(n_1, p) * \cdots * b(n_k, p) = b\left(\sum_{i=1}^k n_i, p\right)$$

注记. 两Poisson随机变量差 $K = N_1 - N_2$ 的分布不再是Poisson分布, 而是Skellam分布, 其形式为

$$p(k; \mu_1, \mu_2) = \Pr\{K = k\} = e^{-(\mu_1 + \mu_2)} \left(\frac{\mu_1}{\mu_2}\right)^{k/2} I_k(2\sqrt{\mu_1\mu_2})$$

其中 μ_1, μ_2 为Poisson分布的参数.

连续型应用: 正态分布的可加性,

$$X_1 \sim N(\mu_1, \sigma_1^2), X_2 \sim N(\mu_2, \sigma_2^2) \Rightarrow X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$$

Γ 分布的可加性,

$$X_1 \sim \Gamma(\alpha_1, \beta), X_2 \sim \Gamma(\alpha_2, \beta) \Rightarrow X_1 + X_2 \sim \Gamma(\alpha_1 + \alpha_2, \beta)$$

特别的, χ^2 分布是 Γ 分布, 也具有可加性, 参数相同的指数分布加起来是 Γ 分布.

注记 (Γ 分布的两种形式: shape form, scale form). 根据第二个参数的不同写法有以下的两种形式:

- 尺度形式:

$$f(x) = \begin{cases} \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-x/\beta}, & 0 < x < \infty \\ 0, & \text{其他} \end{cases}$$

- 速率形式:

$$f(x) = \begin{cases} \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}, & 0 < x < \infty \\ 0, & \text{其他} \end{cases}$$

写成这两种情况的原因我们可以通过一个参数为 λ 的Poisson过程的例子说明: 我们假定拥有泊松过程的假设特别地, 设随机变量 W 表示所需获得的 k 个事件(可能死亡)发生的时间, 其中 k 是固定的正整数. 于是, W 的cdf为

$$G(w) = P(W \leq w) = 1 - P(W > w)$$

根据Poisson分布, 我们可以写出

$$P(W > w) = \sum_{x=0}^{k-1} P(X = x) = \sum_{x=0}^{k-1} \frac{(\lambda w)^x e^{-\lambda w}}{x!}$$

于是 λ 是到达的速率, $\frac{1}{\lambda}$ 是等待时间.

不加证明的给出下面的概率等式,

$$\int_{\lambda w}^{\infty} \frac{z^{k-1} e^{-z}}{(k-1)!} dz = \sum_{x=0}^{k-1} \frac{(\lambda x)^x e^{-\lambda w}}{x!}$$

则

$$G(w) = 1 - \int_{\lambda w}^{\infty} \frac{z^{k-1} e^{-z}}{\Gamma(k)} dz = \int_0^{\lambda w} \frac{z^{k-1} e^{-z}}{\Gamma(k)} dz$$

这对于 $w \leq 0, G(w) = 0$ 也成立. 若我们通过令 $z = \lambda y$ 定义 $G(w)$ 对积分中的积分变量进行变量变换, 则

$$G(w) = \int_0^w \frac{\lambda^k y^{k-1} e^{-\lambda y}}{\Gamma(k)} dy, \quad w > 0$$

因此pdf为:

$$g(w) = G'(w) = \begin{cases} \frac{\lambda^k w^{k-1} e^{-\lambda w}}{\Gamma(k)}, & 0 < w < \infty \\ 0, & \text{其他} \end{cases}$$

因此尺度形式刻画的是等待间隔, 速率形式刻画的是发生强度.

定理 (卷积定理). 假设 X, Y 是两个独立的随机变量, F, G 为其对应的累计分布函数, 则

$$P(X+Y \leq z) = \int F(z-y) dG(y).$$

其中 $dG(y)$ 表示“使用分布函数 G 的, 关于测度 ν 的积分”.

$$\begin{aligned} P(X+Y \leq z) &= \int \int 1_{(x+y \leq z)} \mu(dx) \nu(dy) \\ &= \int F(z-y) \nu(dy) = \int F(z-y) dG(y) \end{aligned}$$

4.2 顺序统计量

极值的分布首先求极大值 ξ_n^* 的分布函数,

$$\begin{aligned} P\{\xi_n^* < x\} &= P\{\max(\xi_1, \xi_2, \dots, \xi_n) < x\} \\ &= P\{\xi_1 < x, \xi_2 < x, \dots, \xi_n < x\} \\ &= P\{\xi_1 < x\} \cdot P\{\xi_2 < x\} \cdots P\{\xi_n < x\} \\ &= [F(x)]^n \end{aligned}$$

其次求极小值 ξ_1^* 的分布函数, 注意到

$$\begin{aligned} P\{\xi_1^* \geq x\} &= P\{\min(\xi_1, \xi_2, \dots, \xi_n) \geq x\} \\ &= P\{\xi_1 \geq x, \xi_2 \geq x, \dots, \xi_n \geq x\} \\ &= P\{\xi_1 \geq x\} P\{\xi_2 \geq x\} \cdots P\{\xi_n \geq x\} \\ &= [1 - F(x)]^n \end{aligned}$$

顺序统计量方法采用概率元的方法(习题46).

样本中观测值落于 $(-\infty, x]$ 内的概率为 $F(x)$, 落入区间 $(x, x + \Delta x]$ 内的概率为 $F(x, x + \Delta x) - F(x)$, 落入区间 $(x + \Delta x, \infty)$ 内的概率为 $1 - F(x, x + \Delta x)$. 将 n 个观测值分成这样的 3 组, 则其总的分法共有 $\frac{n!}{(k-1)!1!(n-k)!}$ 种. 于是, 由多项分布可得:

$$F_k(x + \Delta x) - F_k(x) \approx \frac{n!}{(k-1)!(n-k)!} F(x)^{k-1} (F(x + \Delta x) - F(x)) (1 - F(x + \Delta x))^{n-k}.$$

对两边除以 Δx , 并令 $\Delta x \rightarrow 0$, 即有:

$$f_k(x) = \lim_{\Delta x} \frac{F_k(x + \Delta x) - F_k(x)}{\Delta x} = \frac{n!}{(k-1)!(n-k)!} F(x)^{k-1} f(x) (1 - F(x))^{n-k}.$$

联合

$$\begin{cases} V = x_{(j)} - x_{(i)} \\ z = x_{(i)} \end{cases} \Rightarrow \begin{cases} x_{(i)} = z \\ x_{ij} = v + z \end{cases} \Rightarrow \begin{cases} x = z \\ x = v + z \end{cases}$$

4.3 变量变换方法

设二维随机变量 (X, Y) 的联合密度函数为 $p(x, y)$, 如果函数

$$\begin{cases} u = g_1(x, y), \\ v = g_2(x, y) \end{cases}$$

有连续偏导数, 且存在唯一的反函数

$$\begin{cases} x = x(u, v), \\ y = y(u, v), \end{cases}$$

由反函数存在定理, 其变换的雅可比行列式

$$J = \frac{\partial(x, y)}{\partial(u, v)} = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix} = \left(\frac{\partial(u, v)}{\partial(x, y)} \right)^{-1} = \begin{vmatrix} \frac{\partial u}{\partial x} & \frac{\partial u}{\partial y} \\ \frac{\partial v}{\partial x} & \frac{\partial v}{\partial y} \end{vmatrix}^{-1} \neq 0.$$

若

$$\begin{cases} U = g_1(X, Y), \\ V = g_2(X, Y), \end{cases}$$

则 (U, V) 的联合密度函数为

$$p(u, v) = p(x(u, v), y(u, v)) |J|$$

教材上给出高维的例子, 如果对 $y_i = g_i(x_1, \dots, x_n), i = 1, 2, \dots, n$, 存在唯一的反函数 $x_i(y_1, \dots, y_n) = x_i(i = 1, \dots, n)$, 而且 (η_1, \dots, η_n) 的密度函数为 $q(y_1, \dots, y_n)$, 那么

$$G(y_1, \dots, y_n) = \int_{\substack{u_1 < y_1 \\ \dots \\ u_n < y_n}} q(u_1, \dots, u_n) du_1 \dots du_n$$

可知

$$q(y_1, \dots, y_n) = \begin{cases} p(x_1(y_1, \dots, y_n), \dots, x_n(y_1, \dots, y_n)) |J| & \text{若 } (y_1, \dots, y_n) \text{ 属于 } g_1, \dots, g_n \text{ 的值域} \\ 0, & \text{其他} \end{cases}$$

其中 J 为坐标变换的雅可比行列式

$$J = \begin{vmatrix} \frac{\partial x_1}{\partial y_1} & \cdots & \frac{\partial x_1}{\partial y_n} \\ \vdots & & \vdots \\ \frac{\partial x_n}{\partial y_1} & \cdots & \frac{\partial x_n}{\partial y_n} \end{vmatrix}$$

这里, 我们假定上述偏导数存在而且连续.

4.4 增补变量法

增补变量法实质上是变量变换法的一种应用: 为了求出二维连续随机变量 (X, Y) 的函数 $U = g(X, Y)$ 的密度函数, 增补一个新的随机变量 $V = h(X, Y)$, 一般令 $V = X$ 或 $V = Y$. 先用变量变换法求出 (U, V) 的联合密度函数 $p(u, v)$, 再对 $p(u, v)$ 关于 v 积分, 从而得出关于 U 的边际密度函数. 设随机变量 X 与 Y 相互独立, 其密度函数分别为 $p_X(x)$ 和 $p_Y(y)$. 则 $U = XY$ 的密度函数为

$$p_U(u) = \int_{-\infty}^{\infty} p_X\left(\frac{u}{v}\right) p_Y(v) \frac{1}{|v|} dv.$$

证明记 $V = Y$, 则 $\begin{cases} u = xy, \\ v = y \end{cases}$ 的反函数为 $\begin{cases} x = \frac{u}{v}, \\ y = v, \end{cases}$ 雅可比行列式为

$$J = \begin{vmatrix} \frac{1}{v} & -\frac{u}{v^2} \\ 0 & 1 \end{vmatrix} = \frac{1}{v},$$

所以 (U, V) 的联合密度函数为

$$p(u, v) = p_X\left(\frac{u}{v}\right) \cdot p_Y(v) |J| = p_X\left(\frac{u}{v}\right) p_Y(v) \frac{1}{|v|}.$$

对 $p(u, v)$ 关于 v 积分, 就可得 $U = XY$ 的密度函数为

$$p_U(u) = \int_{-\infty}^{\infty} p_X\left(\frac{u}{v}\right) p_Y(v) \frac{1}{|v|} dv.$$