

第三章 随机变量的数字特征

在前章中,我们较仔细地讨论了随机变量的概率分布,这种分布是随机变量的概率性质最完整的刻画.而随机变量的数字特征,则是某些由随机变量的分布所决定的常数,它刻画了随机变量(或者说,刻画了其分布)的某一方面的性质.

例如,考虑某种大批生产的元件的寿命.如果知道了它的概率分布,就可以知道寿命在任一指定界限内的元件百分率有多少,这对该种元件寿命状况提供了一幅完整的图景.如下文将指出的,根据这一分布就可以算出元件的平均寿命 m , m 这个数虽则不能对寿命状况提供一个完整的刻画,但却在一个重要方面,且往往是人们最为关心的一个方面,刻画了元件寿命的状况,因而在应用上有极重要的意义.类似的情况很多,比如我们在了解某一行业工人的经济状况时,首先关心的恐怕会是其平均收入,这给了我们一个总的印象.至于收入的分布状况,除非为了特殊的研究目的,倒反而不一定是最重要的.

另一类重要的数字特征,是衡量一个随机变量(或其分布)取值的散布程度.例如,两个行业工人的平均收入大体相近,但一个行业中收入分配较平均:大多数人的收入都在平均值上下不远处,其“散布”小;另一个行业则相反:其收入远离平均值者甚多,散布较大,这二者的实际意义当然很不同.又如生产同一产品的两个工厂,各自的产品平均说来都能达到规格要求,但一个厂波动小,较为稳定,另一个厂则波动大,有时质量超标准,有时则低于标准不少,这二者的实际后果当然也不同.

上面论及的平均值和散布度,是刻画随机变量性质的两类最重要的数字特征.对多维变量而言,则还有一类刻画各分量之间的关系数字特征.在本章中,我们将就以上各类数字特征中,举其

最重要者进行讨论.

3.1 数学期望(均值)与中位数

要说明这个名称的来由,让我们回到第一章的例 1.1. 甲乙二人赌技相同,各出赌金 100 元,约定先胜三局者为胜,取得全部 200 元. 现在甲胜 2 局乙胜 1 局的情况下中止,问赌本该如何分? 在那里我们已算出,如果继续赌下去而不中止,则甲有 $\frac{3}{4}$ 的机会(概率)取胜,而乙胜的机会为 $\frac{1}{4}$. 所以,在甲胜 2 局乙胜 1 局这个情况下,甲能“期望”得到的数目,应当确定为

$$200 \times \frac{3}{4} + 0 \times \frac{1}{4} = 150(\text{元})$$

而乙能“期望”得到的数目,则为

$$200 \times \frac{1}{4} + 0 \times \frac{3}{4} = 50(\text{元})$$

如果引进一个随机变量 X , X 等于在上述局面(甲 2 胜乙 1 胜)之下,继续赌下去甲的最终所得,则 X 有两个可能值:200 和 0,其概率分别为 $\frac{3}{4}$ 和 $\frac{1}{4}$. 而甲的期望所得,即 X 的“期望”值,即等于

X 的可能值与其概率之积的累加

这就是“数学期望”(简称期望)这个名词的由来. 这个名词源出赌博,听起来不大通俗化或形象易懂,本不是一个很恰当的命名,但它在概率论中已源远流长获得大家公认,也就站住了脚根. 另一个名词“均值”形象易懂,也很常用,将在下文解释.

3.1.1 数学期望的定义

先考虑一个最简单的情况.

定义 1.1 设随机变量 X 只取有限个可能值 a_1, \dots, a_m . 其概率分布为 $P(X = a_i) = p_i, i = 1, \dots, m$. 则 X 的数学期望,记为 $E(X)^*$ 或 EX , 定义为

* E 是期望 Expectation 的缩写.

$$E(X) = a_1p_1 + a_2p_2 + \cdots + a_m p_m \quad (1.1)$$

名词的来由已如前述. 数学期望也常称为“均值”, 即“随机变量取值的平均值”之意, 当然这个平均, 是指以概率为权的加权平均.

利用概率的统计定义, 容易给均值这个名词一个自然的解释. 假定把试验重复 N 次, 每次把 X 取的值记下来, 设在这 N 次中, 有 N_1 次取 a_1 , N_2 次取 a_2 , \cdots , N_m 次取 a_m . 则这 N 次试验中 X 总共取值为 $a_1N_1 + a_2N_2 + \cdots + a_mN_m$, 而平均每次试验中 X 取值, 记为 \bar{X} , 等于

$$\begin{aligned} \bar{X} &= (a_1N_1 + a_2N_2 + \cdots + a_mN_m)/N \\ &= a_1(N_1/N) + a_2(N_2/N) + \cdots + a_m(N_m/N) \end{aligned}$$

N_i/N 是事件 $\{X = a_i\}$ 在这 n 次试验中的频率. 按概率的统计定义(见第一章, 1.1 节), 当 N 很大时, N_i/N 应很接近 p_i . 因此, \bar{X} 应接近于(1.1)式右边的量, 就是说, X 的数学期望 $E(X)$ 不是别的, 正是在大量次数试验之下, X 在各次试验中取值的平均.

很自然地, 如果 X 为离散型变量, 取无穷个值 a_1, a_2, \cdots , 而概率分布为 $P(X = a_i) = p_i, i = 1, 2, \cdots$, 则我们仿照(1.1), 而把 X 的数学期望 $E(X)$ 定义为级数之和:

$$E(X) = \sum_{i=1}^{\infty} a_i p_i \quad (1.2)$$

但当然, 必须级数收敛才行, 实际上我们要求更多, 要求这个级数绝对收敛:

定义 1.2 如果

$$\sum_{i=1}^{\infty} |a_i| p_i < \infty \quad (1.3)$$

则称(1.2)式右边的级数之和为 X 的数学期望.

为什么不就要求(1.2)右边收敛而必须要求(1.3)? 这就涉及

级数理论中的一个现象:如果某个级数,例如 $\sum_{i=1}^{\infty} a_i p_i$, 只是收敛(称为条件收敛),而其绝对值构成的级数 $\sum_{i=1}^{\infty} |a_i| p_i$, 并不收敛,则将这级数各项次序改排以后,可以使它变得不收敛,或者使它收敛而其和等于事先任意指定之值.这就意味着(1.2)右边的和存在与否,等于多少,与随机变量 X 所取之值的排列次序有关,而 $E(X)$ 作为刻画 X 的某种特性的数值,有其客观意义,不应与其值的人为排列次序有关.

在连续型随机变量的情况,以积分代替求和,而得到数学期望的定义:

定义 1.3 设 X 有概率密度函数 $f(x)$. 如果

$$\int_{-\infty}^{\infty} |x| f(x) dx < \infty \quad (1.4)$$

则称

$$E(X) = \int_{-\infty}^{\infty} x f(x) dx \quad (1.5)$$

为 X 的数学期望.

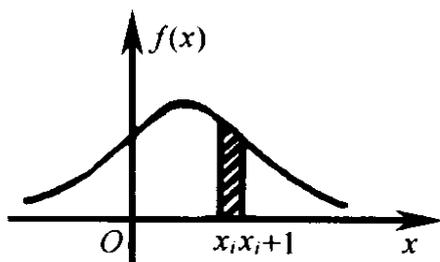


图 3.1

这个定义可以用离散化的方式来加以解释.如图 3.1,在 x 轴上用密集的点列 $\{x_i\}$ 把 x 轴分成很多小区间,长为 $x_{i+1} - x_i = \Delta x_i$.当 X 取值于区间 $[x_i, x_{i+1})$ 内时,可近似地认为其值就是 x_i .按密度函数的定义, X 取上述区间内之值的概率,即图中斜线标出部分的面积,近似地为 $f(x_i) \Delta x_i$.用这个方式,我们把原来的连续型随机变量 X 近似地离散化为一个取无穷个值 $\{x_i\}$ 的离散型变量 X' , X' 的分布为 $P(X' = x_i) \approx f(x_i) \Delta x_i$.按定义 1.2,有

$$E(X') \approx \sum_i x_i f(x_i) \Delta x_i$$

随着区间 Δx_i 愈分愈小, X' 愈来愈接近 X , 而上式右端之和也愈来愈接近于(1.5)式右边的积分, 这样就得出定义 1.3. 至于要求积分绝对收敛即(1.4)式, 其原因与定义 1.2 的情况有所不同, 在此不能细论了.

例 1.1 设 X 服从波哇松分布 $P(\lambda)$ (见第二章例 1.2), 则

$$\begin{aligned} E(X) &= \sum_{i=0}^{\infty} i \frac{\lambda^i}{i!} e^{-\lambda} = \lambda e^{-\lambda} \sum_{i=1}^{\infty} \frac{\lambda^{i-1}}{(i-1)!} \\ &= \lambda e^{-\lambda} \sum_{i=0}^{\infty} \frac{\lambda^i}{i!} = \lambda e^{-\lambda} e^{\lambda} = \lambda \end{aligned} \quad (1.6)$$

这解释了波哇松分布 $P(\lambda)$ 中参数 λ 的意义, 拿第二章例 1.2 的情况来说, λ 就是在所指定的时间段中发生事故的平均次数.

例 1.2 设 X 服从负二项分布(见第二章例 1.5 的(1.11)式), 则

$$E(X) = p^r \sum_{i=0}^{\infty} i \binom{i+r-1}{r-1} (1-p)^i \quad (1.7)$$

为求这个和, 我们要用到在第二章例 1.5 中指出过的负指数二项展开式

$$(1-x)^{-r} = \sum_{i=0}^{\infty} \binom{i+r-1}{r-1} x^i$$

两边对 x 求导, 得

$$r(1-x)^{-r-1} = \sum_{i=0}^{\infty} i \binom{i+r-1}{r-1} x^{i-1}$$

在上式中令 $x=1-p$, 然后两边同乘 $1-p$ 得到

$$\sum_{i=0}^{\infty} i \binom{i+r-1}{r-1} (1-p)^i = rp^{-(r+1)}(1-p)$$

而

$$E(X) = p^r \cdot rp^{-(r+1)}(1-p) = r(1-p)/p \quad (1.8)$$

p 愈小, 则此值愈大, 这是自然的: 若事件 A 的概率 p 很小, 则等待它出现 r 次的平均时间也就愈长, 当 $r=1$ 时, 得到几何分布(第二章(2.12)式)的期望为 $(1-p)/p$.

例 1.3 若 X 服从 $[a, b]$ 区间的均匀分布(第二章例 1.9), 则

$$E(X) = \frac{1}{b-a} \int_a^b x dx = \frac{1}{2}(a+b) \quad (1.9)$$

即期望为区间中点, 这在直观上很显然.

例 1.4 若 X 服从指数分布(第二章例 1.7, (1.20)式), 则

$$E(X) = \lambda \int_0^{\infty} x e^{-\lambda x} dx = \lambda^{-1} \int_0^{\infty} x e^{-x} dx = \lambda^{-1} \Gamma(2) = \lambda^{-1} \quad (1.10)$$

这个结果的直观解释曾在第二章例 1.7 中指出过.

例 1.5 设 X 服从正态分布 $N(\mu, \sigma^2)$, 则

$$E(X) = \frac{1}{\sqrt{2\sigma}} \int_{-\infty}^{\infty} x \exp \frac{(x-\mu)^2}{2\sigma^2} dx$$

作变数代换 $x = \mu + \sigma t$, 化为

$$\begin{aligned} E(X) &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} (\mu + \sigma t) e^{-t^2/2} dt \\ &= \mu \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-t^2/2} dt + \sigma \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} t e^{-t^2/2} dt \end{aligned}$$

上式右边第一项为 μ , 第二项为 0. 因此

$$E(X) = \mu \quad (1.11)$$

这样, 我们得到了正态分布 $N(\mu, \sigma^2)$ 中两个参数之一的 μ 的解释: μ 就是均值, 这一点从直观上看很清楚, 因为 $N(\mu, \sigma^2)$ 的密度函数关于 μ 点对称(见第二章图 2.2b), 其均值自应在这个点.

因为数学期望是由随机变量的分布完全决定的, 故我们可以而且常常说某分布 F 的期望是多少, 某密度 f 的期望是多少等. 期望是通过概率分布而决定这个事实, 可能会被理解为: 在任何应用的场合, 当谈到某变量 X 的期望时, 必须知道其分布, 这话不完全确切. 在有些应用问题中, 人们难于决定有关变量的分布如何, 甚至也难于对之提出某种合理的假定, 但有相当的根据(经验的或理论的)对期望值提出一些假定甚至有不少了解. 例如, 我们可能比较确切地知道某行业工人的平均工资, 而对工资的分布情况并不很清楚. 另外, 当需要通过观察或试验取得数据以进行估计时,

去估计一变量的期望, 要比去估计其分布容易且更确切, 因为期望只是一个数而分布(或密度)是一个函数. 以上所说对其他的数字特征也成立. 在本书后面讲到数理统计学时将更明白这一点.

3.1.2 数学期望的性质

数学期望之所以在理论和应用上都极为重要, 除了它本身的含义(作为变量平均取值之刻画)外, 还有一个原因, 即它具有一些良好的性质, 这些性质使得它在数学上很方便. 本段就是讨论这个问题.

定理 1.1 若干个随机变量之和的期望, 等于各变量的期望之和, 即

$$E(X_1 + X_2 + \cdots + X_n) = E(X_1) + E(X_2) + \cdots + E(X_n) \quad (1.12)$$

当然, 这里要假定各变量 X_i 的期望都存在.

证 先就 $n=2$ 的情况来证, 若 X_1, X_2 为离散型, 分别以 a_1, a_2, \cdots 和 b_1, b_2, \cdots 记 X_1 和 X_2 的一切可能值, 而记其分布为

$$P(X_1 = a_i, X_2 = b_j) = p_{ij}, i, j = 1, 2, \cdots \quad (1.13)$$

当 $X_1 = a_i, X_2 = b_j$ 时, 有 $X_1 + X_2 = a_i + b_j$. 故

$$E(X_1 + X_2) = \sum_{i,j} (a_i + b_j) p_{ij} = \sum_{i,j} a_i p_{ij} + \sum_{i,j} b_j p_{ij}. \quad (1.14)$$

先看第一项, 据第二章(2.8)式, 有

$$P(X_1 = a_i) = \sum_j p_{ij}$$

所以, 按定义 1.2, 有

$$\sum_{i,j} a_i p_{ij} = \sum_i a_i \sum_j p_{ij} = \sum_i a_i P(X_1 = a_i) = E(X_1)$$

同理, (1.14) 右边第二项为 $E(X_2)$. 这证明了所要结果.

若 (X_1, X_2) 为连续型, 以 $f(x_1, x_2)$ 记其联合密度, 按第二章(4.16)式, 知 $X_1 + X_2$ 的密度函数为 $l(y) = \int_{-\infty}^{\infty} f(x, y-x) dx$.

故按定义 1.3, 有

$$\begin{aligned} E(X_1 + X_2) &= \int_{-\infty}^{\infty} y l(y) dy = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y f(x, y-x) dx dy \\ &= \int_{-\infty}^{\infty} \left(\int_{-\infty}^{\infty} y f(x, y-x) dy \right) dx \end{aligned}$$

在里面那个积分作变数代换 $y = x + t$, 得

$$\begin{aligned} E(X_1 + X_2) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x+t) f(x, t) dx dt \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x, t) dx dt + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} t f(x, t) dx dt \end{aligned} \tag{1.15}$$

按第二章(2.9)式, 知 $\int_{-\infty}^{\infty} f(x, t) dt$ 就是 X_1 的密度函数. 所以, (1.15) 右边第一个积分等于

$$\int_{-\infty}^{\infty} x \left(\int_{-\infty}^{\infty} f(x, t) dt \right) dx = \int_{-\infty}^{\infty} x f_1(x) dx = E(X_1)$$

同理证明第二个积分为 $E(X_2)$, 于是证得了所要的结果.

一般情况可用归纳的方式得到. 例如, 记 $Y = X_1 + X_2$, 有

$$\begin{aligned} E(X_1 + X_2 + X_3) &= E(Y + X_3) = E(Y) + E(X_3) \\ &= E(X_1) + E(X_2) + E(X_3) \end{aligned}$$

等等. 定理 1.1 证毕.

定理 1.2 若干个独立随机变量之积的期望, 等于各变量的期望之积:

$$E(X_1 X_2 \cdots X_n) = E(X_1) E(X_2) \cdots E(X_n)$$

当然, 这里也要假定各变量 X_i 的期望都存在.

证 与定理 1.1 相似, 只须对 $n = 2$ 的情况证明即可. 先设 X_1, X_2 都为离散型, 其分布为 (1.13). 由独立性假定知 $p_{ij} = P(X_1 = a_i) P(X_2 = b_j)$.

因为当 $X_1 = a_i, X_2 = b_j$ 时有 $X_1 X_2 = a_i b_j$, 故

$$\begin{aligned}
E(X_1 X_2) &= \sum_{i,j} a_i b_j p_{ij} = \sum_{i,j} a_i b_j P(X_1 = a_i) P(X_2 = b_j) \\
&= \sum_i a_i P(X_1 = a_i) \sum_j b_j P(X_2 = b_j) \\
&= E(X_1) E(X_2)
\end{aligned}$$

如所欲证. 若 (X_1, X_2) 为连续型, 则因独立性, 其联合密度 $f(x_1, x_2)$ 等于各分量密度 $f_1(x_1)$ 与 $f_2(x_2)$ 之积, 故

$$\begin{aligned}
E(X_1 X_2) &= \iint_{-\infty}^{\infty} x_1 x_2 f(x_1, x_2) dx_1 dx_2 \\
&= \int_{-\infty}^{\infty} x_1 f_1(x_1) dx_1 \int_{-\infty}^{\infty} x_2 f_2(x_2) dx_2 \\
&= E(X_1) E(X_2)
\end{aligned}$$

细心的读者可能会注意到, 在后一段证明中我们是从公式

$$E(X_1 X_2) = \iint_{-\infty}^{\infty} x_1 x_2 f(x_1, x_2) dx_1 dx_2 \quad (1.16)$$

出发, 而这公式并非直接从期望的定义而来, 它也需要证明. 因此, 更严格的证法应如定理 1.1 那样, 先推导出 $X_1 X_2$ 的密度 g , 计算 $\int_{-\infty}^{\infty} xg(x)dx$ 再通过积分变数代换. 这不难做到, 我们把它放在习题里留给读者去完成(习题 21).

读者也许还会问: 在以上两个定理中, 如果一部分变量为离散型, 一部分为连续型, 结果如何? 答案是结论仍成立. 对乘积的情况, 由于有独立假定, 证明不难. 对和的情况则要用到高等概率论, 这些都不在此细讲了.

要注意到定理 1.2 和 1.1 之间的区别: 后者不要求变量有独立性. 读者也可以思考一下这个问题: 如果说, 事件积的概率的定理(第一章定理 3.3)与此处定理 1.2 完全对应, 那么, 为什么事件和概率的定理(第一章定理 3.1)与此处的定理 1.1 并不完全对应(概率加法定理中有互斥要求而定理 1.1 无任何要求), 道理何在?

定理 1.3(随机变量函数的期望) 设随机变量 X 为离散型,

有分布 $P(X = a_i) = p_i, i = 1, 2, \dots$, 或者为连续型, 有概率密度函数 $f(x)$. 则

$$E(g(X)) = \sum_i g(a_i) p_i \left(\text{当 } \sum_i |g(a_i)| p_i < \infty \text{ 时} \right) \quad (1.17)$$

或

$$E(g(X)) = \int_{-\infty}^{\infty} g(x) f(x) dx \left(\text{当 } \int_{-\infty}^{\infty} |g(x)| f(x) dx < \infty \text{ 时} \right) \quad (1.18)$$

这个定理的实质在于: 为了计算 X 的某一函数 $g(X)$ 的期望, 并不需要先算出 $g(X)$ 的密度函数, 而可以就从 X 的分布出发, 这当然大大方便了计算, 因为在 g 较为复杂时, $g(X)$ 的密度很难求.

证 离散型情况(1.17)好证, 因为 $P(X = a_i) = p_i$, 有 $P(g(X) = g(a_i)) = p_i$ ($g(a_1), g(a_2), \dots$ 中可以有相重的, 但这并不影响下面的证明). 由此立即得出(1.17).

连续型情况较复杂, 我们只能就 g 为严格上升并可导的情况给出证明. 按第二章(4.2)式, 这时 $Y = g(X)$ 的密度函数为 $f(h(y))h'(y)$, 其中 h 为 g 的反函数, 即 $h(g(x)) = x$. 此式两边对 x 求导, 得 $h'(y)|_{y=g(x)} g'(x) = 1$, 即 $h'(g(x)) = 1/g'(x)$. 因此

$$E(g(X)) = \int_{-\infty}^{\infty} y f(h(y)) h'(y) dy$$

作积分变数代换 $y = g(x)$, 注意到 $f(h(g(x))) = f(x)$, $h'(g(x)) = 1/g'(x)$ 及 $dy = g'(x) dx$, 得

$$E(g(X)) = \int_{-\infty}^{\infty} g(x) f(x) dx$$

即(1.18). 一般情况(g 非单调)的证明超出本书范围之外, 但对有些简单情况, $g(X)$ 虽非单调, 但 $g(X)$ 的密度不难求得, 这时(1.18)也不难证. 有几种这样的情况作为习题留给读者.

本定理的一个重要特例是

系 1.1 若 c 为常数, 则

$$E(cX) = cE(X) \quad (1.19)$$

证明由取 $g(x) = cx$ 得出. 当然, 直接证明也很容易.

这几个定理无论在理论上和实用上都有重大意义, 这里我们举几个例子说明其应用.

例 1.6 设 X 服从二项分布 $B(n, p)$, 求 $E(X)$.

此例不难由定义 1.1 直接计算, 但如下考虑更简单: 因 X 为 n 次独立试验中某事件 A 发生的次数, 且在每次试验中 A 发生的概率为 p . 故如引进随机变量 X_1, \dots, X_n , 其中

$$X_i = \begin{cases} 1, & \text{若在第 } i \text{ 次试验时事件 } A \text{ 发生} \\ 0, & \text{若在第 } i \text{ 次试验时事件 } A \text{ 不发生} \end{cases} \quad (1.20)$$

则 X_1, \dots, X_n 独立, 且

$$X = X_1 + \dots + X_n \quad (1.21)$$

按定理 1.1 有, $E(X) = E(X_1) + \dots + E(X_n)$. 为计算 $E(X_i)$, 注意按定义(1.20), X_i 只取两个值 1 和 0, 其取 1 的概率为 p , 取 0 的概率为 $1 - p$. 因而 $E(X_i) = 1 \times p + 0 \times (1 - p) = p$. 由此得到

$$E(X) = np \quad (1.22)$$

这比直接计算要简单些, 又注意: 在上述论证中并未用到 X_1, \dots, X_n 独立这一事实.

例 1.7 再考虑第一章例 2.2 那个“ n 双鞋随机地分成 n 堆”的试验, 以 X 记“恰好成一双”的那种堆的数目, 求 $E(X)$.

此题若要直接用定义 1.1, 就须计算 $P(X = i)$, 即“恰好有 i 个堆各自成一双”的概率. 这个概率计算不易, 但使用上例的方法不难求解: 引进随机变量 X_1, \dots, X_n , 其中

$$X_i = \begin{cases} 1, & \text{若第 } i \text{ 堆的两只恰成一双} \\ 0, & \text{若第 } i \text{ 堆的两只不成一双} \end{cases}$$

则仍有 $X = X_1 + \dots + X_n$, 且 $E(X_i) = P(X_i = 1) = P(\text{第 } i \text{ 堆恰成一双})$. 为算这个概率, 我们取如下的分堆方法: 先把 $2n$ 只鞋随机地自左至右排成一列, 然后让排在 1, 2 位置的成一堆, 3, 4 位置的为第二堆, 等等. 总的排列方法有 $(2n)!$ 种. 有利于事件{第 i 堆恰成一双}的排法可计算如下: 第 i 堆占据排列中的第 $(2i - 1)$ 和

第 $2i$ 号位置. 第 $(2i-1)$ 号位置可以从 $2n$ 只鞋中任取一只, 有 $2n$ 种取法. 这只定了以后, 为使恰成一双, 第 $2i$ 号位置就只有一种取法. 取好后, 剩下的 $2n-2$ 只则可任意排, 有 $(2n-2)!$ 种排法. 因此, 有利于上述事件的总排列数为 $2n \cdot 1 \cdot (2n-2)!$, 而所求的概率为

$$2n(2n-2)!/(2n)! = 1/(2n-1)$$

此即为 $E(X_i)$, 而 $E(X) = E(X_1) + \cdots + E(X_n) = n/(2n-1)$

例 1.8 试计算“统计三大分布”的期望值.

对自由度 n 的卡方分布, 直接用其密度函数的形式(第二章(4.26)), Γ 函数的公式(第二章(4.23))及数学期望的定义 1.3, 不难算出其期望为 n . 略简单一些是用第二章例 4.9, 把 X 表为 $X_1^2 + \cdots + X_n^2$, X_1, \cdots, X_n 独立且各服从标准正态分布 $N(0, 1)$. 按定理 1.3, 有

$$E(X_i^2) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^2 e^{-x^2/2} dx = \frac{2}{\sqrt{2\pi}} \int_0^{\infty} e^{-x^2/2} x^2 dx$$

把 $e^{-x^2/2} x^2 dx$ 写为 $-x d(e^{-x^2/2})$, 用分部积分, 得到

$$\int_0^{\infty} e^{-x^2/2} x^2 dx = \int_0^{\infty} e^{-x^2/2} dx = \frac{1}{2} \int_{-\infty}^{\infty} e^{-x^2/2} dx = \sqrt{2\pi}/2$$

后一式用第二章(1.15). 于是得到 $E(X_i^2) = 1$, 而 $E(X) = E(X_1^2) + \cdots + E(X_n^2) = n$.

对自由度 n 的 t 分布, 由于其密度函数(第二章(4.31)式)关于 0 对称, 易见其期望为 0. 但是有一个条件, 就是自由度 n 必须大于 1. 这是因为

$$\int_{-\infty}^{\infty} |x| (1 + x^2/n)^{-\frac{n+1}{2}} dx = \infty \text{ 当 } n = 1$$

因而条件(1.4)不适合, 当 $n > 1$ 时上式的积分有限.

对自由度为 m, n 的 F 分布, 写

$$X = \frac{1}{m} X_2 / \frac{1}{n} X_1 = m^{-1} n X_2 / X_1$$

其中 X_1, X_2 独立, 分别服从分布 χ_n^2 和 χ_m^2 . 由于 X_1, X_2 独立, 按

第二章定理 3.3, 知 X_1^{-1} 和 X_2 也独立, 故按定理 1.2, 有

$$E(X) = m^{-1}nE(X_2)E(X_1^{-1}) = m^{-1}nmE(X_1^{-1}) = nE(X_1^{-1}) \quad (1.23)$$

于是问题归结为计算 $E(X_1^{-1})$. 按定理 1.3, 有

$$\begin{aligned} E(X_1^{-1}) &= \left(2^{n/2}\Gamma\left(\frac{n}{2}\right)\right)^{-1} \int_0^{\infty} x^{-1}e^{-x/2}x^{n/2-1}dx \\ &= \left(2^{n/2}\Gamma\left(\frac{n}{2}\right)\right)^{-1} \int_0^{\infty} e^{-x/2}x^{(n-2)/2-1}dx \\ &= \left(2^{n/2}\Gamma\left(\frac{n}{2}\right)\right)^{-1} 2^{(n-2)/2}\Gamma\left(\frac{n}{2}-1\right) \\ &= \frac{1}{2}\Gamma\left(\frac{n}{2}-1\right) / \Gamma\left(\frac{n}{2}\right) \\ &= \frac{1}{2}\Gamma\left(\frac{n}{2}-1\right) / \left[\left(\frac{n}{2}-1\right)\Gamma\left(\frac{n}{2}-1\right)\right] \\ &= 1/(n-2) \end{aligned}$$

由此及(1.23), 知

$$E(X) = n/(n-2) \quad (X \sim F_{m,n}) \quad (1.24)$$

此式只在 $n > 2$ 时才有效. 当 $n = 1, 2$ 时, $F_{m,n}$ 的期望不存在.

3.1.3 条件数学期望(条件均值)

与条件分布的定义相似, 随机变量 Y 的条件数学期望, 就是它在给定的某种附加条件之下的数学期望. 对统计学来说, 最重要的情况是: 在给定了某些其他随机变量 X, Z, \dots 等的值 x, z, \dots 等的条件之下, Y 的条件期望, 记为 $E(Y|X=x, Z=z, \dots)$. 以只有一个变量 X 为例, 就是 $E(Y|X=x)$. 在 X 已明确而不致引起误解的情况下, 也可简记为 $E(Y|x)$.

如果知道了 (X, Y) 的联合密度, 则 $E(Y|x)$ 的定义就可以具体化为: 先定出在给定 $X=x$ 之下, Y 的条件密度函数 $f(y|x)$, 然后按定义 1.3 算出

$$E(Y|x) = \int_{-\infty}^{\infty} yf(y|x)dy \quad (1.25)$$

如果说,条件分布是变量 X 与 Y 的相依关系在概率上的完全刻画,那么,条件期望则在一个很重要的方面刻画了二者的关系,它反映了随着 X 取值 x 的变化, Y 的平均变化的情况如何,而这常常是研究者所关心的主要内容.例如,随着人的身高 x 的变化,具身高 x 的那些人的平均体重的变化情况如何;随着其受教育年数 x 的变化,其平均收入的变化如何等等.在统计学上,常把条件期望 $E(Y|x)$ 作为 x 的函数称为 Y 对 X 的“回归函数”(回归这个名词将在第六章中解释),而“回归分析”,即关于回归函数的统计研究,构成统计学的一个重要分支.

例 1.9 条件期望的一个最重要的例子是 (X, Y) 服从二维正态分布 $N(a, b, \sigma_1^2, \sigma_2^2, \rho)$. 根据第二章例 3.3, 在给定 $X = x$ 时 Y 的条件分布为正态分布 $N(b + \rho\sigma_2\sigma_1^{-1}(x - a), \sigma_2^2(1 - \rho^2))$. 因为正态分布 $N(\mu, \sigma^2)$ 的期望就是 μ , 故有

$$E(Y|x) = b + \rho\sigma_2\sigma_1^{-1}(x - a) \quad (1.26)$$

它是 x 的线性函数. 如果 $\rho > 0$, 则 $E(Y|x)$ 随 x 增加而增加, 即 Y “平均说来”有随 X 的增长而增长的趋势, 这就是我们以前提到的“正相关”的解释. 若 $\rho < 0$, 则为负相关, 当 $\rho = 0$ 时, X 与 Y 独立, $E(Y|x)$ 当然与 x 无关.

从条件数学期望的概念, 可得出求通常的(无条件的)数学期望的一个重要公式. 这个公式与计算概率的全概率公式相当. 回想全概率公式 $P(A) = \sum_i P(B_i)P(A|B_i)$. 它可以理解为通过事件 A 的条件概率 $P(A|B_i)$ 去计算其(无条件)概率 $P(A)$. 更确定地说, $P(A)$ 就是条件概率 $P(A|B_i)$ 的某种加权平均, 权即为事件 B_i 的概率. 以此类推, 变量 Y 的(无条件)期望, 应等于其条件期望 $E(Y|x)$ 对 x 取加权平均, x 的权与变量 X 在 x 点的概率密度 $f_1(x)$ 成比例, 即

$$E(Y) = \int_{-\infty}^{\infty} E(Y|x)f_1(x)dx \quad (1.27)$$

此式很容易证明: 以 $f(x, y)$ 记 (X, Y) 的联合密度函数, 则 X, Y 的(边缘)密度函数分别为

$$f_1(x) = \int_{-\infty}^{\infty} f(x, y) dy \text{ 和 } f_2(y) = \int_{-\infty}^{\infty} f(x, y) dx$$

按定义, $E(Y) = \int_{-\infty}^{\infty} y f_2(y) dy$, 可写为

$$\begin{aligned} E(Y) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y f(x, y) dx dy \\ &= \int_{-\infty}^{\infty} \left[\int_{-\infty}^{\infty} y f(x, y) dy \right] dx \end{aligned}$$

由于 $E(Y|x) = \int_{-\infty}^{\infty} y f(x, y) dy / f_1(x)$, 有 $\int_{-\infty}^{\infty} y f(x, y) dy = E(Y|x) f_1(x)$, 而上式转化为(1.27).

公式(1.27)可给以另一种写法, 记 $g(x) = E(Y|x)$, 它是 x 的函数, 则(1.27)成为

$$E(Y) = \int_{-\infty}^{\infty} g(x) f_1(x) dx \quad (1.28)$$

但据(1.18), 上式右边就是 $E(g(X))$. 从 $g(x)$ 的定义, $g(X)$ 是 $E(Y|x)|_{x=X}$, 可简写为 $E(Y|X)$. 于是由(1.28)得

$$E(Y) = E[E(Y|X)] \quad (1.29)$$

这个公式可以形象地叙述为: 一个变量 Y 的期望, 等于其条件期望的期望. $E(Y|X)$ 这个符号的意义, 从上面的叙述中已明确交代了, 只须记住: 在求 $E(Y|X)$ 时, 先设定 X 等于一固定值 x , x 无随机性, 这样可算出 $E(Y|x)$, 其表达式含 x , 再把 x 换成 X 即得.

公式(1.29)虽可算是概率论中一个比较高深的公式, 它的实际含义其实很简单: 它可理解为一个“分两步走”去计算期望的方法. 因为在不少情况下, 迳直计算 $E(Y)$ 较难, 而在限定某变量 X 之值后, 计算条件期望 $E(Y|x)$ 则较容易. 因此我们分两步走: 第一步算出 $E(Y|x)$, 再借助 X 的概率分布, 通过 $E(Y|x)$ 算出 $E(Y)$. 更直观一些, 你可以把求 $E(Y)$ 看成为在一个很大的范围求平均. 限定 X 之值从这个很大的范围内界定了一个较小的部分. 先对这较小的部分求平均, 然后再对后者求平均. 比如要求全

校学生的平均身高,你可以先求出每个班的学生的平均身高,然后再对各班的平均值求一次平均.自然,在作后一平均时,要考虑到各班人数的不同,是以各班人数为权的加权平均.这个权的作用相当于公式(1.27)中的 $f_1(x)$.

公式(1.29)虽来自(1.27),但因为其形式并不要求对 X, Y 有特殊的假设,故可适用于更为一般的情形.例如, X 不必是一维的,如果 X 为 n 维随机向量 (X_1, \dots, X_n) , 有概率密度 $f(x_1, \dots, x_n)$, 则公式(1.29)有形式

$$E(Y) = \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} E(Y|x_1, \dots, x_n) f(x_1, \dots, x_n) dx_1 \cdots dx_n \quad (1.30)$$

这里 $E(Y|x_1, \dots, x_n)$ 就是在 $X_1 = x_1, \dots, X_n = x_n$ 的条件下, Y 的条件期望,又 X, Y 都可以是离散型的.例如,设 X 为一维离散型变量,有分布

$$P(X = a_i) = p_i, \quad i = 1, 2, \dots$$

则公式(1.29)有形式

$$E(Y) = \sum_{i=1}^{\infty} p_i E(Y|a_i) \quad (1.31)$$

3.1.4 中位数

刻画一个随机变量 X 的平均取值的数学特征,除了数学期望以外,最重要的是中位数.

定义 1.4 设连续型随机变量 X 的分布函数为 $F(x)$, 则满足条件

$$P(X \leq m) = F(m) = 1/2 \quad (1.32)$$

的数 m 称为 X 或分布 F 的中位数.

由于连续型变量取一个值的概率为 0, $P(X = m) = 0$, 由(1.32)知

$P(X \leq m) = P(X < m) = P(X > m) = P(X \geq m) = 1/2$
就是说, m 这个点把 X 的分布从概率上一切两半:在 m 左边(包

括点 m 与否无所谓)占一半, m 右边也占一半,从概率上说, m 这个点正好居于中央,这就是“中位数”得名的由来.

在实用上,中位数用得很多,特别有不少社会统计资料,常拿中位数来刻画某种量的代表性数值,有时它比数学期望更说明问题.例如,某社区内人的收入的中位数告诉我们:有一半的人收入低于此值,另一半高于此值.我们直观上感觉到这个值对该社区的收入情况,的确很具代表性.它和期望值相比它的一个优点是:它受个别特大或特小值的影响很小,而期望则不然.举例而言,若该社区中有一人收入在百万元以上,则该社区的均值可能很高,而绝大多数人并不富裕,这个均值并不很有代表性.中位数则不然:它不受少量这种特大值的影响.

从理论上说,中位数与均值相比还有一个优点,即它总存在,而均值则不是对任何随机变量都存在.

虽则中位数有这些优点,但在概率统计中,无论在理论和应用上,数学期望的重要性都超过中位数,其原因有以下两方面:

一是均值具有很多优良的性质,反映在前面的定理 1.1—1.3. 这些性质使得在数学上处理均值很方便.例如, $E(X_1 + X_2) = E(X_1) + E(X_2)$, 这公式既简单又毫无条件(除了均值存在以外).中位数则不然: $X_1 + X_2$ 的中位数,与 X_1, X_2 各自的中位数之间,不存在简单的联系,这使中位数在数学上的处理很复杂且不方便.

二是中位数本身所固有的某些缺点.首先,中位数可以不唯一.例如,考察图 3.2 的密度函数 f . 它只在两个分开的区间 (a, b) 和 (c, d) 内不为 0,且在这两段区间上围成的面积都是 $1/2$. 这时,按中位数的定义 1.4, 区间 $[b, c]$ 中任何一点 m 都是中位数. 它没有一个唯一的值.

次一个问题是:在 X 为离散型的情况,虽也可以定义中位数(其定义与定义 1.4 有所不同),但并不很理想,不完全符合“中位”这名词所应有的含义.考察一个简单例子,设 X 取三个值 1, 2, 3, 概率分布为

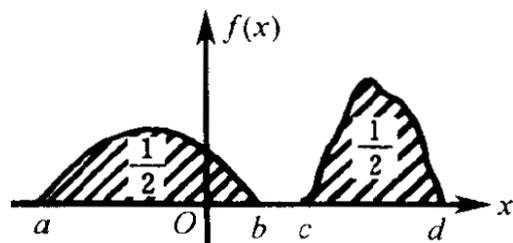


图 3.2

$$P(X = 1) = 2/7, P(X = 2) = 4/7, P(X = 3) = 1/7$$

这时就不存在一个点 m , 使 m 两边的概率恰好一样, 不得已只好退而求其次: 找一个点 m , 使其左右两边的概率差距最小, 在本例中这个点是 2. 从 2 这个位置看, 左边的概率 ($2/7$) 要比右边的概率 ($1/7$) 大. 故并不是理想的“中位”数.

例 1.10 正态分布 $N(\mu, \sigma^2)$ 的中位数就是 μ , 这从 $N(\mu, \sigma^2)$ 的密度函数关于 μ 点对称可以看出. 指数分布函数已在第二章 (1.21) 式中列出, 故其中位数 m 为方程 $1 - e^{-\lambda m} = 1/2$ 的解, 即 $m = (\log 2) / \lambda$ (本书中, \log 都是以 e 为底).