

随机变量函数的分布

选用表示方法: 对 $g(X)$:

$g \setminus X$	离散	连续
可列	PMF	PMF
连续	PMF	PDF

两套工具: CDF 和 PMF/PDF.

考察 $Y=g(X)$ 的分布. 若 $g(X)$ 连续则可通过以下两步实现:1° 得到 Y 的 CDF: $F_Y(y) = P(Y \leq y)$ 2° 求导得到 $f_Y(y) = \frac{dF_Y(y)}{dy}$.例: 设 $X \sim N(\mu, \sigma^2)$, 则 $Y = (X - \mu)/\sigma \sim N(0, 1)$.

$$P(Y \leq y) = P(X \leq \mu + \sigma y) = \int_{-\infty}^{\mu + \sigma y} \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) dx = \int_{-\infty}^y \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) dt = \int_{-\infty}^y \varphi(t) dt.$$

为标准正态分布的形式.

设 $X \sim N(0, 1)$, 求 $Y = X^2$ 的概率密度. ($y > 0, Y \geq 0$)

$$F_Y(y) = P(Y \leq y) = P(-\sqrt{y} \leq X \leq \sqrt{y}) = \Phi(\sqrt{y}) - \Phi(-\sqrt{y}) = 2\Phi(\sqrt{y}) - 1, \text{ 是连续的.}$$

$$f_Y(y) = F'_Y(y) = 2\varphi(\sqrt{y}) \cdot \frac{1}{2\sqrt{y}} = \frac{1}{\sqrt{2\pi y}} e^{-\frac{y}{2}}, \text{ 即 } Y \sim \Gamma\left(\frac{1}{2}, \frac{1}{2}\right). \text{ (正态} \rightarrow \text{Gamma)}$$

• $X \sim \mathcal{E}(\lambda), Y = \lambda X$. 证明 $Y \sim \mathcal{E}(1)$:

$$F_Y(y) = P(Y \geq y) = P(X \geq \frac{y}{\lambda}) = \int_{\frac{y}{\lambda}}^{\infty} \lambda e^{-\lambda t} dt = -e^{-y}, \quad f_Y(y) = \frac{dF_Y}{dy} = e^{-y}.$$

• Gamma 分布 $\Gamma(\alpha, \lambda)$. α 个 iid $\mathcal{E}(\lambda)$ 之和 α, λ 为正常数, 若 X 的密度是 $f_X(x) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}, x \geq 0$,称 X 服从参数 (α, λ) 的 Gamma 分布, $X \sim \Gamma(\alpha, \lambda)$. $\Gamma(\alpha) = \int_0^{\infty} x^{\alpha-1} e^{-x} dx$ 为 Gamma 函数.性质: $\Gamma(n) = (n-1)!$; $\Gamma(\alpha+1) = \alpha \Gamma(\alpha)$; $\Gamma(\frac{1}{2}) = \sqrt{\pi}$. α 称为形状参数 (shape parameter), λ 称为尺度参数 (rate parameter).考虑标准正态分布: $1 = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \stackrel{u=\frac{x^2}{2}}{=} \Rightarrow \sqrt{2\pi} = 2 \int_0^{+\infty} \frac{1}{\sqrt{2u}} e^{-u} du = \sqrt{2} \int_0^{+\infty} u^{-\frac{1}{2}} e^{-u} du = \sqrt{2} \Gamma(\frac{1}{2})$. $\alpha=1$ 时为指数分布, α 为正整数时称为 Erlang 分布.

线性变换 (改变伸缩倍数和平移)

$$Y = aX + b, \quad f_Y(y) = \frac{1}{|a|} f_X\left(\frac{y-b}{a}\right). \text{ 从 PDF 到 PDF.}$$

可以用该结论验证: 若 X 是服从正态分布的随机变量, 则 Y 也是正态的.* 扩展: $Y = g(X)$, $g(X)$ 是严格单调函数.那么事件 $\{x \leq X \leq x + \delta\} = \{g(x) \leq Y \leq g(x + \delta)\}$ 近似为 $g(x) + \delta |g'(x)|$.因此 $\delta f_X(x) = \delta f_Y(g(x)) \cdot |g'(x)|$, 即 $f_Y(y) = f_X(h(y)) |h'(y)|$, $h(y)$ 是 $g(x)$ 的逆映射.

例: $X \sim \Gamma(\alpha, 1)$, $f_X(x) = \frac{1}{\Gamma(\alpha)} x^{\alpha-1} e^{-x}$, $x > 0$, $Y = \frac{X}{\lambda}$, $f_Y(y) = \frac{\lambda^\alpha}{\Gamma(\alpha)} y^{\alpha-1} e^{-\lambda y}$, $Y \sim \Gamma(\alpha, \lambda)$.

计算技巧: $f_X(x) \left| \frac{dx}{dy} \right| = f_Y(y)$, $\left| \frac{dx}{dy} \right| = \left(\left| \frac{dy}{dx} \right| \right)^{-1}$.

更一般的定理: 设 X 的概率密度为 $f_X(x)$, $D \subset \mathbb{R}$, $Y = g(X)$, $P(Y \in D) = 1$. 若

1° 对 $y \in D$, $\{Y=y\} = \bigcup_{i=1}^n \{X=h_i(y)\}$;

2° 每个 $h_i(y)$ 是 D 到其值域 D_i 的可逆映射, 在 D 内有连续的导数;

3° $D_1, D_2, \dots, D_n$ 互不相交. $\left\{ \sum_{i=1}^n f_X(h_i(y)) |h_i'(y)|, y \in D \right.$

则 Y 的密度函数为 $f_Y(y) = \begin{cases} \sum_{i=1}^n f_X(h_i(y)) |h_i'(y)|, & y \in D \\ 0, & y \in D^c \end{cases}$

例 $r > 0$, $X \sim U(0, 2\pi)$, 求 $Y = r \cos X$ 的概率密度. (两种方法)

方法一: $D = (-r, r)$, $P(Y \in D) = 1$, $\{Y=y\} = \{X = \arccos \frac{y}{r}, X = 2\pi - \arccos \frac{y}{r}\}$ $\begin{cases} h_1(x) = 2\pi - h_2(x) \\ h_1(x) = \arccos \frac{y}{r} \end{cases}$

利用 $f_X(x) = \frac{1}{2\pi}$: $f_Y(y) = \frac{1}{2\pi} (|\frac{dy}{dx} h_1(y)| + |\frac{dy}{dx} h_2(y)|) = \frac{1}{\pi \sqrt{r^2 - y^2}}$, $-r < y < r$.

方法二: $P(Y \leq y) = P(\cos X \leq y/r) = \int_{x: \cos x \leq y/r} \frac{1}{2\pi} dx = \frac{1}{2\pi} (2\pi - 2\arccos \frac{y}{r})$.

$(\arccos x)' = -\frac{1}{\sqrt{1-x^2}}$, $f_Y(y) = \frac{1}{\pi \sqrt{r^2 - y^2}}$, $-r < y < r$.

随机向量及其分布 (特别关注多项分布, 二元正态分布)

(定义) 若 $X_1, \dots, X_n$ 都是概率空间 $(\Omega, \mathcal{F}, P)$ 上的随机变量, 称 $X = (X_1, \dots, X_n)$ 是概率空间上的 n 维随机向量.

(定义) $\vec{X}$ 为 n 维随机向量, $\mathbb{R}^n$ 上的 n 元函数: $F(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n)$

为 $\vec{X}$ 的联合概率分布函数, 简称分布函数或联合分布.

$F(x_1, \dots, x_n)$ 性质: $\mathbb{R}^n$ 上的右连续函数, 关于每个自变量 x_i 单调非降.

(定义) 若 $X_1, \dots, X_n$ 都是离散型随机变量, 称 $\vec{X} = (X_1, \dots, X_n)$ 为离散型随机向量.

若 X 所有的不同取值是 $\vec{x}(j_1, \dots, j_n) = (x_1(j_1), x_2(j_2), \dots, x_n(j_n))$, $j_i \geq 1$,

则称 $p_{j_1, \dots, j_n} = P(\vec{X} = \vec{x}(j_1, \dots, j_n))$ 是 $\vec{X}$ 的联合分布列.

性质: $p_{j_1, \dots, j_n} \geq 0$, $\sum_{j_1, \dots, j_n} p_{j_1, \dots, j_n} = 1$. (p 是在单一取值下的可能概率)

表格形式: p_{ij} y_1 y_2 $\dots$ $\{p_{i\cdot}\}$ $p_{i\cdot}$ 是各行和, $p_{\cdot j}$ 是各列和.

x_1	p_{11}	p_{12}	$\dots$	$p_{1\cdot}$
x_2	p_{21}	p_{22}	$\dots$	$p_{2\cdot}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$

$\{p_{i\cdot}, p_{\cdot j}\}$ 分别为 X, Y 的 PMF.

$\{q_j\}$ q_1 q_2 $\dots$ $\Sigma = 1$

(定义) 设离散型随机变量的联合分布列为 $P_{j_1, \dots, j_n}$, 则称 $(j \geq 1)$

$$P(X_1 = x_1(j_1), \dots, X_k = x_k(j_k)) = \sum_{j_{k+1}, \dots, j_n} P_{j_1, \dots, j_n}, \text{ 为 } X \text{ 的边缘分布列.}$$

(定义) 边缘分布/边际分布 marginal distribution

对 $1 \leq k < n$, $S_k = \{i_1, \dots, i_k\}$ 为指标集, 称 $X_{S_k} = (X_{i_1}, \dots, X_{i_k})$ 的联合分布

$$F_k(x_{i_1}, x_{i_2}, \dots, x_{i_k}) = P(X_{i_1} \leq x_{i_1}, \dots, X_{i_k} \leq x_{i_k}) = P(X_j \leq x_j, j \in S_k, X_t \leq \infty, t \in S_k^c).$$

为 $F_1(x_1, \dots, x_n)$ 的 k -维边缘分布. (一共有 $2^n - 2$ 个边缘分布)

离散型随机向量的独立性: 设 $\vec{X} = (X_1, \dots, X_n)$ 有概率分布 $P_{j_1, \dots, j_n} = P(\vec{X} = \vec{x}(j_1, \dots, j_n))$,

则 $X_1, \dots, X_n$ 相互独立的充要条件是: 对任意 $(x_1(j_1), x_2(j_2), \dots, x_n(j_n))$, 有

$$P(X_1 = x_1(j_1), \dots, X_n = x_n(j_n)) = \prod_{i=1}^n P(X_i = x_i(j_i)).$$

推论: (二维) 设离散型随机向量 (X, Y) 的所有不同取值是 $(x_i, y_j), i, j \geq 1$,

则 X, Y 相互独立的充要条件是 $\forall (x_i, y_j)$, 有 $P(X = x_i, Y = y_j) = P(X = x_i) P(Y = y_j)$.

$$\begin{aligned} \text{(证明)} \Leftarrow: P(X \leq x, Y \leq y) &= \sum_{x_i \leq x} \sum_{y_j \leq y} P(X = x_i, Y = y_j) = \sum_{x_i \leq x} \sum_{y_j \leq y} P(X = x_i) P(Y = y_j) \\ &= \sum_{x_i \leq x} P(X = x_i) \sum_{y_j \leq y} P(Y = y_j) = P(X \leq x) P(Y \leq y). \end{aligned}$$

$\Rightarrow: A = \{x_i\}$ 和 $B = \{y_j\}$ 都是 Borel 集, $\{X \in A\}$ 与 $\{Y \in B\}$ 独立, $P(X = x_i, Y = y_j) = P(X = x_i) P(Y = y_j)$.

为例: 多项分布. 设 $A_1, \dots, A_r$ 是试验 S 的完备事件组, 对试验 S 进行 n 次独立重复试验时, 用 X_i 表示 A_i 发生次数, 则 $(X_1, \dots, X_r)$ 的概率分布是

$$P(X_1 = k_1, \dots, X_r = k_r) = \frac{n!}{k_1! \dots k_r!} p_1^{k_1} \dots p_r^{k_r}, \text{ 其中 } k_i \geq 0, p_i = P(A_i), \sum_{i=1}^r k_i = n.$$

时 $1 \leq m < n$, $(X_{j_1}, \dots, X_{j_m})$ 的边缘分布为 $P(X_{j_1} = k_1, \dots, X_{j_m} = k_m) = \frac{n!}{k_1! \dots k_m!} p_{j_1}^{k_1} \dots p_{j_m}^{k_m} q^k$,
其中 $0 \leq k_i \leq n$, $k = n - \sum_{i=1}^m k_i \geq 0$, $q = 1 - \sum_{i=1}^m p_{j_i}$.

特别地, $P(X_j = k) = \binom{n}{k} p_j^k (1 - p_j)^{n-k}$, $k \geq 0$. (特殊情况下为二项分布)

*重要性质 若 $X_1, \dots, X_n$ 相互独立, 则 $F(X_1, \dots, X_k)$ 与 $G(X_{k+1}, \dots, X_n)$ 也相互独立.

一维: CDF
PMF PDF

高维: Joint CDF
Joint PMF Joint PDF
Marginal CDF Marginal PMF Marginal PDF

边缘推联合 (离散)

只能保证存在性, 不能保证唯一性. (连续): 既不保证唯一, 也不保证存在.

(下一部分会更新此图)

(定义) $\vec{x} = (x_1, \dots, x_n)$ 为随机向量, 若存在 $\mathbb{R}^n$ 上非负可积函数 $f(\vec{x})$, 使得对 $\mathbb{R}^n$ 的任何子立方体, $D = \{(x_1, \dots, x_n) | a_i < x_i < b_i, 1 \leq i \leq n\}$ 有

$P(X \in D) = \int_D f(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n = \int_D f(\vec{x}) d\vec{x}$, 则称 $\vec{x}$ 为连续型随机向量, $f(\vec{x})$ 是 $\vec{x}$ 的联合密度函数, 简称联合密度 / 概率密度.

(定理) 对 n 维 Borel 集 B 有 $P(X \in B) = \int_B f(\vec{x}) d\vec{x}$.

$\vec{x}$ 的联合概率密度不必唯一. $\mathbb{R}^n$ 是 Borel 集, $\int_{\mathbb{R}^n} f(\vec{x}) d\vec{x} = P(X \in \mathbb{R}^n) = 1$.

(定理) (会用即可) Fubini: 设 D 是 $\mathbb{R}^n$ 上的子区域, $\varphi(\vec{x})$ 是 D 上的非负函数或绝对可积函数 (指取绝对值后积分有限), 则对区域 D 上的 n 重积分 $\int_D \varphi(\vec{x}) d\vec{x}$

可以进行累次积分计算, 且积分次序可以交换.

二维边缘密度: 联合密度 $f(x, y)$, $f_x(x) = \int_{-\infty}^{+\infty} f(x, y) dy$, $f_y(y) = \int_{-\infty}^{+\infty} f(x, y) dx$.

(定义) 称被积函数 $f_k(x_1, \dots, x_k) = \int_{\mathbb{R}^{n-k}} f(x_1, \dots, x_n) dx_{k+1} \dots dx_n$ 是 $(x_1, \dots, x_k)$ 的联合密度, 称为 $\vec{x}$ 的边缘概率密度函数, 简称边缘密度.

注: 求连续型随机变量 概率密度 - 一定要注意范围, 建议用示性函数.

· 连续型随机向量的独立性

(PDF 不表示事件, 不能像离散型 PMF 一样直接拆开各项)

定理 设对每个 $i (1 \leq i \leq n)$, 随机变量 X_i 有概率密度 $f_i(x_i)$, 则 $X_1, \dots, X_n$ 相互独立的充要条件是 $\vec{x} = (x_1, \dots, x_n)$ 有联合密度 $f_1(x_1) \dots f_n(x_n)$, $\vec{x} \in \mathbb{R}^n$.

证明 $\Leftarrow$: $\forall \vec{x} \in \mathbb{R}^n$, $P(X_1 \leq x_1, \dots, X_n \leq x_n) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_n} f_1(t_1) \dots f_n(t_n) dt_1 \dots dt_n$
 $= \prod_{i=1}^n \int_{-\infty}^{x_i} f_i(t_i) dt_i = \prod_{i=1}^n P(X_i \leq x_i)$, 故 $X_1, \dots, X_n$ 相互独立.

$\Rightarrow$: 对 $\mathbb{R}^n$ 的任意子立方体用 Fubini 定理. 得

$P(X \in D) = P(a_1 < X_1 \leq b_1) \dots P(a_n < X_n \leq b_n) = \int_{a_1}^{b_1} f_1(t_1) dt_1 \dots \int_{a_n}^{b_n} f_n(t_n) dt_n$
 $= \int_D f_1(t_1) \dots f_n(t_n) dt_1 \dots dt_n$. 因此 $f_1(x_1) \dots f_n(x_n)$ 为联合密度.

* 例: 二元正态分布.

除了 $\mu_1, \mu_2, \sigma_1, \sigma_2$ 外引入新参数 ρ , 其中 $\sigma_1, \sigma_2 > 0$, $\rho \in (-1, 1)$,

$(X, Y) \sim N(\mu_1, \mu_2, \sigma_1, \sigma_2, \rho)$, 若 (X, Y) 有概率密度

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)}\left[\frac{(x-\mu_1)^2}{\sigma_1^2} - \frac{2\rho(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right]\right\}$$

引入矩阵 $\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$, $|\Sigma|$ 表示其行列式. $\vec{x} = (x, y)^T$, $\mu = (\mu_1, \mu_2)^T$,

证明独立的方法: 析联合分布列或考虑条件分布.

Date: /

前式简写为 $f(x) = \frac{1}{\sqrt{(2\pi)^2 |\Sigma|}} \exp(-\frac{1}{2} [x-\mu]^T \Sigma^{-1} (x-\mu))$.

例 $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2)$ 求 X, Y 的边缘密度. ($\mu_1 = \mu_2 = 0, \sigma_1^2 = \sigma_2^2 = 1$)

$$f_X(x) = \int f(x, y) dy = \frac{1}{\sqrt{2\pi} \sqrt{1-\rho^2}} \exp\left(\frac{y^2 - 2\rho xy + \rho^2 x^2 + x^2 - \rho^2 x^2}{2(1-\rho^2)}\right) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right).$$

发现此时 $f_X(x) \sim N(0, 1)$.

注意: 两个正态分布联合 (X, Y) 不一定是构成二元正态分布.

定理 设 $(X, Y) \sim N(\mu_1, \mu_2, \sigma_1^2, \sigma_2^2, \rho)$, 则 X, Y 独立的充要条件是 $\rho = 0$.

联合密度 $f(x, y) \rightarrow$ 联合分布 $F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) du dv$, (x, y 连续时) $f = \frac{\partial^2 F}{\partial x \partial y}$.

联合分布 $\rightarrow$ 联合密度: 若 $\frac{\partial^2 F}{\partial x \partial y}, \frac{\partial^2 F}{\partial y \partial x}, \frac{\partial^2 F}{\partial x^2}, \frac{\partial^2 F}{\partial y^2}$ 均连续, 则

(定理) $f(x, y) = \frac{\partial^2 F}{\partial x \partial y} = \frac{\partial^2 F}{\partial y \partial x}$ 为 (X, Y) 的联合密度函数.

说明: 更一般地, 设 (X, Y) 有连续分布函数 $F(x, y)$, 定义 $f(x, y) = \begin{cases} \frac{\partial^2 F(x, y)}{\partial x \partial y}, & \text{混合偏导存在} \\ 0, & \text{否则} \end{cases}$

若 $\int_{\mathbb{R}^2} f(x, y) dx dy = 1$ 则 $f(x, y)$ 是 (X, Y) 的联合密度.

若 X, Y 的分布函数连续, 则其在联合分布 $F(x, y)$ 连续.

· 存在随机向量 (X, Y) : 它有连续的联合分布, 但不是连续型随机向量.

(反例) $X \sim U(0, 1), Y = X$, 若有联合密度 $f(x, y)$, 用 D 表示 $y = x$ 直线上的全部点,

$1 = P(X=Y) = P((X, Y) \in D) = \int_D f(x, y) dx dy = 0$, 那么 (X, Y) 不是连续型随机向量.

条件密度和条件分布

· 离散型: joint PMF $p_{ij} = P(X=x_i, Y=y_j)$; marginal PMF $p_i = P(X=x_i), q_j = P(Y=y_j)$.

(定义) 对每个固定的 j , 称 $P(X=x_i | Y=y_j) = \frac{P(X=x_i, Y=y_j)}{P(Y=y_j)} = \frac{p_{ij}}{q_j}$ 为

给定条件 $Y=y_j$ 下, X 的条件分布列 (conditional PMF).

定理: X, Y 独立的充要条件: $\forall i, j \geq 1, P(X=x_i | Y=y_j) = P(X=x_i)$.

独立同分布序列 (iid): 随机变量 $\{X_i\}$ 相互独立并有相同的分布函数.

例 (射击问题) 用 S_n 表示第 n 次击中目标时的射击次数, 每次击中概率为 $p=1-q$.

$(X, Y) = (S_1, S_2)$ 的联合分布: $P(X=i, Y=j) = p^2 q^{j-2}, j \geq i \geq 1$.

边缘分布: $P(X=i) = pq^{i-1}, P(Y=j) = (j-1)p^2 q^{j-2}$.

条件分布: $P(Y=j | X=i) = pq^{j-i-1}, P(X=i | Y=j) = \frac{1}{j-1}$, 证明 $S_2=j$ 时, S_1 在 1 到 $j-1$

中的取值是等可能的. 若令 $X_1=S_1, X_2=S_2-S_1, (X_i=S_i-S_{i-1})$, 发现

$P(X_1=i, X_2=j) = P(X_1=i)P(X_2=j)$. $X_1, \dots, X_n$ 是独立同分布的.

例(孵化问题) $N \sim P(\lambda)$ 为鸡蛋总数, X 为孵化成功, Y 为失败.

$X/N = n \sim B(n, p)$. $X+Y=N$, 显然 $X \perp Y$. 接下来证明之.

$$P(X=i, Y=j) = P(X=i | N=i+j) P(N=i+j) = \frac{j+i-1}{i! j!} p^i q^j \frac{\lambda^{i+j}}{(i+j)!} e^{-\lambda}$$

$$= \frac{\lambda^i p^i}{i!} \frac{\lambda^j q^j}{j!} e^{-\lambda} \quad (\text{Poisson分布核心项}) = P(X=i) P(Y=j), \text{ 它们其实相互独立.}$$

技巧: 识别核心项; 归一化系数对应 PMF/PDF; 拆分快速判断独立性.

$X+Y=N$ 却相互独立是 Poisson 分布特性, 可用“密度”概念理解.

当发现联合分布列中 i, j 已经解耦(完全拆开), 可直接判定为相互独立.

例(消费问题) 超市单日顾客数 N 是随机变量, 单个顾客消费与 N 独立且服从 $P(\mu)$.

S 表示全天营业额, 求 $P(S=k|N)$.

X_j 表示第 j 个顾客的消费, $\{X_j\}$ 独立同分布. S_n 表示前 n 个顾客消费, $S_n \sim P(n\mu)$.

(要证: $S_n \sim P(n\mu)$: 先证 $n=2$ 情况, $X+Y=k$ 分类讨论并求和, $S_2 \sim P(2\mu)$.)

之后用归纳法证明.)

$$P(S=k|N=m) = P(S_m=k) = \frac{(m\mu)^k}{k!} e^{-m\mu}, \quad P(S=k|N) = \frac{(N\mu)^k}{k!} e^{-N\mu}.$$

· 连续型: 理解: 对 y 固定, $f_{X|Y}(x|y)$ 是一个概率密度函数 (PDF)

为了解条件密度, 考虑在 y 的周围施加一个微小扰动.

$$P(x \leq X \leq x+\Delta x | Y=y) \approx P(x \leq X \leq x+\Delta x | y \leq Y \leq y+\Delta y).$$

$$\approx \frac{f(x, y) \cdot \Delta x \cdot \Delta y}{f_Y(y) \cdot \Delta y} \quad (\text{直接用 PDF 计算}) \approx f_A(x) \cdot F_A(x) = \int_{-\infty}^x f_A(t) dt.$$

(先到 CDF 再求导得 PDF) 若 $f_Y(y)$ 在 y 连续, $f_Y(y) > 0$, $\frac{\partial F}{\partial y}$ 存在, 则 $\lim_{\Delta y \rightarrow 0} P(x \leq X | y \leq Y \leq y+\Delta y)$

$$= \lim_{\Delta y \rightarrow 0} \frac{F(x, y+\Delta y) - F(x, y-\Delta y)}{f_Y(y+\Delta y) - f_Y(y-\Delta y)} = \lim_{\Delta y \rightarrow 0} \frac{\frac{\partial F}{\partial y}}{f_Y(y)} = \frac{\frac{\partial}{\partial y} \left(\int_{-\infty}^x f(s, y) ds \right)}{f_Y(y)} = \frac{\int_{-\infty}^x f(s, y) ds}{f_Y(y)}.$$

(定义) 随机向量 (X, Y) 有联合密度 $f_{XY}(x, y)$, Y 边缘密度 $f_Y(y)$, 给定 $f_Y(y) > 0$, 则

$$P(X \leq x | Y=y) = \frac{\int_{-\infty}^x f(s, y) ds}{f_Y(y)} \text{ 为给定 } Y=y \text{ 时 } X \text{ 的条件分布函数, 记作 } F_{X|Y}(x|y).$$

称 $f_{X|Y}(x|y) = \frac{f(x, y)}{f_Y(y)} = \frac{f(x, y)}{\int_{-\infty}^{\infty} f(x, y) dy}$ 为 X 的条件概率密度.

· 条件密度与条件分布关系: 若 y 使得 $f_Y(y) > 0$, 有

$$1^\circ F_{X|Y}(x|y) = P(X \leq x | Y=y) = \int_{-\infty}^x f_{X|Y}(s|y) ds, \quad x \in \mathbb{R}.$$

2° 若 $F(x, y)$ 关于 x 连续, 且除去至多可数个点外有连续导数, 则 X 条件密度 $f_{X|Y}(x|y) = \begin{cases} \frac{\partial F_{X|Y}(x|y)}{\partial x} & \text{偏导存在} \\ 0 & \text{不存在} \end{cases}$

(定理) X, Y 独立的充要条件: 对 $y \in \{y | f_Y(y) > 0\}$, $f_{X|Y}(x|y) = f_X(x)$, $x \in \mathbb{R}$.

随机向量条件分布+边缘分布 $\rightarrow$ 联合分布 $\rightarrow$ 另一变量的边缘分布
 (定义) 设 $\vec{X} = (X_1, \dots, X_n)$ 和 $\vec{Y} = (Y_1, \dots, Y_m)$ 是随机向量, $f(\vec{x}, \vec{y})$ 为其联合密度, $\vec{Y}$ 的边缘密度 $f_Y(\vec{y}) = \int_{\mathbb{R}^n} f(\vec{x}, \vec{y}) d\vec{x}$. 给定 $\vec{y}$, $f_Y(\vec{y}) > 0$, 则称
 $P(X \leq x | Y = \vec{y}) = \frac{\int_{s \leq x} f(s, \vec{y}) ds}{f_Y(\vec{y})}$ 为 X 的条件分布函数 (条件分布), $F_{X|Y}(x|\vec{y})$.
 $f_{X|Y}(x|\vec{y}) = \frac{f(x, \vec{y})}{f_Y(\vec{y})}$ 为 X 的条件概率密度 (条件密度).

随机向量函数的分布 (都与正态分布有关, 统推里会讲)

- 卡方分布 Chi-Squared distribution (χ^2 分布) 卡方检验 可写作 χ^2 分布.
 多个正态独立同分布平方和. $f(x) = \frac{1}{2^{v/2} \Gamma(v/2)} x^{\frac{v}{2}-1} e^{-\frac{x}{2}}, x \geq 0$.
 $X \sim \chi^2$ (参数为 v) $\chi^2 \sim \Gamma(\frac{v}{2}, \frac{1}{2})$, 于是 $\chi^2_n = \Gamma(\frac{n}{2}, \frac{1}{2})$. $EX = n, \text{var}(X) = 2n$.
- Student's t 分布 t 检验 $f(x) = \frac{\Gamma(\frac{v+1}{2})}{\sqrt{v\pi} \Gamma(\frac{v}{2})} (1 + \frac{x^2}{v})^{-\frac{v+1}{2}}$.
 设有 $Z \sim N(0,1)$, $X \sim \chi^2_n$ 且 X 与 Z 独立, 令 $T = \frac{Z}{\sqrt{X/n}}$, 则有 $T \sim t_n$.
 对称性: $T \sim t_v$, 则 $-T \sim t_v$. 此正态分布重尾. $n \geq 2$ 时 $ET = 0$, $n \geq 3$ 时 $\text{var}(T) = \frac{n}{n-2}$.
 v 很大时 t_v 和标准正态分布很像; $v=1$ 时性质特殊, 也叫 Cauchy 分布.

- F 分布 Fisher Snedecor distribution 方差分析. 线性回归 (两个卡方分布)


$$f(x) = \frac{\Gamma(\frac{m+n}{2}) m^{\frac{m}{2}} n^{\frac{n}{2}} x^{\frac{m}{2}-1}}{\Gamma(\frac{m}{2}) \Gamma(\frac{n}{2}) (m+x)^{\frac{m+n}{2}}}, x \geq 0, X \sim F(m,n). \quad n \geq 3 \text{ 时 } EX = \frac{n}{n-2}.$$

(或 $X \sim \chi^2_m, Y \sim \chi^2_n$ 独立, $F = \frac{X/m}{Y/n}$)

独立同分布变量 $X_j \sim N(0,1), j=1, \dots, m$ 和 $Y_j \sim N(0,1), j=1, \dots, n$. $F = \frac{\frac{1}{m} \sum X_j^2}{\frac{1}{n} \sum Y_j^2}, F \sim F(m,n)$.

定理 n 维随机向量 X, Y 有相同分布, $g: \mathbb{R}^n \rightarrow \mathbb{R}^m$ 可测, 则 $g(X)$ 与 $g(Y)$ 有相同的分布.

PA $P(x|y) \leftrightarrow \text{Conditional } F(x|y) \leftrightarrow f(x|y)$ (连续时可推)



II:

$$F(x,y) = F_X(x) F_Y(y)$$

$$P(x,y) = P_X(x) P_Y(y) \quad f(x,y) = f_X(x) f_Y(y)$$

$$P(x|y) = P_X(x) \quad f_{X|Y}(x|y) = f_X(x)$$

CDF PDF / PMF

对 $X, Y \text{ i.i.d.} \sim N(0,1)$, 考虑随机变量 $T = \frac{X}{Y}$.

$$P(T \leq t) \Rightarrow P\left(\frac{X}{Y} \leq t\right) = P(X \leq tY) = \int_{-\infty}^{\infty} \int_{-\infty}^{ty} \phi(x) \phi(y) dx dy$$

$$= \int_{-\infty}^{+\infty} \Phi(t|y) \phi(y) dy. \quad f_T(t) = 2 \int_0^{+\infty} \phi(y) \phi(ty) y dy \rightarrow$$

$$f_T(t) = \frac{2}{\pi} \int_0^{+\infty} \exp\left(-\frac{y^2(1+t^2)}{2}\right) y dy. \quad \text{用 } u = -\frac{1}{2}y^2(1+t^2) \text{ 换元:}$$

$$f_T(t) = \frac{1}{\pi} \frac{1}{1+t^2} \int_0^{+\infty} e^{-u} du = \frac{1}{\pi(1+t^2)}. \rightarrow \text{积分部分是 } \Sigma(\lambda=1) \text{ 的 CDF.}$$

$$\text{或者 } P(X \leq t|Y) = \int P(X \leq t|y) P(Y=y) \phi(y) dy = \int \Phi(t|y) \phi(y) dy.$$

Cauchy 分布: t 分布在 $t_0=1$ 时的特例, $f(x) = \frac{1}{\pi(1+x^2)}$, $X \sim t_1$.

独立同分布变量 $Z_j \sim t_1$, 令 $X = \frac{Z_1 + \dots + Z_n}{n}$, 则依然有 $X \sim t_1$.

例 设 (X, Y) 有联合分布列, 求 $Z = X + Y$ 的分布列.

$$P_Z(Z=z) = P(X+Y=z) = \sum_x P(X=x) P(Y=z-x).$$

特别地, 当 X, Y 独立时, 有分布列 $P_Z(Z) = \sum_x P(X=x) P(Y=z-x) = \sum_x P_X(x) P_Y(z-x)$.

此时 Z 的分布列为 X 和 Y 的分布列的卷积 (convolution).

对连续型: (X, Y) 有联合密度 $f(x, y)$, 则 $Z = X + Y$ 有密度函数

$$f_Z(z) = \int_{-\infty}^{\infty} f(x, z-x) dx. \quad X, Y \text{ 独立时有 } f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx.$$

$$\text{证明: } P(a < X+Y \leq b) = \int_{\mathbb{R}^2} \mathbb{I}_{a < x+y \leq b} f(x, y) dx dy = \int_{\mathbb{R}} \left(\int_{a-x}^{b-x} f(x, y) dy \right) dx = \int_{\mathbb{R}} \left(\int_a^b f(x, z-x) dz \right) dx \\ = \int_a^b \left(\int_{\mathbb{R}} f(x, z-x) dx \right) dz. \quad \text{因此 } f_Z(z) = \int_{-\infty}^{\infty} f(x, z-x) dx = \int_{-\infty}^{+\infty} f(z-y, y) dy.$$

$$\text{或者用微元法: } P(z < X+Y \leq z+\Delta z) \approx f_Z(z) \Delta z \rightarrow \int_{-\infty}^{+\infty} \int_{z-x}^{z+\Delta z-x} f(x, y) dy dx = \int_{-\infty}^{+\infty} f_{X,Y}(x, z-x) dx.$$

例 均匀分布的独立同分布推广

$$\cdot X, Y \text{ 独立且 } \sim U(0,1), Z = X+Y. \quad f_X(x) = f_Y(y) = \mathbb{I}_{0 \leq x < 1}. \quad f_Z(z) = \int_0^1 \mathbb{I}_{0 \leq z-x < 1} dx = \begin{cases} z, & z \in [0,1] \\ 2-z, & z \in [1,2] \\ 0, & \text{otherwise} \end{cases}$$

$$X, Y \text{ 独立且 } \sim U(-1,1), Z = X+Y. \quad f_Z(z) = \int_{-1}^1 \mathbb{I}_{-1 \leq z-x < 1} dx = \begin{cases} \frac{1}{2}(2-|z|), & |z| \leq 2 \\ 0, & |z| > 2 \end{cases}.$$

有 $X_1, X_2, X_3 \sim U(-1,1)$, $f_{X_1+X_2+X_3}(x) = \frac{1}{6}(3-|x|)^2, 1 \leq |x| \leq 3$ 或 $\frac{1}{6}(3-x^2), 0 \leq |x| \leq 1$. $|x| > 3$ 无意义.

$$\text{i.i.d. } X_1, \dots, X_n \sim U(-1,1): f_{S_n}(x) = \frac{1}{2^n(n-1)!} \sum_{k=0}^{\lfloor \frac{n-|x|}{2} \rfloor} (-1)^k \binom{n}{k} (n+x-2k)^{n-1}, |x| \leq n.$$

对减法: $V = X - Y$ 有 $f_V(v) = \int_{-\infty}^{\infty} f(x, x-v) dx$. 特别地, 当 X, Y 独立时

$$f_V(v) = \int_{-\infty}^{+\infty} f_X(x) f_Y(x-v) dx = \int_{-\infty}^{+\infty} f_X(y+v) f_Y(y) dy.$$

* 特别注意易错题: X, Y 独立同分布, 且 $\sim N(0,1)$, $T = \frac{X}{Y}$ 的概率密度:

$$f_T(t) = \int_{-\infty}^{\infty} f_X(ty) f_Y(y) dy \Rightarrow \text{做法错误. 卷积公式只对和差适用.}$$

如果用微元理解: 随 X, Y 变化, 乘/除法不能直接提 Δz .

$$\text{用除法公式: } \int |y| f_X(t|y) f_Y(y) dy.$$

多个函数的联合密度

(多元随机变量函数)

设 $\vec{X} = (X_1, \dots, X_n)$ 有联合密度 $f(\vec{x})$, $Y_i = g_i(\vec{X})$, $\vec{Y} = (Y_1, \dots, Y_n)$ 是 $n \times 1$ 的函数.定理(只考虑二维) 设 (X, Y) 有联合密度 $f(x, y)$. $U = u(x, y)$, $V = v(x, y)$ 都是 (X, Y) 函数,平面上区域 D 使得 $P((U, V) \in D) = 1$. 若存在 D 上函数 $X_i(u, v)$, $Y_i(u, v)$, 使得1° 对 $(u, v) \in D$ 有 $\{U=u, V=v\} = \bigcup_{i=1}^n \{X=X_i, Y=Y_i\}$;2° $\Delta_i: X_i = X_i(u, v), Y_i = Y_i(u, v)$ 是 D 到其值域 D_i 的可逆映射, 有连续的偏导数, 且Jacobi 矩阵行列式绝对值 $|\frac{\partial(X_i, Y_i)}{\partial(u, v)}| \neq 0$.3° $D_1, \dots, D_n$ 互不相交.则 (U, V) 有联合密度 $g(u, v) = \begin{cases} \sum_{i=1}^n f(X_i(u, v), Y_i(u, v)) \left| \frac{\partial(X_i, Y_i)}{\partial(u, v)} \right| & (u, v) \in D \\ 0 & (u, v) \in D^c \end{cases}$ 用事件换元法解决 $P(T = \frac{X}{Y} \leq t)$: 考虑 (X, Y) 在二维平面内对应角度 α 的均匀分布, $P = P(0 \in [\alpha, \pi] \cup [\pi - \alpha, 2\pi])$, $\alpha = \arctan \frac{1}{t}$.或者 $P = 1 - \frac{\pi}{\pi} = 1 - \frac{1}{\pi} \arctan \frac{1}{t} \Rightarrow f_T(t) = \frac{1}{\pi(1+t^2)}$.例 设 X, Y 独立, $X, Y \sim N(0, 1)$, 考虑 $U = \frac{X}{Y}$ 和 $V = X^2 + Y^2$. (增补变量法)

$$f_{u,v}(u, v) = f_{X,Y}(X, Y) \left| \frac{\partial(X, Y)}{\partial(u, v)} \right| = f_X(X) f_Y(Y) \cdot \frac{1}{2(1+u^2)} = \frac{1}{4\pi} e^{-\frac{1}{2}u^2} \frac{1}{1+u^2}.$$

但这样系数会差 2: (u, v) 和 $(-u, v)$ 是一组 2 的关系, (X, Y) 与 $(-X, -Y)$ 结果相同. $g(u, v) = \frac{1}{2\pi(1+u^2)} e^{-\frac{1}{2}u^2}$, 即 u, v 独立, u 服从 Cauchy 分布, v 服从指数分布.总结: 求 $\frac{X}{Y}$ 等随机变量分布的方法:(General) $CDF \rightarrow f(X, Y)$ $CDF \rightarrow f_X \cdot f_Y$.

(Special) 微元法(特别关注卷积) 事件换元法. 增补变量法(如上)

对于多个函数的联合密度: 一般只考虑到二维.

注意点: $|\frac{\partial(X, Y)}{\partial(u, v)}|$ 上下次序(可先用逆矩阵 $|\frac{\partial(u, v)}{\partial(X, Y)}|$ 取行列式倒数).例: X, Y 独立, $X, Y \sim N(0, 1)$, 由极坐标变换 $\begin{cases} X = R \cos \theta \\ Y = R \sin \theta \end{cases}$, 求 (R, θ) 的联合密度.

$$f_{X,Y} = \frac{1}{2\pi} \exp(-\frac{X^2+Y^2}{2}), \text{ 定义 } D = \{(r, \theta) | r > 0, \theta \in [0, 2\pi)\}. P((R, \theta) \in D) = 1.$$

$$\left| \frac{\partial(X, Y)}{\partial(r, \theta)} \right| = r > 0, g(r, \theta) = f(r \cos \theta, r \sin \theta) \cdot r = \frac{1}{2\pi} r \exp(-\frac{r^2}{2}) = \frac{1}{2\pi} \exp(-\frac{r^2}{2}).$$

 r 和 θ 独立, $g_R(r) = r \exp(-\frac{r^2}{2})$, 为 Rayleigh 分布, $\theta \sim U(0, 2\pi)$.

次序统计量 order statistics

(定义) 设 $X_1, X_2, \dots, X_n$ 是概率空间 $(\Omega, \mathcal{F}, P)$ 上的随机变量, 对 $\omega \in \Omega$, 将 $X_1(\omega), \dots, X_n(\omega)$ 称 $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ 从小到大排列得到 $X_{(1)}(\omega) \leq X_{(2)}(\omega) \leq \dots \leq X_{(n)}(\omega)$ 为原 $\{X_i\}$ 的次序统计量.

下设 $X_1, X_2, \dots, X_n$ 为 iid, 有共同的分布函数 $F(x)$ 和 密度函数 $f(x)$.

性质 1° $(X_{(1)}, \dots, X_{(n)})$ 有联合密度 $g(x_1, \dots, x_n) = \begin{cases} n! \prod_{i=1}^n f(x_i), & x_1 \leq \dots \leq x_n \\ 0, & \text{otherwise} \end{cases}$

2° $X_{(k)}$ 有密度 $g_k(x_k) = n \binom{n-1}{k-1} [F(x_k)]^{k-1} [1-F(x_k)]^{n-k} f(x_k)$.

3° 对于 $-\infty \leq a < x_1 < \dots < x_k < b \leq \infty$, 有

$$\int_a^b \int_{x_1}^b \dots \int_{x_{k-1}}^b f(x_1) \dots f(x_k) dx_1 \dots dx_k = \frac{1}{k!} (F(b) - F(a))^k$$

3° 可用归纳法证明. 由 Fubini 定理 $= \int_a^b \frac{1}{(k-1)!} (F(x_k) - F(a))^{k-1} f(x_k) dx_k$.

4° 对 $k < k_2$, $(X_{(k)}, X_{(k_2)})$ 有联合密度 $(X_{(k)} < X_{(k_2)})$

$$g(x_k, x_{k_2}) = \frac{n!}{(k-1)!(k_2-k-1)!(n-k_2)!} [F(x_k)]^{k-1} [F(x_{k_2}) - F(x_k)]^{k_2-k-1} [1-F(x_{k_2})]^{n-k_2} f(x_k) f(x_{k_2})$$

Beta 分布 $\text{Beta}(\alpha, \beta)$, $\alpha, \beta > 0$

$$f(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, \quad 0 < x < 1, \quad \text{其中 } B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}$$

常在 Bayes 统计方法中作为参数的先验分布. 特别地, 它是二项分布的共轭分布.

↓ $|X|p \sim B(n, p)$, p 的先验 $B(\alpha, \beta)$, 观测 X 后得到后验 $\text{Beta}(\alpha+X, \beta+n-X)$.

· 例 灯泡问题. 若每个灯泡的寿命 $X_i \sim \varepsilon(\lambda)$, 教室内原本装有 4 只灯泡, 现在想换成 24 只, 第一只灯泡损坏的时长 Z 如何变化?

由上述性质 2, 4 只灯泡时 $g_2(X_{(1)}) = \varepsilon(4\lambda)$, 24 只时 $g_2(X_{(1)}) = \varepsilon(24\lambda)$.

那 $n > 4$ 只灯泡时 更快出现灯泡损坏的概率更大.

例 均匀分布 $\{X_n\}$ iid, $X_i \sim U(0, 1)$. 极差 $R = X_{(n)} - X_{(1)}$.

1° (随机向量函数) 求 R 的 pdf. 由公式 $f(X_{(1)}, X_{(n)}) = \frac{n!}{0!(n-2)!0!} x_1^0 (x_n - x_1)^{n-2} (1-x_n)^0 \cdot 1 \cdot 1 = n(n-1)(x_n - x_1)^{n-2}$

$$P(R \leq x) = \int_0^x dx_1 \int_{x_1}^{x_1+x} f(x_1, x_n) dx_n + \int_{1-x}^1 dx_1 \int_{x_1}^1 f(x_1, x_n) dx_n = nx^{n-1} - (n-1)x^n$$

$$R \text{ 的 pdf: } f_R(x) = n(n-1)x^{n-2}(1-x)$$

2° 条件密度: 在 $X_{(n)} = y$ 条件下, 求 $X_{(1)}$ 和 $(X_{(2)}, \dots, X_{(n-1)})$ 条件密度 $\Rightarrow f_{X_{(1)}|X_{(n)}}(y) = ny^{n-1}$.

$$f_{X_{(1)}|X_{(n)}}(x_1|y) = \frac{f_{X_{(1)}, X_{(n)}}(x_1, y)}{f_{X_{(n)}}(y)} = \frac{n(n-1)(y-x_1)^{n-2}}{ny^{n-1}} = \frac{(n-1)(y-x_1)^{n-2}}{y^{n-1}}$$

$$f(X_1, \dots, X_n) = n! f(X_1, \dots, X_{n-1}|y) = \frac{n!}{ny^{n-1}} = \frac{(n-1)!}{y^{n-1}}, \quad x_1 \leq \dots \leq x_{n-1} \leq y.$$

(联合密度)

随机变量的 p 分位数

设 X 是 $(\Omega, \mathcal{F}, P)$ 上的 r.v. 分布函数为 $F(x)$.

该式确定的 p 不唯一.

(直观定义) 对 $p \in (0, 1)$, 若 $P(X \leq \alpha) \geq p$, $P(X \geq \alpha) \geq 1 - p$, 称 α 为 X 的 p -分位数.

(正式定义) 对 $p \in (0, 1)$, 定义 $F^{-1}(p) = \inf\{x | F(x) \geq p\}$, 称 $F^{-1}(p)$ 为 F 或 X 的 p 分位数

(p -quantile), 通常用 x_p 表示. 此时即为 X 或 F 的中位数. 定义等价于 $F^{-1}(p) = \sup\{x | F(x) < p\}$.

常见应用: 统计计算 (要求唯一性), 统计推断 (通常不要求唯一性)


性质 1° $F^{-1}(p)$ 单调非降

$$2^\circ F^{-1}(F(x)) \leq x, \forall x \in \mathbb{R}$$

$$3^\circ F(F^{-1}(p)) \geq p, \forall p \in (0, 1).$$

$$*4^\circ F^{-1}(p) \leq t \Leftrightarrow p \leq F(t).$$

5° $F^{-1}(p)$ 左连续.



6. 若 F 连续, 则 $F(F^{-1}(p)) = p, \forall p \in (0, 1).$

(定理): 产生服从分布函数 $F(x)$ 的随机变量:

设 $X \sim U(0, 1)$, $F(x)$ 是分布函数, 则 $Y = F^{-1}(X) \sim F$.

例 设 $F(x)$ 为随机变量 X 的 cdf, 且 $F(x)$ 是连续分布函数, 则 $F(X) \sim U(0, 1)$.

设 $Y = F(X)$, $P(Y \leq y) = P(F(X) \leq y) = P(X \leq F^{-1}(y)) = F(F^{-1}(y)) = y$, 则 $Y \sim U(0, 1)$.

接下来考虑: 易生成服从均匀分布的随机变量, 如何生成服从下列分布函数的 r.v.:

$$1. \text{Exp. } X = -\lambda^{-1} \lg(1 - U), U \sim U(0, 1).$$

$$2. \text{Cauchy 分布. } Z = X/Y, \text{ 其中 } X, Y \text{ 相互独立且服从 } N(0, 1).$$

$$3^\circ \text{ 令 } \theta = 2\pi U, R = \sqrt{-2 \lg V} \text{ (} U, V \sim U(0, 1) \text{ 且相互独立) 则 } X = R \cos \theta \text{ 和 } Y = R \sin \theta$$

相互独立, 且都服从 $N(0, 1)$.

证明: (利用多个函数的联合密度) (参考前页极坐标变换例题) $R = \sqrt{-2 \lg U} \sim \text{Rayleigh 分布}$,

$\theta = 2\pi U \sim U(0, 2\pi)$. R 与 θ 独立. 由此前定理: X, Y 同分布, $g: \mathbb{R}^n \rightarrow \mathbb{R}^m$ 可测, 则 $g(X)$ 与

$g(Y)$ 同分布. 当时为了得到两个正态分布的极坐标变换构造了 R, θ , 那么

$$X = \sqrt{-2 \lg U} \cos(2\pi V), Y = \sqrt{-2 \lg U} \sin(2\pi V), X, Y \text{ 独立且服从 } N(0, 1). \text{ (用于产生正态随机变量)}$$

4° (离散型) $F_n(x) = \frac{1}{n} \sum_{i=1}^n I(x_i \leq x)$, 其中 $x_1, \dots, x_n$ 是给定的观测值. (利用次序统计量)

$F_n(x)$ 是阶梯函数. 令 $x_{(1)} \leq \dots \leq x_{(n)}$ 是 $\{x_i\}$ 的次序观测值, 因为

$$F^{-1}(x) = x_{(1)} \text{ (} 0 < x \leq \frac{1}{n} \text{), } x_{(2)} \text{ (} \frac{1}{n} < x \leq \frac{2}{n} \text{), } \dots, x_{(n)} \text{ (} \frac{n-1}{n} < x \leq 1 \text{).}$$

所以 $F^{-1}(u)$ 的值域为 $\{x_{(i)}\}$ 且 $P(F^{-1}(u) = x_{(k)}) = P(\frac{k-1}{n} < u \leq \frac{k}{n}) = \frac{1}{n}, k = 1, \dots, n$.

期望与方差

目的: 在事情发生前刻画整体情况; 总结事件; 便于决策.

(定义) 离散型: X 有概率分布 $P(X=x_j), j=1, 2, \dots$ 若 $\sum_{j=1}^{\infty} |x_j| P(X=x_j) < +\infty$ (绝对收敛),

称 $E(X) = \sum_{j=1}^{\infty} x_j P(X=x_j)$ 为 X 的数学期望或均值.

随机变量总结为一个数: (加权) 平均. 有限个值的 r.v. 的期望总存在.

直观示例: A 为事件, 1_A 是 A 的示性函数, 则 1_A 服从两点分布, 且 $E1_A = P(A)$.

· 二项分布 $X \sim B(n, p)$, $p_j = \binom{n}{j} p^j (1-p)^{n-j}$, $E(X) = np$.

(用归一化证明) $E(X) = \sum_{j=0}^n j \binom{n}{j} p^j (1-p)^{n-j}$, 其中 $j \binom{n}{j} = n \binom{n-1}{j-1}$,

$E(X) = np \sum_{j=1}^n \binom{n-1}{j-1} p^{j-1} (1-p)^{n-j} = np (p + (1-p))^m = np$.

· 泊松分布 $X \sim P(\lambda)$ 同理 $E(X) = \lambda$.

· 几何分布 $X \sim G(p)$ $E(X) = \frac{1}{p}$.

(定义) 连续型: 设 X 有概率密度 $f(x)$, 若 $\int_{-\infty}^{+\infty} |x| f(x) dx < +\infty$,

称 $E(X) = \int_{-\infty}^{+\infty} x f(x) dx$ 为 X 的数学期望或均值.

· 均匀分布 $X \sim U(a, b)$ $E(X) = \frac{a+b}{2}$ (分部积分)

· 指数分布 $X \sim Z(\lambda)$ $E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \int_0^{\infty} \lambda x e^{-\lambda x} dx = \frac{1}{\lambda}$.

例 任意给 - Gamma 分布 (Gamma) $f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}$, $x > 0$. ($X \sim \Gamma(\alpha, \beta)$).

$E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \int_0^{\infty} \frac{\beta^\alpha}{\Gamma(\alpha)} x^\alpha e^{-\beta x} dx = \frac{1}{\beta \Gamma(\alpha)} \int_0^{\infty} t^{\alpha+1} e^{-t} dt$, $t = \beta x$ 换元.

$\int_0^{\infty} t^{\alpha+1} e^{-t} dt = \Gamma(\alpha+1) \int_0^{\infty} f(x \sim \Gamma(\alpha+1, 1)) dt = \Gamma(\alpha+1)$,

$E(X) = \frac{1}{\beta \Gamma(\alpha)} \Gamma(\alpha+1) = \frac{\alpha}{\beta}$.

· 正态分布 $X \sim N(\mu, \sigma^2)$. 先用 $X - \mu$ 换元.

由对称性、归一化, $E(X) = \int_{-\infty}^{+\infty} x f(x) dx = \int_{-\infty}^{+\infty} \mu f(x) dx + \int_{-\infty}^{+\infty} (x - \mu) f(x) dx$

$= \mu + \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{+\infty} (x - \mu) \exp(-\frac{(x - \mu)^2}{2\sigma^2}) dx$ 奇函数 $\rightarrow E(X) = \mu$.

· (直观利用“重心性质”): $E(X)$ 存在, $f(x)$ 关于 $x = \mu$ 对称, 即 $f(x + \mu) = f(\mu - x)$, 则 $E(X) = \mu$.

一般随机变量的数学期望: $E(X) = \int_{\Omega} X dP = \int_{\mathbb{R}} x dF(x)$, F 为分布函数.

(将离散的求和形式化地写成积分形式) 对任意单调不减右连续函数 $F(x)$, 若 F 在

(a, b) 上似有可列个跳跃点且 $\sum_{j: x_j \in (a, b)} |f(x_j)| [F(x_j) - F(x_j - 0)] < \infty$ 则 $\int_a^b f(x) dF(x) = \sum_{j: x_j \in (a, b)} f(x_j) [F(x_j) - F(x_j - 0)]$

若 $F(x)$ 可分解为 $F_1(x) + F_2(x)$, 其中 $F_1(x) = \int_a^x f_1(s) ds$, $F_2(x)$ 可列个跳跃点, 若 F_1, F_2 均绝对收敛,

则 EX 存在且 $EX = \int_{-\infty}^{+\infty} x f_1(x) dx + \sum_{j=1}^{\infty} x_j P(X=x_j) = \int_{-\infty}^{+\infty} x dF_1(x) + \int_{-\infty}^{+\infty} x dF_2(x) = \int_{-\infty}^{+\infty} x dF(x)$.

随机变量函数的数学期望:

(定理) 设 $X = (X_1, X_2, \dots, X_n)$ 为随机向量 (随机变量同理), $\vec{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$. 若

X 有联合分布函数 $F(\vec{x})$, 实函数 $g(\vec{x})$ 使得 $\int_{\mathbb{R}^n} |g(\vec{x})| dF(\vec{x}) < \infty$,

则 $Y = g(\vec{X})$ 有期望 $E(Y) = E(g(\vec{X})) = \int_{\mathbb{R}^n} g(\vec{x}) dF(\vec{x})$.

离散情形结论类似. 对 $Y = g(X)$, $EY = g(EX)$ 可以直接应用 (g 符合条件时)

$$E(X+Y) = \int z f_Z(z) dz = \int (x+y) f_{X,Y}(x,y) dx dy.$$

一般地说, $E(g(X)) \neq g(EX)$. 以下为一些特例:

(定理) $E|X| < +\infty$, $E|Y| < +\infty$, $a, b, c \in \mathbb{R}$, 则

$$1^\circ E c = c \text{ (常数)}$$

$$2^\circ |EX| \leq E|X|.$$

$$* 3^\circ E(aX + bY) = aEX + bEY \text{ (linearity, 线性组合可直接提系数)}$$

$$4^\circ X \leq Y \text{ a.s.} \Rightarrow EX \leq EY. \quad (\text{反过来不对})$$

$$* 5^\circ X \text{ 和 } Y \text{ 独立, 则 } E(XY) = (EX)(EY). \quad (\text{Fubini 定理, 可以直接拆乘法, 要求独立})$$

(由此, 二项分布相当于 n 个两点分布之和, Gamma 分布可看作 α 个 $\varepsilon(\beta)$ 之和)

例 (邮票收藏问题) 有一盒共 N 张邮票, 从中有放回地每次抽取一张, 要收集 k 张不同的邮票, 那么抽取次数的期望?

想抽取到第 i 张不同的邮票, 相当于概率为 $\frac{N-i+1}{N}$ 的几何分布, $\varepsilon_i = \frac{N}{N-i+1}$.

(如抽到第一张 $\varepsilon_1 = 1$) 抽取次数的期望相当于 $\varepsilon_1 \sim \varepsilon_k$ k 个几何分布的期望之和 (拆分成可计算的分布) $\sum_{i=1}^k \varepsilon_i = N \left(\sum_{m=1}^N \frac{1}{m} - \sum_{m=1}^{N-k} \frac{1}{m} \right) \approx N \ln \frac{N+1}{N-k+1}$.

定理 设 $EX = \mu$, $EX^2 < \infty$, 则 $E(X-\mu)^2 \leq E(X-c)^2$, $\forall c \in \mathbb{R}$.

证 等价表达 (优化角度): $E(X) = \arg \min_{c \in \mathbb{R}} E(X-c)^2$.

$$E(X-c)^2 = E(X-\mu+\mu-c)^2 = E(X-\mu)^2 + 2(\mu-c) \underbrace{E(X-\mu)}_{=0} + (\mu-c)^2 = E(X-\mu)^2 + (\mu-c)^2.$$

中位数: X 有概率密度 $f(x)$, m 是其中位数, 则 $m = \arg \min E|X-c|$.

中位数在社会统计资料中常用. 优点: 一定存在, 不易受极值影响.

概统中期望比中位数更重要. 性质优良; 中位数可能不唯一)

例: $X \sim t$, 即 Cauchy 分布, 求 $E(X)$.

考虑 $X, Y \sim N(0,1)$ 且独立, $\varphi \sim t$, $E(\varphi)$ 是否存在? (接下页)

例 Cauchy 分布 ($X \sim t_1$) 的 EX : 由对称性可直观判断 $EX=0$.

若 $X, Y \sim N(0,1)$ 且独立, 则 $\frac{X}{Y} \sim t_1$. $f_X = f_Y = \frac{1}{\sqrt{\pi}} e^{-x^2}$.

$E\frac{X}{Y} \neq \frac{EX}{EY}$: 乘/除法不能拆开. $\frac{EX}{EY} = \frac{0}{0} \Rightarrow$ 不存在.

但实际上 $E|X| = \int_{-\infty}^{+\infty} \frac{|x|}{\pi(1+x^2)} dx = \frac{2}{\pi} \int_0^{+\infty} \frac{x}{1+x^2} dx = \frac{2}{\pi} \cdot \frac{1}{2} \ln(1+x^2) \Big|_0^{+\infty} = +\infty$.

Cauchy 有特殊性质, 但其期望不存在, 也称为 evil distribution.

例 $X \sim \Gamma(\alpha, 1)$, $Y \sim \Gamma(\beta, 1)$, $T = X+Y$, $W = \frac{X}{X+Y}$. X, Y 相互独立. $\begin{cases} X = TW \\ Y = T(1-W) \end{cases}$
1° 判断 T 和 W 是否相互独立, 考虑联合 PDF 能否拆开.

$$f_{T,W}(t, w) = f_{X,Y}(x, y) \left| \frac{\partial(x, y)}{\partial(t, w)} \right| = t f_X(x) f_Y(y).$$

$$= t t^{\alpha-1} \frac{1}{\Gamma(\alpha)} e^{-x} t^{\beta-1} \frac{1}{\Gamma(\beta)} e^{-y} = \frac{1}{\Gamma(\alpha)\Gamma(\beta)} e^{-t} (tw)^{\alpha-1} [t(1-w)]^{\beta-1}$$

$$= \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} w^{\alpha-1} (1-w)^{\beta-1} \cdot \frac{1}{\Gamma(\alpha+\beta)} t^{\alpha+\beta-1} e^{-t}. \text{ 那么 } W \sim \text{Beta}(\alpha, \beta), T \sim \Gamma(\alpha+\beta, 1).$$

即 W 与 T 相互独立. 2° 此时 $EW = \frac{EX}{ET} = \frac{EX}{E(X+Y)}$. (一般情况不成立)

· 若 $E|X|=0$, 则 $P(X=0)=1$, 即 $X=0$ a.s.

$$\text{证明: } P(|X|>h) = P(\ln|X|>\ln h) = E[\mathbb{I}_{\ln|X|>\ln h}] \leq E(\ln|X| \mathbb{I}_{\ln|X|>\ln h}) \leq n E|X| = 0$$

由概率连续性, $P(|X|>0) = P(\bigcup_{h>0} \{|X|>h\}) = \lim_{h \rightarrow 0} P(|X|>h) = 0$. 最后 $P(X=0)=1$.

高阶矩(定义) Moment 设 X 为 r.v., $m \in \mathbb{N}^+$. 若 $E|X|^m < \infty$, 称 $E|X|^m$ 为 X 的 m 阶原点矩, 称 $E(X-EX)^m$ 为 X 的 m 阶中心矩.

$m \geq 2$ 时以上原点/中心矩统称高阶矩. $m=3$ 偏度 skewness $m=4$ 峰度 kurtosis
(定义): 随机变量的方差 (Variance)

若随机变量 X 的期望 $\mu = EX$ 有限, 称 $E(X-\mu)^2$ 为 X 的方差, 记为 $\text{var}(X)$ 或 σ_X^2 .

当 $\text{var}(X) < \infty$ 时, 称 X 的方差有限. 表示了 X 在期望附近的集中程度.

常用公式: $\text{var}(X) = E(X-EX)^2 = E(X^2) - E^2(X)$. *

· 两点分布 $\text{var}(X) = p(1-p) = pq$, 二项分布 $\text{var}(X) = npq$.

· 泊松分布 $E(X) = E(X(X+1)) + E(X) = \sum_{k=0}^{\infty} k(k+1) \frac{\lambda^k}{k!} e^{-\lambda} + \lambda = \lambda \sum_{k=2}^{\infty} \frac{\lambda^{k-2}}{(k-2)!} e^{-\lambda} + \lambda = \lambda^2 + \lambda$

则 $\text{var}(X) = \lambda$, 即对泊松分布 $E(X) = \text{var}(X) = \lambda$.

· 几何分布 $X \sim \text{Geo}(p)$. $EX = \sum_{j=1}^{\infty} j p q^{j-1} = \sum_{j=0}^{\infty} j p q^{j-1} = p \sum_{j=0}^{\infty} (j+1) q^j$

$$E(X^2) = E(X(X-1)) + E(X) = \sum_{j=1}^{\infty} j(j-1) p q^{j-1} + p = p q \left(\sum_{j=0}^{\infty} q^j \right)' + p$$

$$= p q \left(\frac{1}{1-q} \right)' + p = \frac{p q}{p^2} + p. \text{ 因此 } \text{var}(X) = \frac{q}{p^2}.$$

• 均匀分布 $X \sim U(a, b)$. $E(X^2) = \int_a^b \frac{x^2}{b-a} dx = \frac{b^3 - a^3}{3(b-a)}$ ($a \neq b$)

所以 $\text{var}(X) = \frac{b^3 - a^3}{3(b-a)} - \left(\frac{a+b}{2} \right)^2 = \frac{1}{12}(b-a)^2$.

(转移到Gamma分布的PDF)

• 指数分布 $E(X^2) = \int_0^{\infty} x^2 \lambda e^{-\lambda x} dx = \frac{1}{\lambda^2} \Gamma(3) = \frac{2}{\lambda^2}$, $\text{var}(X) = \frac{1}{\lambda^2}$.

• Gamma分布 $f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}$. $E(X^2) = \int_0^{\infty} \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha+1} e^{-\beta x} dx = \frac{\Gamma(\alpha+2)}{\beta^2 \Gamma(\alpha)}$.

(凑Gamma分布) $E(X^2) = \frac{\alpha(\alpha+1)}{\beta^2}$, $\text{var}(X) = \frac{\alpha(\alpha+1)}{\beta^2} - \left(\frac{\alpha}{\beta} \right)^2 = \frac{\alpha}{\beta^2}$.

• 正态分布 同时利用对称性、分部积分、归一化

$$\text{var}(X) = \int_{-\infty}^{+\infty} (x-\mu)^2 f(x) dx = + \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{+\infty} (x-\mu)^2 \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) dx = \sigma^2 \int_{-\infty}^{+\infty} t^2 \exp\left(-\frac{t^2}{2}\right) dt$$

$$= \sigma^2 \int_{-\infty}^{+\infty} \frac{t^2}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) dt = \sigma^2. \text{ (内部化为标准正态)}$$

• 方差的性质 (由于定义来自期望, 性质也多与期望有关) 设 $EX = \mu$, $\text{var}(X) < \infty$, 则

1° $\text{var}(aX+b) = a^2 \text{var}(X)$, (故缩, = 所期望) $a, b \in \mathbb{R}$

2° $\text{var}(X) = E(X-\mu)^2 \leq E(X-c)^2$, $\forall c \in \mathbb{R}$

3° $\text{var}(X) = 0 \Leftrightarrow X = \mu$. a.s.

4° $X_1, \dots, X_n$ 相互独立, 则 $\text{var}\left(\sum_{k=1}^n X_k\right) = \sum_{k=1}^n \text{var}(X_k)$.

证明4°: $\text{var}(X_1+X_2) = E((X_1+X_2)^2) - (EX_1+EX_2)^2$ $\because X_1, X_2$ 独立, $EX_1+EX_2 = E(X_1+X_2)$

$$= EX_1^2 + 2EX_1X_2 + EX_2^2 - (EX_1)^2 - 2EX_1EX_2 - (EX_2)^2 = \text{var}(X_1) + \text{var}(X_2) + \cancel{E(X_1X_2) - EX_1EX_2}$$

例 信封匹配问题: 记 X_i 表示第 i 封匹配, 共有 n 封信. X 为总的匹配数.

$EX = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} \cdot \sum_{i=1}^n EX_i = 1$ (互相独立)

$\text{var}(X) = E\left(\sum_{i=1}^n X_i\right)^2 - 1 = \sum_{i=1}^n EX_i + \sum_{i \neq j} E(X_i X_j) - 1 = 1 + \frac{n(n-1)}{n(n-1)} - 1 = 1$.

即对于匹配问题, 其期望、方差均为1.

(定义) 若随机变量 X 的期望 $\mu = EX$ 有限, 记 $\text{var}(X) = E(X-\mu)^2$ 为 X 的方差, 记作 σ^2 ,

则称 $\sigma_X = \sqrt{\text{var}(X)}$ 为 X 的标准差 (Standard deviation);

设 $\text{var}(X) < \infty$, 令 $Y = \frac{X-EX}{\sqrt{\text{var}(X)}}$. 则 $EY = 0$, $\text{var}(Y) = 1$. 此时称 Y 是 X 的标准化 (Standardization). 特别地, $X \sim N(\mu, \sigma^2)$ 时 $Y = \frac{X-\mu}{\sigma} \sim N(0, 1)$.

计算公式: $\text{var}(X) = E(X^2) - E^2(X)$.