

## 3.2 方差与矩

### 3.2.1 方差和标准差

现在我们转到本章开始时提到的另一类数字特征,即刻画随机变量在其中心位置附近散布程度的数字特征,其中最重要的是方差.

设随机变量  $X$  有均值  $a = E(X)$ . 试验中,  $X$  取的值当然不一定恰好是  $a$ , 而会有所偏离. 偏离的量  $X - a$  本身也是随机的(因为  $X$  是随机的). 我们要取这个偏离  $X - a$  的某种有代表性的数字, 来刻画这偏离即散布的程度大小如何. 我们不能就取  $X - a$  的均值, 因为  $E(X - a) = E(X) - a = 0$ ——正负偏离彼此抵消了. 一种解决办法是取  $X - a$  的绝对值  $|X - a|$  以消除符号, 再取其

均值  $E|X - a|$ , 作为变量  $X$  取值的散布程度的数字特征. 这个量  $E|X - a|$  叫做  $X$  (或其分布) 的“平均绝对差”, 是常用于刻画散布度的数字特征之一. 但是, 由于绝对值在数学上处理甚不方便, 人们就考虑了另一种作法: 先把  $(X - a)$  平方以消去符号, 然后取其均值得  $E(X - a)^2$ , 把它作为  $X$  取值散布度的衡量. 这个量就叫做  $X$  的“方差”(方差: “差”的“方”).

**定义 2.1** 设  $X$  为随机变量, 分布为  $F$ , 则

$$\text{Var}(X) = E(X - EX)^2 \quad (2.1)$$

称为  $X$  (或分布  $F$ ) 的方差\*, 其平方根  $\sqrt{\text{Var}(X)}$  (取正值) 称为  $X$  (或分布  $F$ ) 的标准差.

暂记  $EX = a$ . 由于  $(X - a)^2 = X^2 - 2aX + a^2$ , 按定理 1.1 得

$$\begin{aligned} \text{Var}(X) &= E(X^2) - 2aE(X) + a^2 \\ &= E(X^2) - (EX)^2 \end{aligned} \quad (2.2)$$

方差的这个形式在计算上往往较为方便.

方差之所以成为刻画散布度的最重要的数字特征, 原因之一是它具有一些优良的数字性质, 反映在以下的几个定理中.

**定理 2.1** 1° 常数的方差为 0. 2° 若  $C$  为常数, 则  $\text{Var}(X + C) = \text{Var}(X)$ . 3° 若  $C$  为常数, 则  $\text{Var}(CX) = C^2\text{Var}(X)$ .

**证** 1° 若  $X =$  常数  $a$ , 则  $E(X) = a$ , 故  $X - E(X) = 0$ , 因而  $\text{Var}(X) = 0$ .

2° 因为  $E(X + C) = E(X) + C$ , 故

$$\begin{aligned} \text{Var}(X + C) &= E[(X + C) - (EX + C)]^2 = E[X - EX]^2 \\ &= \text{Var}(X) \end{aligned}$$

3° 因  $C$  为常数, 有  $E(CX) = CE(X)$ . 故

$$\begin{aligned} \text{Var}(CX) &= E[CX - CE(X)]^2 = C^2E(X - EX)^2 \\ &= C^2\text{Var}(X) \end{aligned}$$

**定理 2.2** 独立随机变量之和的方差, 等于各变量的方差之和:

---

\*  $\text{Var}$  是方差 Variance 的缩写.

$$\text{Var}(X_1 + \cdots + X_n) = \text{Var}(X_1) + \cdots + \text{Var}(X_n) \quad (2.3)$$

证 记  $E(X_i) = a_i, i = 1, \cdots, n$ , 则因  $E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n a_i$ , 有

$$\begin{aligned} \text{Var}(X_1 + \cdots + X_n) &= E\left[\sum_{i=1}^n X_i - \sum_{i=1}^n a_i\right]^2 = E\left[\sum_{i=1}^n (X_i - a_i)\right]^2 \\ &= \sum_{i,j=1}^n E[(X_i - a_i)(X_j - a_j)] \end{aligned} \quad (2.4)$$

有两类项: 一类是  $i, j$  相同, 这类项, 按方差的定义, 即为  $\text{Var}(X_i)$ . 另一类项是  $i, j$  不同. 这时, 因  $X_i, X_j$  独立, 按定理 1.2 有  $E(X_i X_j) = E(X_i)E(X_j) = a_i a_j$ . 所以

$$\begin{aligned} E[(X_i - a_i)(X_j - a_j)] &= E(X_i X_j) - E(a_i X_j) - E(a_j X_i) + a_i a_j \\ &= a_i a_j - a_i a_j - a_i a_j + a_i a_j = 0 \end{aligned}$$

这样, 在(2.4)式最后一个和中, 只剩下  $i = j$  的那些项. 这些项之和即(2.3)式右边. 因而证明了本定理.

这个定理是方差的一个极重要的性质, 它与均值的定理 1.1 相似. 但要注意的是: 方差的定理要求各变量独立, 而均值的定理则不要求.

**例 2.1** 设  $X$  为一随机变量,  $E(X) = a$  而  $\text{Var}(X) = \sigma^2$ . 记  $Y = (X - a)/\sigma$ , 则  $E(Y) = 0$ , 且按定理 2.1 易知  $\text{Var}(Y) = 1$ . 这样, 对  $X$  作一线性变换后, 得到一个具均值 0、方差 1 的变量  $Y$ . 常称  $Y$  是  $X$  的“标准化”.

**例 2.2** 设  $X$  服从波哇松分布  $P(\lambda)$ . 求其方差. 前已求出  $E(X) = \lambda$ . 又据定理 1.3, 知

$$E(X^2) = \sum_{i=0}^{\infty} i^2 e^{-\lambda} \lambda^i / i!$$

把  $i^2$  写为  $i(i-1) + i$ , 注意到  $\sum_{i=0}^{\infty} i e^{-\lambda} \lambda^i / i!$  就是  $X$  的均值, 即  $\lambda$ , 而  $i(i-1)/i! = 1/(i-2)!$ , 有

$$\begin{aligned}
E(X^2) &= \sum_{i=2}^{\infty} e^{-\lambda} \lambda^i / (i-2)! + \lambda \\
&= \lambda^2 \sum_{i=2}^{\infty} e^{-\lambda} \lambda^{i-2} / (i-2)! + \lambda \\
&= \lambda^2 e^{-\lambda} \sum_{j=0}^{\infty} \lambda^j / j! + \lambda = \lambda^2 e^{-\lambda} e^{\lambda} + \lambda = \lambda^2 + \lambda
\end{aligned}$$

于是按公式(2.2)得到  $\text{Var}(X) = \lambda^2 + \lambda - \lambda^2 = \lambda$ . 即波哇松分布  $P(\lambda)$  的均值方差相同, 都等于其参数  $\lambda$ .

**例 2.3** 设  $X$  服从二项分布  $B(n, p)$ , 求  $\text{Var}(X)$ .

把  $X$  表为(1.21)的形式, 其中  $X_i$  由(1.20)定义, 因为  $X_1, \dots, X_n$  独立, 有  $\text{Var}(X) = \text{Var}(X_1) + \dots + \text{Var}(X_n)$ . 现计算  $\text{Var}(X_i)$ . 因  $X_i$  只取 1, 0 两个值, 概率分别为  $p$  和  $1-p$ , 故

$$E(X_i) = p, E(X_i^2) = p, i = 1, \dots, n$$

因而得到  $\text{Var}(X_i) = p - p^2 = p(1-p)$ , 而

$$\text{Var}(X) = np(1-p) \quad (2.5)$$

本题也可由定义直接计算, 但比这麻烦些.

**例 2.4** 再考察例 1.7, 求该例中变量  $X$  的方差.

仍如该例把  $X$  表为  $X_1 + \dots + X_n$ . 麻烦的是, 这里  $X_1, \dots, X_n$  并非独立, 因而不能用定理 2.2. 但这种表示仍可简化计算, 有

$$E(X^2) = E\left(\sum_{i=1}^n X_i\right)^2 = \sum_{i,j=1}^n E(X_i X_j) \quad (2.6)$$

分两类项: 一类是  $i=j$ . 这类项之和为  $\sum_{i=1}^n E(X_i^2)$ . 由于  $X_i$  只取 1, 0 两值, 故  $X_i^2 = X_i$ , 因而

$$\sum_{i=1}^n E(X_i^2) = \sum_{i=1}^n E(X_i) = E(X) = n/(2n-1)$$

(见例 1.7)

对  $i \neq j$ , 取  $i=1, j=2$  为例, 其他  $i, j$  一样, 因为  $X_i, X_j$  都只取 1, 0 为值, 有

$$E(X_1 X_2) = P(X_1 = 1, X_2 = 1)$$

即“第 1, 2 堆都恰成一双”的概率. 这概率计算的思想, 与例 1.7 中阐明过的完全一样, 结果为

$$P(X_1 = 1, X_2 = 1) = 2n \cdot 1 \cdot (2n - 2) \cdot 1 \cdot (2n - 4)! / (2n)! \\ = 1 / [(2n - 1)(2n - 3)]$$

又在和(2.6)中,  $i \neq j$  的项的个数为  $n(n - 1)$ , 故第二类项 ( $i \neq j$  的项) 之和为  $n(n - 1) / [(2n - 1)(2n - 3)]$ . 由此, 用公式(2.2), 得

$$\begin{aligned} \text{Var}(X) &= E(X^2) - (EX)^2 \\ &= n / (2n - 1) + n(n - 1) / [(2n - 1)(2n - 3)] \\ &\quad - [n / (2n - 1)]^2 = 4n(n - 1)^2 / [(2n - 1)^2(2n - 3)] \end{aligned}$$

**例 2.5** 设  $X$  服从正态分布  $N(\mu, \sigma^2)$ . 注意到  $E(X) = \mu$ , 有

$$\text{Var}(X) = E(X - \mu)^2 = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} (x - \mu)^2 e^{-(x - \mu)^2 / 2\sigma^2} dx$$

作变数代换  $x = \mu + \sigma t$ , 得

$$\text{Var}(X) = \sigma^2 \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} t^2 e^{-t^2/2} dt$$

式中的积分已在例 1.8 中计算过, 为  $\sqrt{2\pi}$ . 所以

$$\text{Var}(X) = \sigma^2 \quad (2.7)$$

由此得到正态分布  $N(\mu, \sigma^2)$  中另一参数  $\sigma^2$  的解释: 它就是分布的方差. 正态分布完全由其均值  $\mu$  和方差  $\sigma^2$  决定, 故也常说“均值为  $\mu$  方差为  $\sigma^2$  的正态分布”. 经过标准化  $Y = (X - \mu) / \sigma$ , 按例 2.1 得出均值为 0 方差为 1 的正态分布, 即标准正态分布. 这一点早在第二章例 1.6 中, 通过直接计算分布的方法证明过(第二章(1.17)式).




图 3.3

方差  $\sigma^2$  愈小, 则  $X$  的取值以更大的概率集中在其均值  $\mu$  附近, 这一点也可从如下看出: 正态分布  $N(\mu, \sigma^2)$  的密度函数在  $x = \mu$  点之值, 等于  $(\sqrt{2\pi}\sigma)^{-1}$ . 它与  $\sigma$  成反比:  $\sigma$  愈小, 这个值愈大, 而密度在  $\mu$  点处有一个更

高的峰,显示概率更多地集中在  $\mu$  点附近,见图 3.3. 其中画出了正态  $N(\mu, \sigma^2)$  当  $\sigma^2=1$  和  $\sigma^2=1/4$  时密度函数的图形.

**例 2.6** 指数分布(第二章例 1.7)的方差为  $1/\lambda^2$ . 区间  $[a, b]$  上的均匀分布(第二章例 1.9)的方差为  $(b-a)^2/12$ . 这些都容易直接据公式(2.2)算出,留给读者. 在均匀分布的情况,方差随区间  $[a, b]$  之长  $b-a$  的增大而增大,这当然,因区间长了,散布的程度也就大了.

**例 2.7** 求“统计三大分布”的方差.

先考虑卡方分布. 设  $X \sim \chi_n^2$ . 把  $X$  表为  $X_1^2 + \cdots + X_n^2$ ,  $X_1, \cdots, X_n$  独立同分布且有公共分布  $N(0, 1)$ . 有

$$\text{Var}(X_i^2) = E(X_i^4) - [E(X_i^2)]^2 = E(X_i^4) - 1$$

而

$$E(X_i^4) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^4 e^{-x^2/2} dx = \frac{2}{\sqrt{2\pi}} \int_0^{\infty} x^4 e^{-x^2/2} dx$$

作变数代换  $x = \sqrt{2}t$ , 有

$$\begin{aligned} E(X_i^4) &= \frac{2}{\sqrt{2\pi}} 2\sqrt{2} \int_0^{\infty} t^{3/2} e^{-t} dt = \frac{4}{\sqrt{\pi}} \Gamma\left(\frac{5}{2}\right) \\ &= \frac{4}{\sqrt{\pi}} \frac{3}{2} \frac{1}{2} \sqrt{\pi} = 3 \end{aligned}$$

故  $\text{Var}(X_i^2) = 3 - 1 = 2$ , 而  $\text{Var}(X) = 2n$ .

次考虑  $t$  分布. 设  $X = X_1 / \sqrt{\frac{1}{n} X_2}$ ,  $X_1, X_2$  独立而  $X_2 \sim \chi_n^2$ ,  $X_1 \sim N(0, 1)$ . 前已指出  $E(X) = 0$ . 故由独立性有

$$\text{Var}(X) = E(X^2) = E(X_1^2) E(n/X_2) = nE(1/X_2)$$

在例 1.8 中已算出  $E(1/X_2) = 1/(n-2)$ , 故  $\text{Var}(X) = n/(n-2)$ , ( $n > 2$ ).

自由度  $n$  的  $t$  分布  $t_n$  有期望 0, 与标准正态  $N(0, 1)$  的期望同. 其方差  $n/(n-2)$  大于 1 但当  $n$  很大时接近  $N(0, 1)$  的方差 1. 以后将指出: 当  $n$  很大时,  $t_n$  的分布确实接近  $N(0, 1)$ .

类似地算出自由度  $m, n$  的  $F$  分布  $F_{m, n}$  的方差为  $2n^2(m +$

$n-2)/[m(n-2)^2(n-4)]$  (当  $n > 4$ ). 细节留给读者.

### 3.2.2 矩

**定义 2.2** 设  $X$  为随机变量,  $c$  为常数,  $k$  为正整数. 则量  $E[(X-c)^k]$  称为  $X$  关于  $c$  点的  $k$  阶矩.

比较重要的有两个情况:

1.  $c=0$ . 这时  $a_k = E(X^k)$  称为  $X$  的  $k$  阶原点矩.
2.  $c = E(X)$ . 这时  $\mu_k = E[(X - EX)^k]$  称为  $X$  的  $k$  阶中心矩.

一阶原点矩就是期望. 一阶中心矩  $\mu_1 = 0$ , 二阶中心矩  $\mu_2$  就是  $X$  的方差  $\text{Var}(X)$ . 在统计学上, 高于 4 阶的矩极少使用. 三、四阶矩有些应用, 但也不很多.

应用之一是用  $\mu_3$  去衡量分布是否有偏. 设  $X$  的概率密度函数为  $f(x)$ . 若  $f$  关于某点  $a$  对称, 即

$$f(a+x) = f(a-x)$$




图 3.4

如图 3.4 所示, 则  $a$  必等于  $E(X)$ , 且  $\mu_3 = E[X - E(X)]^3 = 0$ . 如果  $\mu_3 > 0$ , 则称分布为正偏或右偏. 如果  $\mu_3 < 0$ , 则称分布为负偏或左偏. 特别, 对正态分布而言有  $\mu_3 = 0$ , 故如  $\mu_3$  显著异于 0, 则是分布与正态有较大偏离的标志. 由于  $\mu_3$  的因次是  $X$  的因次的三次方, 为抵消这一点, 以  $X$  的标准差的三次方, 即  $\mu_2^{3/2}$  去除  $\mu_3$ . 其商

$$\beta_1 = \mu_3 / \mu_2^{3/2} \quad (2.8)$$

称为  $X$  或其分布的“偏度系数”.

应用之二是用  $\mu_4$  去衡量分布(密度)在均值附近的陡峭程度如何. 因为  $\mu_4 = E[X - E(X)]^4$ , 容易看出, 若  $X$  取值在概率上很集中在  $E(X)$  附近, 则  $\mu_4$  将倾向于小, 否则就倾向于大. 为抵消尺度的影响, 类似于  $\mu_3$  的情况, 以标准差四次方即  $\mu_2^2$  去除, 得

$$\beta_2 = \mu_4 / \mu_2^2 \quad (2.9)$$

它称为  $X$  或其分布的“峰度系数”。

若  $X$  有正态分布  $N(\mu, \sigma^2)$ , 则  $\beta_2 = 3$ , 与  $\mu$  和  $\sigma^2$  无关. 为了迁就这一点, 也常定义  $\mu_4 / \mu_2^2 - 3$  为峰度系数, 以使正态分布有峰度系数 0.

“峰度”这个名词, 单从表面上看, 易引起误解. 例如, 我们在例 2.4 中已指出, 并由图 3.3 看出, 就正态分布  $N(\mu, \sigma^2)$  而言,  $\sigma^2$  愈小, 密度函数在  $\mu$  点处“高峰”就愈高且愈陡峭. 那么, 为何所有的正态分布都又有同一峰度系数? 这岂不与这个名词的直觉含义不符? 原因在于:  $\mu_4$  在除以  $\mu_2^2$  后已失去了因次, 即与  $X$  的单位无关. 或者换句话说, 两个变量  $X, Y$ , 谁的峰度大, 不能直接比其密度函数, 而要调整到方差为 1 后再去比. 就是说, 找两个常数  $c_1, c_2$ , 使  $c_1 X$  和  $c_2 Y$  的方差都为 1, 再比较其密度的“陡峭”程度如何.

在这个共同的标准下, “峰度”一词就好理解了. 不信看图 3.5. 为便于理解, 我们在图中画了两条都以  $\mu$  为对称中心的对称密度曲线, 且峰的高度一样, 但  $f_1$  在顶峰处很陡. 而  $f_2$  则在顶峰处形成平台, 较为平缓. 这样, 在  $\mu$  附近,  $f_2$  的概率多而  $f_1$  的概率少. 而方差都为 1, 故  $f_1$  的“尾巴”必比  $f_2$  的厚一些, 这导致其  $\mu_4$  较大, 即有较大的峰度系数.




图 3.5