

超几何分布、二项分布与正态分布的区别与联系

◎郭 婧¹ 李 强² (1.青岛西海岸新区第一高级中学,山东 青岛 266000;
2.青岛大学,山东 青岛 266000)

【摘要】人教 A 版选修 2-3 中介绍了超几何分布、二项分布和正态分布,前两者属于离散型随机变量服从的分布,后者属于连续型随机变量服从的分布.实际中的许多问题都可以利用这三个概率模型来解决.区分前两者的关键是看属于“不放回”模型还是“有放回”模型.同时,随着产品数量的增加,超几何分布越来越趋近于二项分布;随着试验次数的增加,二项分布越来越趋近于正态分布.从而三者在极限方面实现统一.

【关键词】超几何分布;二项分布;正态分布;极限

【基金项目】山东省教育学会科技教育专项课题:基于虚拟现实的高中数学翻转课堂教学模式研究(课题号 18-KJJY-0074).科技部国家重点研发计划:流域水系分级嵌套耦合大规模水文模拟并行算法设计(No.2017YFB0203102).

一、总述

人教 A 版选修 2-3 中介绍了超几何分布、二项分布和正态分布,前两者属于离散型随机变量服从的分布,后者属于连续型随机变量服从的分布.在实际教学中发现学生辨别这些分布是难点,或者即使能辨别却无法从本质上认识它们.本文介绍三种分布的区别与联系,来帮助学生克服此难点.

在教材中,三种分布的定义如下:

一般地,在含有 M 件次品的 N 件产品中,任取 n 件,其中恰有 X 件次品,则

$$P(X=k) = \frac{C_M^k C_{N-M}^{n-k}}{C_N^n}, k=0,1,2,\dots,m,$$

其中 $m=\min\{M,n\}$, $n \leq N$, $M \leq N$, $n, M, N \in \mathbb{N}^+$. 如果随机变量 X 的分布列具有上述形式,则称随机变量 X 服从超几何分布(hypergeometric distribution).

一般地,在 n 次独立重复试验中,用 X 表示事件 A 发生的次数,设每次试验中事件 A 发生的概率为 p ,则 $P(X=k) = C_n^k p^k (1-p)^{n-k}$, $k=0,1,2,\dots,n$. 此时称随机变量 X 服从二项

分布(binomial distribution),记作 $X: B(N, p)$, 并称 p 为成功概率.

一般地,如果对于任何实数 a, b ($a < b$),随机变量 X 满足

$$P(a < X \leq b) = \int_a^b \varphi_{\mu, \sigma}(x) dx, \text{ 其中 } \varphi_{\mu, \sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, x \in (-\infty, +\infty), \text{ 则称随机变量 } X \text{ 服从正}$$

态分布(normal distribution),记作 $X \sim N(\mu, \sigma^2)$ [1].

二、超几何分布与二项分布的区别与联系

超几何分布是“不放回”情境中的古典概型,二项分布是“有放回”情境中的 n 次独立重复试验概型.如教材习题 2.2B 组第三题:某批 n 件产品的次品率为 2% ,现从中任意地抽出 3 件进行检验,问:当 $n=500, 5\ 000, 50\ 000$ 时,分别以放回和不放回的方式抽取,恰好抽到 1 件次品的概率各是多少?设抽取到的次品数为 X .若以有放回的方式抽取,抽取 3 次相当于做了 3 次独立重复试验,则 $X: B(3, 2\%)$, 故 $P(X=1) = C_3^1 \times 2\% \times (1-2\%)^2 \approx 0.057\ 624$. 若以不放回方式抽取,这个问题回归到古典概型, X 服从超几何分布. $n=$

$$500 \text{ 时,次品数是 } 500 \times 2\% = 10, P(X=1) = \frac{C_{10}^1 C_{490}^2}{C_{500}^3} \approx$$

$$0.057\ 853. \text{ 同理可得 } n=5\ 000 \text{ 时, } P(X=1) = \frac{C_{100}^1 C_{4900}^2}{C_{5000}^3} \approx$$

$$0.057\ 647. n=50\ 000 \text{ 时, } P(X=1) = \frac{C_{1000}^1 C_{49000}^2}{C_{50000}^3} \approx 0.057\ 626. \text{ 由}$$

此可见,随着产品数 n 的增加,超几何分布的概率是越来越接近于二项分布的概率的.此结论也可以通过以下表格验证:

$k \backslash n$	0	1	2	3
500	-1.16×10^{-4}	2.29×10^{-4}	1.11×10^{-4}	-2.21×10^{-6}
5 000	-1.2×10^{-5}	2.3×10^{-5}	1.11×10^{-5}	-2.34×10^{-7}
50 000	-1.1×10^{-6}	2×10^{-6}	1.11×10^{-6}	-2.35×10^{-8}

其中表中的每一个数表示相应超几何分布与二项分布的概率差.由此可见,无论取几件次品,随着产品数的增加,二者的差距都是越来越趋近于零的^[3].即

$$\lim_{N \rightarrow \infty} \frac{C_M^k C_{N-M}^{n-k}}{C_N^n} = C_n^k p^k (1-p)^{n-k}.$$

下面我们对这个结论给出证明:

$$\begin{aligned} \lim_{N \rightarrow \infty} \frac{C_M^k C_{N-M}^{n-k}}{C_N^n} &= \lim_{N \rightarrow \infty} \frac{A_M^k A_{N-M}^{n-k} n!}{k! (n-k)! A_N^n} \\ &= \lim_{N \rightarrow \infty} C_n^k \frac{M(M-1) \cdots (M-k+1) (N-M)(N-M-1) \cdots (N-M-n+k+1)}{N(N-1) \cdots (N-n+1)} \\ &= \lim_{N \rightarrow \infty} C_n^k \frac{pN(pN-1) \cdots (pN-k+1) (N-pN)(N-pN-1) \cdots (N-pN-n+k+1)}{N(N-1) \cdots (N-n+1)} \\ &= \lim_{N \rightarrow \infty} C_n^k \frac{\overbrace{pN(pN-1) \cdots (pN-k+1)}^{k \uparrow}}{N^k} \cdot \frac{\overbrace{(N-pN)(N-pN-1) \cdots (N-pN-n+k+1)}^{(n-k) \uparrow}}{N^{n-k}} \\ &\quad \frac{N^n}{\underbrace{N(N-1) \cdots (N-n+1)}_{n \uparrow}} \\ &= C_n^k p^k (1-p)^{n-k}. \end{aligned}$$

一般地,如果随机变量依分布收敛于随机变量,则前者期望与方差的极限分别是后者的期望与方差^[4].实际上,若 X 服从超几何分布,则

$$\begin{aligned} E(X) &= \sum_{k=0}^m \frac{C_M^k C_{N-M}^{n-k}}{C_N^n} \\ &= \sum_{k=0}^m \frac{M C_{M-1}^{k-1} C_{N-M}^{n-k}}{N C_{N-1}^{n-1}} \\ &= \frac{nM}{N} \sum_{k=0}^m \frac{C_{M-1}^{k-1} C_{N-M}^{n-k}}{C_{N-1}^{n-1}} \\ &= n \frac{M}{N} \\ &= np. \\ D(X) &= E(X^2) - (E(X))^2 \\ &= \sum_{k=0}^m k^2 \frac{C_M^k C_{N-M}^{n-k}}{C_N^n} - \left(n \frac{M}{N}\right)^2 \\ &= \sum_{k=1}^m k(k-1) \frac{C_M^k C_{N-M}^{n-k}}{C_N^n} + \sum_{k=0}^m k \frac{C_M^k C_{N-M}^{n-k}}{C_N^n} - \left(n \frac{M}{N}\right)^2 \\ &= M(M-1) \sum_{k=2}^m \frac{C_{M-2}^{k-2} C_{N-M}^{n-k}}{C_N^n} + n \frac{M}{N} - \left(n \frac{M}{N}\right)^2 \end{aligned}$$

$$\begin{aligned} &= n(n-1) \frac{M(M-1)}{N(N-1)} \sum_{k=2}^m \frac{C_{M-2}^{k-2} C_{N-M}^{n-k}}{C_{N-2}^{n-2}} + n \frac{M}{N} - \left(n \frac{M}{N}\right)^2 \\ &= n(n-1) \frac{M(M-1)}{N(N-1)} + n \frac{M}{N} - \left(n \frac{M}{N}\right)^2. \end{aligned}$$

$$\therefore \lim_{N \rightarrow \infty} D(X) = np(1-p).$$

三、二项分布与正态分布的区别与联系

二项分布是离散型随机变量服从的分布,关注随机变量取某一个值时的概率;正态分布是连续型随机变量服从的分布,关注随机变量在某一范围的概率,存在于生活中的方方面面,如“长度测量的误差”“某一地区同年龄人群的身高、体重、肺活量”“在一定条件下生长的小麦的株高、穗长”等等都服从正态分布.但是貌似毫无关联的二项分布与正态分布,存在以下联系:

定理 在 n 次独立重复试验中,事件 A 在每次试验中出现的概率是 p ($0 < p < 1$), μ_n 为 n 次试验中事件 A 出现的次数,则

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

上式表明二项分布收敛于正态分布^[5].

四、总结

超几何分布、二项分布与正态分布是三个非常重要的、应用广泛的概率模型.实际中的许多问题都可以利用这三个概率模型来解决.区分前两者的关键是看属于“不放回”模型还是“有放回”模型.同时,随着产品数量的增加,超几何分布越来越趋近于二项分布;随着试验次数的增加,二项分布越来越趋近于正态分布.从而三者在极限方面实现统一.

【参考文献】

- [1] 李勇.普通高中课程标准实验教科书数学选修2-3[M].北京:人民教育出版社,2011.
- [2] 丁曼.超几何分布与二项分布的联系与区别[J].中国课程辅导,2010(7):115-116.
- [3] 魏宗舒.概率论与数理统计教程[M].北京:高等教育出版社,2008.
- [4] 汪嘉冈.现代概率论基础[M].上海:复旦大学出版社,2005.