

## 第五章 大数定律与中心极限定理

大数定律和中心极限定理的研究,在概率论的发展中占有重要地位,是概率论成为一门成熟的数学学科的重要标志之一,而且仍然是现代概率论的重要研究方向之一.

大数定律有重要的理论意义,是概率稳定性和大量观测结果平均水平稳定性的的数学定理;中心极限定理是在一定条件下关于“大量随机变量之和的极限分布是正态分布”的一系列定理的总称.我们这里只介绍实际中最常用的极限定理,其中大数定律包括贝努里大数定律、切比雪夫大数定律和辛钦大数定律;中心极限定理包括德莫佛—拉普拉斯定理和林德伯格—列维定理.

### § 5.1 大数定律

在第一章中,我们已经指出,人们在长期实践中发现,虽然个别随机事件在某次试验中可能出现也可能不出现,但是在大量重复试验中却呈现出明显的规律性,即一个随机事件出现的频率在某个固定数的附近变动,这就是所谓“频率的稳定性”,对于这点,至今为止,我们没有给出理论上的说明.

数学上怎样来描述在一定条件下的大量重复试验呢?我们在前面的内容中已经建立了贝努里试验这一概率模型,并指出它可以作为一定条件下的重复试验的数学模型.在贝努里试验中,各次试验是相互独立的;在每次试验中,我们所关心的事件  $A$  出现的概率  $P(A) = p$  保持不变.这些特征可以看作是从数学角度把“在一定条件下”、“重复试验”等等用语的涵义加以明确化.

在贝努里试验中,若以  $\mu_n$  记  $n$  次试验中  $A$  出现的次数,则  $\frac{\mu_n}{n}$  便是在这  $n$  次试验中事件  $A$  出现的频率,所谓频率的稳定性无非是指当试验次数  $n$  增大时,频率  $\frac{\mu_n}{n}$  接近于某个固定的常数.

这个固定的常数就是事件  $A$  在一次试验中发生的概率.由此可见,讨论频率  $\frac{\mu_n}{n}$  的极限行为是理解概率论中最基本的概念—概率所不可缺少的.正是这个缘故,在概率论的发展史上,极限定理的研究一直占有重要地位,而它的发源地就是贝努里试验这个概型.

从前几章的讨论中我们知道,  $\mu_n$  是随机变量, 它服从二项分布

$$P\{\mu_n = k\} = C_n^k p^k q^{n-k} \quad k = 0, 1, 2, \dots, n$$

其数学期望  $E\mu_n = np$ , 方差  $D\mu_n = npq$ , 这在一定程度上帮助我们进一步了解了频率  $\frac{\mu_n}{n}$

的性质, 但是我们更需要知道的是,  $n$  很大时,  $\mu_n$  或  $\frac{\mu_n}{n}$  的性质。

显然, 当  $n$  很大时,  $\mu_n$  一般也很大, 所以直接研究  $\mu_n$  不是很恰当, 还是研究频率  $\frac{\mu_n}{n}$

为宜。因为  $E(\frac{\mu_n}{n}) = p, D(\frac{\mu_n}{n}) = \frac{pq}{n}$ , 所以当  $n \rightarrow \infty$  时, 频率的数学期望保持不变, 而

方差则趋于零。我们知道方差为零的随机变量是常数, 于是我们自然预期频率将趋于常数  $p$  (事件  $A$  发生的概率), 但是频率  $\mu_n/n$  是随机变量, 关于它的极限又将如何表示呢?

一种提法是, 当  $n$  足够大时, 频率  $\frac{\mu_n}{n}$  与概率  $p$  有较大偏差的概率很小, 用数学语言

来讲, 就是要证明, 对于任给的  $\varepsilon > 0$ ,

$$\lim_{n \rightarrow \infty} P\{|\mu_n/n - p| \geq \varepsilon\} = 0 \quad (5.1)$$

或它的等价式

$$\lim_{n \rightarrow \infty} P\{|\mu_n/n - p| < \varepsilon\} = 1$$

成立。

历史上, 贝努里第一个研究了这种类型的极限定理. 在 1713 年发表的论文中, 他建立了等式(5.1), 这是一大类概率论极限定理中的第一个 (也是概率论的第一篇论文)。

**定理 1** (贝努里大数定律) 设  $\mu_n$  是  $n$  重贝努里试验中事件  $A$  出现的次数, 又  $A$  在每次试验中出现的概率为  $p$  ( $0 < p < 1$ ), 则对任意的  $\varepsilon > 0$ , 有

$$\lim_{n \rightarrow \infty} P\{|\mu_n/n - p| < \varepsilon\} = 1 \quad (5.2)$$

**证明:** 令  $\xi_i = \begin{cases} 0 & \text{在第 } i \text{ 次试验中 } A \text{ 出现} \\ 1 & \text{在第 } i \text{ 次试验中 } A \text{ 不出现} \end{cases} \quad (1 \leq i \leq n)$

则  $\xi_1, \xi_2, \dots, \xi_n$  是  $n$  个相互独立的随机变量, 且

$$E\xi_i = p, D\xi_i = p(1-p) = pq,$$

而

$$\mu_n = \sum_{i=1}^n \xi_i,$$

所以

$$\frac{\mu_n}{n} - p = \frac{\mu_n - np}{n} = \frac{\sum_{i=1}^n \xi_i - E(\sum_{i=1}^n \xi_i)}{n},$$

由切比雪夫不等式

$$\begin{aligned} P\{|\mu_n/n - p| \geq \varepsilon\} &= P\left\{\left|\frac{\sum_{i=1}^n \xi_i - E(\sum_{i=1}^n \xi_i)}{n}\right| \geq \varepsilon\right\} = P\left\{\left|\sum_{i=1}^n \xi_i - E(\sum_{i=1}^n \xi_i)\right| \geq n\varepsilon\right\} \\ &\leq \frac{D(\sum_{i=1}^n \xi_i)}{n^2 \varepsilon^2} \quad (\text{由独立性 } D(\sum_{i=1}^n \xi_i) = \sum_{i=1}^n D\xi_i = np) \\ &= \frac{npq}{n^2 \varepsilon^2} = \frac{1}{n} \frac{pq}{\varepsilon^2} \rightarrow 0 \quad (n \rightarrow \infty) \end{aligned}$$

这个定理以严格的数学形式表达了概率的稳定性。就是说当  $n$  很大时，事件发生的频率与概率有较大偏差的可能性很小，由实际推断原理，在实际应用中，当试验次数很大时，便可以用事件的频率来代替事件的概率。

下面给出的是比贝努里大数定律更广泛一些的切比雪夫大数定律。

**定理 2** (切比雪夫大数定律) 设  $\xi_1, \xi_2, \dots, \xi_n, \dots$  是一列两两不相关的随机变量，又设它们的方差有界，即存在常数  $C > 0$ ，使有  $D\xi_i \leq C \quad i = 1, 2, \dots$ ，则对任意的  $\varepsilon > 0$ ，有

$$\lim_{n \rightarrow \infty} P\left\{\left|\frac{1}{n} \sum_{i=1}^n \xi_i - \frac{1}{n} \sum_{i=1}^n E\xi_i\right| < \varepsilon\right\} = 1 \quad (5.3)$$

**证明：**由切比雪夫不等式，有

$$P\left\{\left|\frac{1}{n} \sum_{i=1}^n \xi_i - \frac{1}{n} \sum_{i=1}^n E\xi_i\right| \geq \varepsilon\right\} \leq \frac{D\left(\frac{1}{n} \sum_{i=1}^n E\xi_i\right)}{\varepsilon^2} = \frac{D\left(\sum_{i=1}^n E\xi_i\right)}{n^2 \varepsilon^2}$$

因为  $\{\xi_i\}$  两两不相关, 且由它们的方差有界即可得到

$$D\left(\sum_{i=1}^n \xi_i\right) = \sum_{i=1}^n D\xi_i \leq nC$$

从而有

$$P\left\{\left|\frac{1}{n}\sum_{i=1}^n \xi_i - \frac{1}{n}\sum_{i=1}^n E\xi_i\right| \geq \varepsilon\right\} \leq \frac{C}{n\varepsilon^2} \rightarrow 0, n \rightarrow \infty$$

可以看出贝努里大数定律是切比雪夫大数定律的特例, 在它们的证明中, 都是以切比雪夫不等式为基础的, 所以要求随机变量具有方差, 但是进一步的研究表明, 方差存在这个条件并不是必要的, 下面我们介绍一个满足独立同分布条件时的辛钦大数定律。

**定理 3** (辛钦大数定律) 设  $\xi_1, \xi_2, \dots, \xi_n, \dots$  是一列独立同分布的随机变量, 且数学期望存在,  $E\xi_i = a \quad i=1, 2, \dots$ , 则对任意的  $\varepsilon > 0$ , 有

$$\lim_{n \rightarrow \infty} P\left\{\left|\frac{1}{n}\sum_{i=1}^n \xi_i - a\right| < \varepsilon\right\} = 1. \quad (5.4)$$

证明略。

显然, 辛钦大数定律也是贝努里大数定律的一种推广。辛钦大数定律表明, 当  $n$  很大时, 随机变量在  $n$  次观测中的算术平均值  $\frac{1}{n}\sum_{i=1}^n \xi_i$  会“靠近”它的期望值, 这就为寻找随机变量的期望值提供了一条实际可行的途径。

$n$  个随机变量的算术平均值会“靠近”它的期望值, 这种“靠近”是在概率意义下的接近。通俗地说, 在定理的条件下,  $n$  个随机变量的算术平均, 当  $n$  无限增加时将几乎变成一个常数。

设  $\xi_1, \xi_2, \dots, \xi_n, \dots$  是一列随机变量,  $a$  是一个常数, 若对于任意的  $\varepsilon > 0$ , 有

$$\lim_{n \rightarrow \infty} P\{|\xi_n - a| < \varepsilon\} = 1$$

则称序列  $\xi_1, \xi_2, \dots, \xi_n, \dots$  依概率收敛到  $a$ , 记作  $\lim_{n \rightarrow \infty} \xi_n \stackrel{P}{=} a$ , 或者  $\xi_n \xrightarrow{P} a \quad (n \rightarrow \infty)$ 。

贝努里大数定律表明了频率  $\frac{\mu_n}{n}$  依概率收敛于  $p$ , 即  $\frac{\mu_n}{n} \xrightarrow{P} p \quad (n \rightarrow \infty)$

关于依概率收敛有下面的一些性质。

若  $\{\xi_n\}$ 、 $\{\eta_n\}$  是两个随机变量序列，并且当  $n \rightarrow \infty$  时，有  $\xi_n \xrightarrow{P} a$ ， $\eta_n \xrightarrow{P} b$ ，

其中  $a$  和  $b$  是常数，则有

$$(1) \xi_n + \eta_n \xrightarrow{P} a + b, (n \rightarrow \infty)$$

$$(2) \xi_n - \eta_n \xrightarrow{P} a - b, (n \rightarrow \infty)$$

$$(3) \xi_n \cdot \eta_n \xrightarrow{P} ab, (n \rightarrow \infty)$$

$$(4) \text{若 } b \neq 0, \xi_n / \eta_n \xrightarrow{P} a/b, (n \rightarrow \infty)$$

上述结论的证明是容易的，在此略去。

## § 5.2 中心极限定理

自从高斯提出测量误差服从正态分布以后，人们发现，正态分布在自然界中极为常见，如炮弹的落点、身高、体重等，观察表明，如果一个量是由大量相互独立的随机因素的影响所造成，而每一个因素在总因素中所起的作用不是很大，则这种量通常都服从或近似服从正态分布。

如果一个量的形成受到众多的随机因素的影响，而其中任一单个因素所起的作用很有限，则这个量的概率分布，必然（近似地）用正曲线去描述，此结果在概率论上叫做“中心极限定理”。概率论中凡是关于“在一定条件下，随机变量之和的分布是正态分布”的定理，统称为中心极限定理。

中心极限定理在概率论和统计学中有极广泛的应用，它揭示了正态分布的源泉。中心极限定理的内容非常丰富，它有多种形式，我们只介绍常用的两种：德莫佛-拉普拉斯（De Moivre-Laplace）中心极限定理和林德伯格-列维（Lindeberg-Levy）中心极限定理。德莫佛-拉普拉斯中心极限定理说明二项分布的极限分布是正态分布，而林德伯格-列维中心极限定理说明“独立随机变量之和或算术平均值”的极限分布是正态分布。

**定理 1**（德莫佛-拉普拉斯中心极限定理）在  $n$  重贝努里试验中，事件  $A$  在每次试验中出现的概率为  $p(0 < p < 1)$ ， $\mu_n$  为  $n$  次试验中事件  $A$  出现的次数，则

$$\lim_{n \rightarrow \infty} P\left\{\frac{\mu_n - np}{\sqrt{npq}} < x\right\} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \quad (5.5)$$

证明略。

该定理表明，正态分布是二项分布的极限分布。当  $n$  充分大时，我们可以用下式来计算二项分布的概率

$$\lim_{n \rightarrow \infty} P\left\{a \leq \frac{\mu_n - np}{\sqrt{npq}} \leq b\right\} = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{t^2}{2}} dt$$

下一定理是定理德莫佛-拉普拉斯中心极限定理的推广，又把它叫做独立同分布的中心极限定理。

**定理 2** (林德伯格-列维中心极限定理) 设  $\xi_1, \xi_2, \dots, \xi_n, \dots$  是一列独立同分布的随机变量,  $E\xi_i = a \quad i=1,2,\dots, D\xi_i = \sigma^2 \quad (\sigma > 0)$ , 则有

$$\lim_{n \rightarrow \infty} P\left\{\frac{\sum_{i=1}^n \xi_i - na}{\sigma\sqrt{n}} < x\right\} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \quad (5.6)$$

证明略。

定理 2 表明, 均值为  $a$ , 方差为  $\sigma^2$  的独立同分布的随机变量  $\xi_1, \xi_2, \dots, \xi_n$  之和  $\sum_{i=1}^n \xi_i$  的标准化变量, 在  $n$  充分大时, 近似地服从标准正态分布。

将(5.6)式左端改写, 则(5.6)式变为

$$\lim_{n \rightarrow \infty} P\left\{\frac{\frac{1}{n} \sum_{i=1}^n \xi_i - a}{\sigma/\sqrt{n}} < x\right\} = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt \quad (5.7)$$

(5.7)式表明, 均值为  $a$ , 方差为  $\sigma^2$  的独立同分布的随机变量  $\xi_1, \xi_2, \dots, \xi_n$  的算术平均

$\bar{\xi} = \frac{1}{n} \sum_{i=1}^n \xi_i$ , 在  $n$  充分大时近似地服从均值为  $a$ 、方差为  $\sigma^2/n$  的正态分布。这一结果是

数理统计中大样本统计推断的基础。

下面举几个关于中心极限定理应用的例子。

**例 1** 某单位内部有 260 部电话分机, 每部分机有 4% 的时间要使用外线通话, 若各电话分机是否使用外线是相互独立的, 问总机要配备多少条外线方可以 95% 的把握保证每部分

机在使用外线时不必等候?

解: 令  $X_i = \begin{cases} 1, & \text{第 } i \text{ 个分机要使用外线} \\ 0 & \text{第 } i \text{ 个分机不使用外线} \end{cases}, i=1,2,\dots,260$

$P\{X_k = 1\} = 0.04, P\{X_k = 0\} = 0.96$ , 则任一时刻 260 部分机中要使用外线的分机数

为  $Y_n = \sum_{k=1}^{260} X_k$ , 且服从参数为 260, 0.04 的二项分布, 由极限定理

$$P\{Y_{260} < x\} = P\left\{ \frac{Y_{260} - 260 \times 0.04}{\sqrt{260 \times 0.04 \times 0.96}} \leq \frac{x - 260 \times 0.04}{\sqrt{260 \times 0.04 \times 0.96}} \right\} \\ \approx \Phi\left( \frac{x - 260 \times 0.04}{\sqrt{260 \times 0.04 \times 0.96}} \right) = \Phi(b) \geq 0.95$$

由正态分布表, 要使  $\Phi(b) \geq 0.95$ , 必需  $b=1.65$ ,

$$\text{即 } x = 1.65 \times \sqrt{260 \times 0.04 \times 0.96} + 260 \times 0.04 \approx 15.61.$$

取最接近的整数  $x = 16$ , 故总机至少要配备 16 条外线, 才能保证有 95% 的把握使各个分机在使用外线时不占线.

**例 2** 设男孩出生率为 0.515, 求在 10000 个新生儿中女孩不少于男孩的概率.

解: 用  $X$  表示 10000 个新生儿中男孩的个数, 则  $X \sim B(n, p)$ , 其中,  $n=10000$ ,  $p=0.515$ .

要求女孩数不少于男孩个数的概率, 即求  $P\{X \leq 5000\}$ . 由德莫佛-拉普拉斯极限定理, 有

$$\{X \leq 5000\} = \left\{ \frac{X - np}{\sqrt{npq}} \leq \frac{5000 - np}{\sqrt{npq}} \right\}$$

令  $Y = \frac{X - np}{\sqrt{npq}}$ , 则  $Y \sim N(0,1)$  于是有

$$P\{X \leq 5000\} = P\left\{ Y \leq \frac{5000 - 10000 \times 0.515}{\sqrt{10000 \times 0.515 \times 0.485}} \right\} \approx \Phi(-3) = 1 - \Phi(3) = 0.00135$$

**例 3** 对于一个学生而言, 来参加家长会的家长人数是一个随机变量, 设一个学生无家长、1 名家长、2 名家长来参加会议的概率分别为 0.05、0.8、0.15. 若学校共有 400 名学生, 设各学生参加会议的家长人数相互独立, 且服从统一分布。(1) 求参加会议的家长数超过

450 的概率； ②) 求有 1 名家长来参加会议的学生数不多于 340 的概率。

解：(1) 以用  $X_k (k=1,2,\dots,400)$  表示第  $k$  个学生来参加会议的家长数，则

$X_k (k=1,2,\dots,400)$  的分布律为

$X_k$	0	1	2
$p_k$	0.05	0.8	0.15

易知  $E(X_k) = 1.1, D(X_k) = 0.19 (k=1,2,\dots,400)$ 。而  $X = \sum_{k=1}^{400} X_k$ ，由定理 2

$$\begin{aligned}
 P\{X > 450\} &= P\left\{\frac{X - 400 \times 1.1}{\sqrt{400} \sqrt{0.19}} > \frac{450 - 400 \times 1.1}{\sqrt{400} \sqrt{0.19}}\right\} \\
 &= 1 - P\left\{\frac{X - 400 \times 1.1}{\sqrt{400} \sqrt{0.19}} \leq 1.147\right\} \\
 &\approx 1 - \Phi(1.147) = 0.1257
 \end{aligned}$$

(2) 以  $Y$  记有一名家长来参加会议的学生数，则  $Y \sim b(400, 0.8)$ ，则由定理 1 得

$$\begin{aligned}
 P\{Y \leq 340\} &= P\left\{\frac{Y - 400 \times 0.8}{\sqrt{400 \times 0.8 \times 0.2}} \leq \frac{340 - 400 \times 0.8}{\sqrt{400 \times 0.8 \times 0.2}}\right\} \\
 &= P\left\{\frac{Y - 400 \times 0.8}{\sqrt{400 \times 0.8 \times 0.2}} \leq 2.5\right\} \\
 &\approx \Phi(2.5) \leq 0.9938
 \end{aligned}$$