

第三章 第一节

给定概率空间 (Ω, \mathcal{F}, P) ，设 X 是从 Ω 到实数 \mathbb{R} 的映照，对任何 $a < b$ ，区间 $(a, b]$ 的逆像都属于 \mathcal{F} ，则称 X 是[定义在概率空间 (Ω, \mathcal{F}, P) 上的]随机变量。

这与课本上定义 3.1.1 是一致的，但回避了“博雷尔”这几个字。熟知实数 \mathbb{R} 自带一个 σ 域，就是开集全体生成的最小 σ 域，叫做 Borel 域 \mathcal{B} ，因此映照 X 诱导了 \mathcal{B} 到 \mathcal{F} 的映照，所谓 X 可测就是 \mathcal{B} 中任何一个元素(Borel 集)的逆像都属于 \mathcal{F} 。学完实变函数你会发现要找一个不可测函数还是挺难的，我们平常打交道的函数，你能随口说出的函数，都是可测函数。所以暂时可以不管“可测”这两个字。

给定概率空间 (Ω, \mathcal{F}, P) 和随机变量 X ，对于任意实数 x ， $\{\omega, X(\omega) \leq x\}$ 属于 \mathcal{F} ，定义 $F(x) = P(\{\omega, X(\omega) \leq x\})$ ，称函数 F 为随机变量 X 的分布函数。

请注意这里的定义与课本上定义 3.1.2 相差一个等号。因为经常打交道，不会引起歧义的话可以写的省略一些， $F(x) = P(\omega, X(\omega) \leq x) = P(X \leq x)$ ，

分布函数 F 具有如下性质：1.单调上升，2.左端趋向 0，右端趋向 1，3. 左极右连。
严格的证明用到了概率公理假设中的下连续性 (1.5.14)。由于我们修改了定义，课本上是左极右连。思考题：如果一个函数满足上述三点，一定是某个随机变量的分布函数吗？

我们根据分布函数对随机变量进行分类：

如果 X 只取可列个数值，分布函数是阶梯形的，称 X 是离散型的，

如果分布函数是可微的，则称 X 是连续型的，此时分布函数 F 的导数 f 叫做 X 的（概率）密度函数 (pdf)

当然还有分布函数既不是阶梯形的也不是可微分的，此时称 X 是奇异型的。

显然古典概型诱导的随机变量是离散型的，前面学到的二项分布，伯努利分布，泊松分布，几何分布，帕斯卡分布等等，都是离散型的。

这里有一个小问题，前面在讨论几何概型时，用到了不同概率空间，而这时候不能同时用多个概率空间，更重要的我们希望摆脱实际束缚，找到更多例子，这就要回答前面的思考题。

给定单调函数 F ，左极右连。取 $\Omega = \mathbb{R}$ ， $\mathcal{F} = \text{Borel 域}$ ， X 是从 \mathbb{R} 到 \mathbb{R} 的恒同映照，定义 $P((a, b]) = F(b) - F(a)$ ，然后把 P 的定义延拓到 Borel 域，这样我们构造了一个概率空间及其上的随机变量 X ，其分布函数就是 F 。

这个回答很重要，这说明概率空间并不是本质的，可以随时造一个。这样造出来的概率空间叫做典范的(canonical)，在典范概率空间，随机变量和分布函数一一对应，我们感到舒服多了，因此有时候也混为一谈，譬如离散分布实指离散型随机变量的分布函数。

而且任何一个实轴上的非负函数 f ，如果积分为 1，则 f 就是某个随机变量的概率密度函数。于是我们就有很多连续型随机变量的例子：

均匀分布 $U(a, b)$, 对应几何概型

正态分布 $N(\mu, \sigma^2)$, 又叫做高斯分布, $\mu=0, \sigma=1$ 时, $N(0,1)$ 叫做标准正态分布

指数分布 $\text{Exp}(\lambda)$, 与离散型的几何分布很像, 都具有无记忆性

Gamma 分布 $\Gamma(r, \lambda)$, 只要能记得 Γ -积分

大家应当要记得这几个分布的密度函数, 没有什么道理, 就是我能记得, 所以要求大家记得。

在所有分布中, 正态分布是最重要的, 首先在很多场合出现, 譬如误差的分布, 其次它具有非常优美的性质, 不同的 $N(\mu, \sigma^2)$ 通过线性变换可以转化为 $N(0,1)$, 因此一张正态分布表就可以了 (P133L-3 有误), 最重要的它是各种收敛序列的极限分布。

指数分布的无记忆性很重要, 今后讲马氏过程, 马尔可夫性质, 就依赖这个无记忆性。而且指数分布是唯一具有无记忆性的连续型随机变量。这句话里我们不仅把分布和随机变量混为一谈, 而且用到了典范概率空间。定义在两个不同概率空间上的两个随机变量, 即使它们的分布函数相同, 按照定义, 它们是不同的。但从使用者角度来看, 看不见概率空间, 只能感受到分布函数, 因此谈论唯一性的时候, 限用典范概率空间。

以后我们还可以构造另一个概率空间, 其中 $\Omega=[0,1]$, 与现在所说的典范概率空间是等价的, 也是很常见的。

第二节 随机向量

随机向量是概率空间到 n 维欧氏空间的可测映照, 所谓可测, 就是要求欧式空间的任意开集的逆像都属于概率空间的 σ 域 \mathcal{F} , 如前所述我们还真很难碰到不可测的映照。

显然随机变量是一维随机向量, 也有人把随机变量和随机向量混为一谈。试想若把 n 维欧氏空间换成群, 从概率空间到群的可测映照, 又叫什么?

随机向量还可以看成是定义在同一概率空间的 n 个随机变量。

随机向量也分为离散型和连续型 (还有奇异型), 对于离散型随机向量, 列表是最简单的, 即 $P(X=x_i) = p_i$

对于连续型随机变量, 最常用是其概率密度函数, 首先从分布函数说起, 为简单计, 这里只拿二维随机向量 (X,Y) 举例, 推广到 n 维并非难事。令

$F(x,y) = P(X \leq x, Y \leq y)$, 注意我们这里修改了等号, 对于连续型, 不用太在意边界, 随机向量落在边界的概率为零。 $p(x,y)$ 是 $F(x,y)$ 关于 x 和 y 的二阶偏导数

则 $P(X \leq x, Y \leq y) = F(x,y) = \iint_{-\infty}^{x,y} p(u,v) du dv$

这一等式可以推广到更一般情形

$$P((X,Y) \in A) = \iint_A p(u,v) du dv$$

容易验证这等式对于矩形成立, 然后可以用若干不相交矩形的并来逼近区域, 再次利用概率的连续性。由于这最后一条等式, 对于连续型随机变量, 通常只用密度函数, 很少用分布函数。

任何非负函数，只要积分有限，经过归一化，就可以是一个密度函数，但真正需要记住的只有有限区域上的均匀分布，和高维正态分布(3.2.22)和(4.6.1)，

随机向量的分布函数包含很多信息，可以诱导出边缘（边际）分布，例如

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

对于离散型，就是适当求和。对于连续型，给定密度函数，可以通过积分就出边缘分布的边缘密度函数

$$p_X(x) = \int_{-\infty}^{\infty} p(x, y) dy$$

对于 3 维情形，还可以有 2 维的边缘分布，n 维的分布函数可以诱导出 $2^n - 2$ 个边缘分布，特别是高维正态分布的边缘分布仍是正态的。这些边缘分布之间还有相容性，即边缘分布的边缘分布还是边缘分布。但这些边缘分布并不能决定原来的分布函数。给定若干（相容）的分布函数，构造一个高维分布函数，以这些分布函数为边缘分布？这是一个问题，耦合技术就是来解决这个问题的。

条件分布，对于离散情形，在给定事件 $\{Y=y\} = \{\omega: Y(\omega)=y\}$ 条件下， $P(X \leq x | Y=y) = P(X \leq x, Y=y) / P(Y=y)$ ，其实更常用的是条件概率 $P(X=x | Y=y) = P(X=x, Y=y) / P(Y=y)$ 。

对于连续情形，事件 $\{Y=y\}$ 是零概率，但零概率事件是会发生的，所以要考察

$$P(X \leq x | Y=y) = \lim_{\epsilon \rightarrow 0} P(X \leq x | y - \epsilon \leq Y \leq y + \epsilon)$$

这里的等号=实为定义。

$$P(X \leq x | y - \epsilon \leq Y \leq y + \epsilon) = \frac{P(X \leq x, y - \epsilon \leq Y \leq y + \epsilon)}{P(y - \epsilon \leq Y \leq y + \epsilon)} = \frac{\int_{-\infty}^x \int_{y-\epsilon}^{y+\epsilon} p(u, v) du dv}{\int_{-\infty}^{\infty} \int_{y-\epsilon}^{y+\epsilon} p(u, v) du dv}$$

$$\rightarrow \frac{\int_{-\infty}^x p(u, y) du}{\int_{-\infty}^{\infty} p(u, y) du} = \int_{-\infty}^x \frac{p(u, y)}{\int_{-\infty}^{\infty} p(w, y) dw} du$$

因此把 $p(x, y) / \int_{-\infty}^{\infty} p(u, y) du = p(x, y) / p_Y(y)$ 作为事件 $\{Y=y\}$ 的条件概率密度函数。

作为微积分的练习题，正态分布的条件分布仍是正态的。看看图 3.2.3 就可以

两个随机变量 X 和 Y，如果对于任何实数 x 和 y，事件 $\{\omega: X(\omega) \leq x\}$ 和事件 $\{\omega: Y(\omega) \leq y\}$ 都独立，等价的是， $P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y)$ ，则称随机变量 X 和 Y 相互独立。

若把 X 和 Y 看成是随机向量的两个分量，则上述条件可以写为 $F(x, y) = F_X(x) F_Y(y)$ ，在独立性假设下，边缘分布可以决定联合分布。

独立性条件还可以推出更强的形式，对任意可测集 A 和 B，

$$P(X \in A, Y \in B) = P(X \in A)P(Y \in B)$$

学过实变函数或测度论就知道，这样的推广并不困难，使用起来更方便。

不难把两个随机变量的独立性推广到多个随机变量，对任意 x, y, \dots, z

$$P(X \leq x, Y \leq y, \dots, Z \leq z) = P(X \leq x)P(Y \leq y) \dots P(Z \leq z)$$

则称随机变量 X, Y, ... Z 相互独立。这里 x, y, \dots, z 可取任意实数，也可以是 ∞ ，正因为

如此，这一条等式已经与 2^n 条等式相当。