



第三讲 常用概率分布

(PROBABILITY DISTRIBUTIONS)

一般数学表示方法

■ 概率数学表示方法

- X —— 符合某种概率分布的随机变量
- x —— 随机变量 X 的一个实例, `rnorm`, ...
- f —— 随机变量 X 的概率密度分布函数 (pdf) ,
`dnorm`,
- F —— 累积密度分布函数 (cdf) , `pnorm`, ...
- $P(X=k)$ —— 概率群分布函数 (probability mass distribution)

常用概率分布

- 离散概率分布 (Discrete)
 - 离散均匀分布 (discrete uniform)
 - 伯努利分布 (Bernoulli)
 - 二项式分布 (Binomial)
 - 泊松分布 (Poisson)
 - 超几何分布 (Hypergeometric)
- 连续概率分布 (continuous)
 - 均匀分布 (Uniform)
 - 正态分布 (Normal/Gaussian)
 - 指数分布 (Exponential)
 - Gamma分布
 - Beta分布
 - Gumbel分布



离散概率分布

离散均匀分布 (discrete uniform)

- 概念：每次抽样存在多种可能结果，每种结果出现的概率完全一致，也就是 X 的取值空间为一个有穷的集合 $S=\{k_1, k_2, \dots, k_n\}$ 且对于任意 $i \in 1 \dots n$, $P(X=k_i)=1/n$

- R代码

```
>>> x <- sample(c(1,2,6,8,9), 10000, prob=rep(0.2,5),  
               replace=TRUE)
```

```
>>> table(x)
```

```
## 另一种方法：用index
```

```
>>> idx <- runif(10000,0,5); idx <- ceiling(idx)
```

```
>>> x <- c(1,2,6,8,9)[idx]
```

```
>>> table(x)
```

伯努利试验 (Bernoulli)

- 概念：仅存在两种可能结果的一次试验
- 举例：扔硬币，正面朝上（“H”），反面朝上（“T”）
 - $P(X="H") = \pi$, $P(X="T") = 1 - \pi$
- R代码：进行1000次伯努利试验

```
>>> outcome <- sample(c("T","F"), 1000,
                        prob=c(0.8, 0.2), replace=TRUE)
>>> ot <- table(outcome)
>>> ot <- ot/sum(ot)
```

二项式分布 (Binomial)

- 概念

重复进行 n 次独立的伯努利试验(可能结果为 $\{1, 0\}$, 出现 1 的概率是 p), n 次结果中有 X 次 1 的概率分布就是二项式分布, X 的可能取值范围是 $\{0, 1, \dots, n\}$, 记作 $X \sim B(n, p)$

- 二项式分布的概率函数

$$P(X) = C_n^X \pi^X (1 - \pi)^{n - X}$$

$$C_n^X = \frac{n!}{X!(n - X)!}$$

二项式分布示例1

一个袋子里有5个乒乓球，其中2个黄球，3个白球，我们进行有放回的摸球游戏。因此每一次摸到黄球的概率是0.4，摸到白球的概率是0.6。

这个实验有三个特点：

1. 各次摸球是彼此独立的；
2. 每次摸球只有二种可能的结果，或黄或白；
3. 每次摸到黄球（或摸到白球）的概率是固定的。

具备这三点后， n 次中有 X 次摸到黄球（或白球）的概率分布就是二项分布。

二项分布在医学研究中的应用

医学研究中很多现象观察结果是以两分类变量来表示的，如阳性与阴性、治愈与未愈、生存与死亡等等。如果每个观察对象阳性结果的发生概率均为 π ，阴性结果的发生概率均为 $(1-\pi)$ ；而且各个观察对象的结果是相互独立的，那么，重复观察 n 个人，发生阳性结果的次人数 X 的概率分布为二项分布，记作 $B(X; n, \pi)$ 。

二项式分布示例2

用针灸治疗头痛，假定结果不是有效就是无效，每一例有效的概率为 $\pi=0.6$ 。某医生用此方法治疗头痛患者3例，2例有效的概率是多少？至少1例有效的概率呢？

$$C_3^2 0.6^2 (1 - 0.6)^{(3-2)} = 0.432$$

```
>>> n <- 3; pi <- 0.6
### p2 <- choose(3,2)*0.6^2*(1-0.6)^(3-2)
>>> p2 <- dbinom(2, n, pi)
>>> p123 <- sum(dbinom(c(1,2,3), n, pi))
### p123 <- 1-pbinom(0, n, pi)
### p123 <- pbinom(0, n, p, lower.tail=F)
```

二项式分布

治疗3例可能的有效例数及其概率

| 有效人数 (x) | C_3^x | π^x | $(1-\pi)^{n-x}$ | 出现该结果概 率 $P(x)$ |
|-------------|---------|-----------------------------|-----------------------------|--------------------|
| 0 | 1 | $0.6^0=1$ | $0.4 \times 0.4 \times 0.4$ | 0.064 |
| 1 | 3 | 0.6 | 0.4×0.4 | 0.288 |
| 2 | 3 | 0.6×0.6 | 0.4 | 0.432 |
| 3 | 1 | $0.6 \times 0.6 \times 0.6$ | 0.4^0 | 0.216 |

```
>>> x <- 0:3; n <- 3; pi <- 0.6  
>>> p <- dbinom(x, n, pi)  
>>> cp1 <- cumsum(p)  
>>> cp2 <- pbinom(x, n, pi)
```

二项式分布的特征

二项分布的图形特征

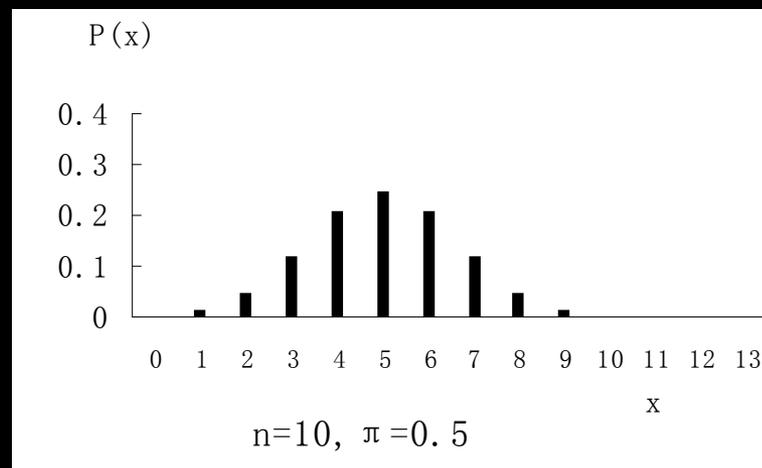
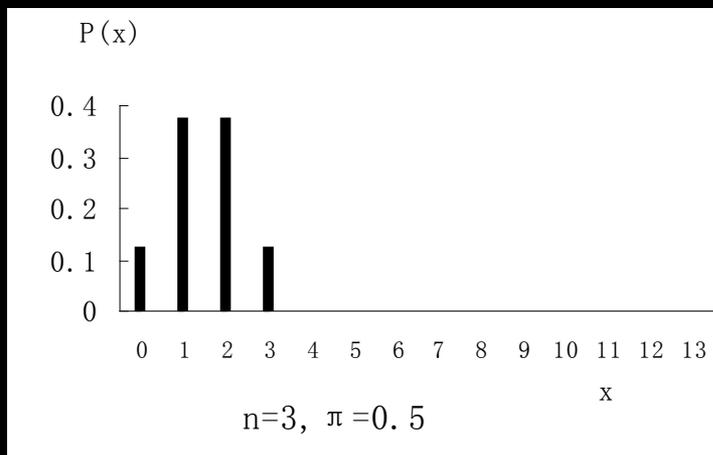
π 接近0.5时，图形是对称的；

π 离0.5愈远，对称性愈差，但随着 n 的增大，分布趋于对称

当 $n \rightarrow \infty$ 时，只要 π 不太靠近0或1，当 nP 和 $n(1-P)$ 都大于5时，二项分布近似于正态分布。

二项分布图形取决于 π 与 n ，高峰 $\mu=n\pi$ 处

二项式分布



$\pi=0.5$ 时,不同 n 值对应的二项分布

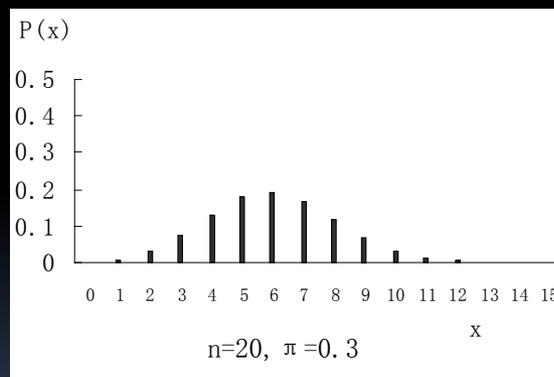
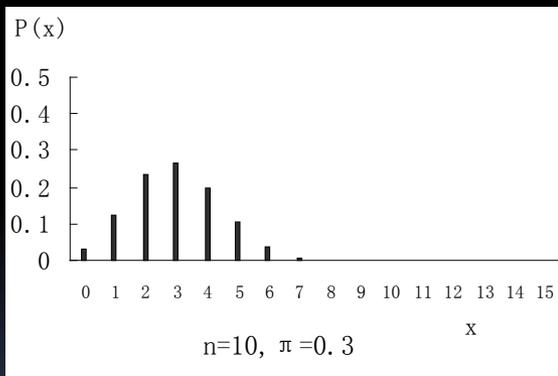
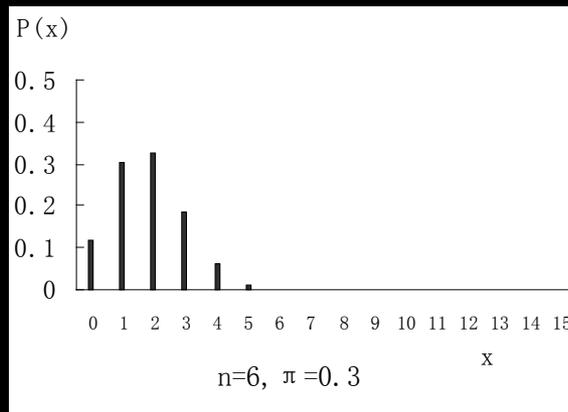
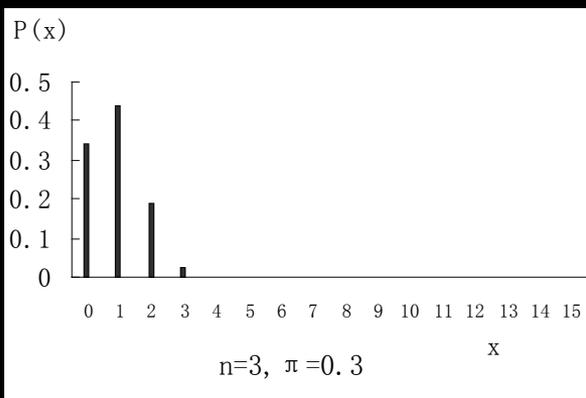
```
>>> x1 <- 0:3; x2 <- 0:10
```

```
>>> p1 <- dbinom(x1, 3, .5); p2 <- dbinom(x2, 10, .5)
```

```
>>> par(mfrow=c(1,2));
```

```
>>> plot(x1, p1, type='h'); plot(x2, p2, type='h')
```

二项式分布



$\pi=0.3$ 时, 不同 n 值对应的二项分布

二项式分布

- 二项分布的均数和标准差

总体均数: $\mu = n\pi$

方差: $\sigma^2 = n\pi(1 - \pi)$

标准差: $\sigma = \sqrt{n\pi(1 - \pi)}$

```
>>> n <- 100; pi <- 0.6
```

```
>>> x <- rbinom(1000, n, pi)
```

```
>>> mu <- mean(x); sigma2 <- var(x); sigma <- sd(x)
```

Poisson分布

概念

Poisson分布也是一种离散型分布，用以描述罕见事件发生次数的概率分布。医学上人群中出生缺陷、多胞胎、染色体异常等事件等都是罕见的，可能发生这些事件的观察例数 n 常常很大，但实际上发生类似事件的数目却很小很小。

Poisson分布

- Poisson分布可以看作是发生的概率 π （或未发生的概率 $1-\pi$ ）很小，而观察例数 n 很大时的二项分布。
- 除二项式分布的三个基本条件以外，Poisson分布还要求 π 或 $(1-\pi)$ 接近于0或1（例如 <0.001 或 >0.999 ）。

Poisson分布

Poisson分布的概率函数为

$$P(X) = e^{-\lambda} \frac{\lambda^X}{X!}$$

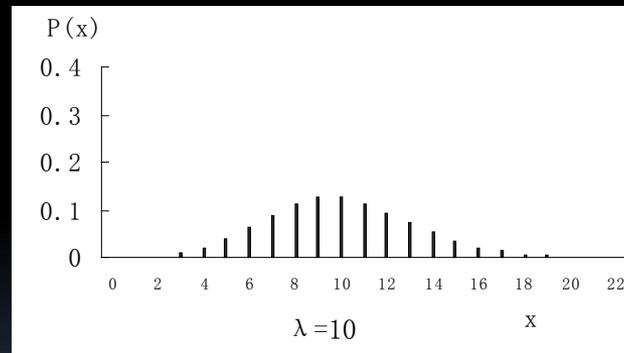
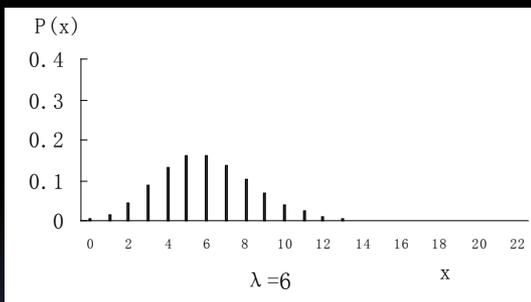
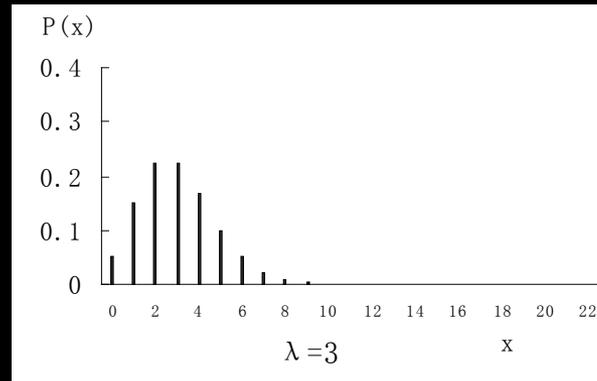
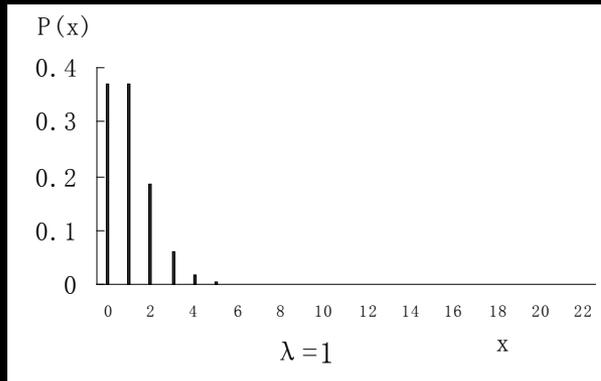
式中， $\lambda = n\pi$ 为Poisson分布的总体均数， X 为观察单位内某稀有事件的发生次数。

Poisson分布

Poisson分布当总体均数 λ 值小于5时为偏峰， λ 愈小分布愈偏，随着 λ 增大，分布趋向对称。

- Poisson分布有以下特性：
 - (1) Poisson分布的总体均数与总体方差相等，均为 λ
 - (2) Poisson分布的观察结果有可加性

Poisson分布



λ 取不同值时的Poisson分布图

Poisson分布

- 如果某地新生儿先天性心脏病的发病概率为8‰，那么该地120名新生儿中有4人患先天性心脏病的概率有多大？

$$\lambda = n\pi = 120 \times 0.008 = 0.96$$

$$P(X = 4) = \frac{e^{-0.96} 0.96^4}{4!} = 0.014$$

```
>>> n <- 120; pi <- 0.008
```

```
>>> x <- 4
```

```
>>> p1 <- dpois(x, n*pi)
```

```
>>> p2 <- dbinom(x, n, pi)
```

Poisson分布

单侧累计概率计算

如果稀有事件发生次数的总体均数为 λ ，那么该稀有事件发生次数至多为 k 次的概率

$$P(X \leq k) = \sum_{X=0}^k P(X) = \sum_{X=0}^k e^{-\lambda} \frac{\lambda^X}{X!}$$

发生次数至少为 k 次的概率

$$P(X \geq k) = 1 - P(X \leq k - 1)$$

Poisson分布

- 上例中，至多有4人患先天性心脏病的概率有多大？至少有5人患先天性心脏病的概率有多大？

至多有4人患先天性心脏病的概率

$$\begin{aligned} P(X \leq 4) &= \sum_{X=0}^4 P(X) = \sum_{X=0}^4 \frac{e^{-0.96} 0.96^X}{X!} \\ &= \frac{e^{-0.96} 0.96^0}{0!} + \frac{e^{-0.96} 0.96^1}{1!} + \frac{e^{-0.96} 0.96^2}{2!} + \frac{e^{-0.96} 0.96^3}{3!} + \frac{e^{-0.96} 0.96^4}{4!} = 0.997 \end{aligned}$$

至少有5人患先天性心脏病的概率为

$$P(X \geq 5) = 1 - P(X \leq 4) = 1 - 0.997 = 0.003$$

Poisson分布

- 实验显示某 100cm^2 的培养皿平均菌落数为6个，试估计该培养皿菌落数小于3个的概率，大于1个的概率。

该培养皿菌落数小于3个的概率

$$P(X < 3) = \sum_{X=0}^2 P(X) = \sum_{X=0}^2 \frac{e^{-6} 6^X}{X!} = \frac{e^{-6} 6^0}{0!} + \frac{e^{-6} 6^1}{1!} + \frac{e^{-6} 6^2}{2!} = 0.062$$

菌落数大于1个的概率为

$$P(X > 1) = 1 - P(X = 0) - P(X = 1) = 1 - \frac{e^{-6} 6^0}{0!} - \frac{e^{-6} 6^1}{1!} = 0.983$$

超几何分布 (Hypergeometric)

- 概念

- 超几何分布是一种不放回的抽样
- 已知1000个产品中不合格产品为2%，现抽取50个样品，出现3个不合格的几率是多少？

$$P(X = k) = \frac{\binom{m}{k} \binom{N-m}{n-k}}{\binom{N}{n}},$$



连续概率分布

连续均匀分布 (Uniform)

- 概念

- 与离散均匀分布类似，但变量的取值范围是一个闭合区间 $[a, b]$

$$f(x) = \begin{cases} \frac{1}{b-a} & \text{for } a \leq x \leq b, \\ 0 & \text{for } x < a \text{ or } x > b \end{cases}$$

正态分布

正态分布，也称为高斯分布（Gaussian）

正态曲线(normal curve)是一条高峰位于中央，两侧逐渐下降并完全对称，曲线两端永远不与横轴相交的钟型曲线该曲线表现为中间高，两边低，左右对称，略显钟形，类似于数学上的正态分布曲线。因为频率的总和等于1，故曲线下的面积等于1。

正态分布R函数

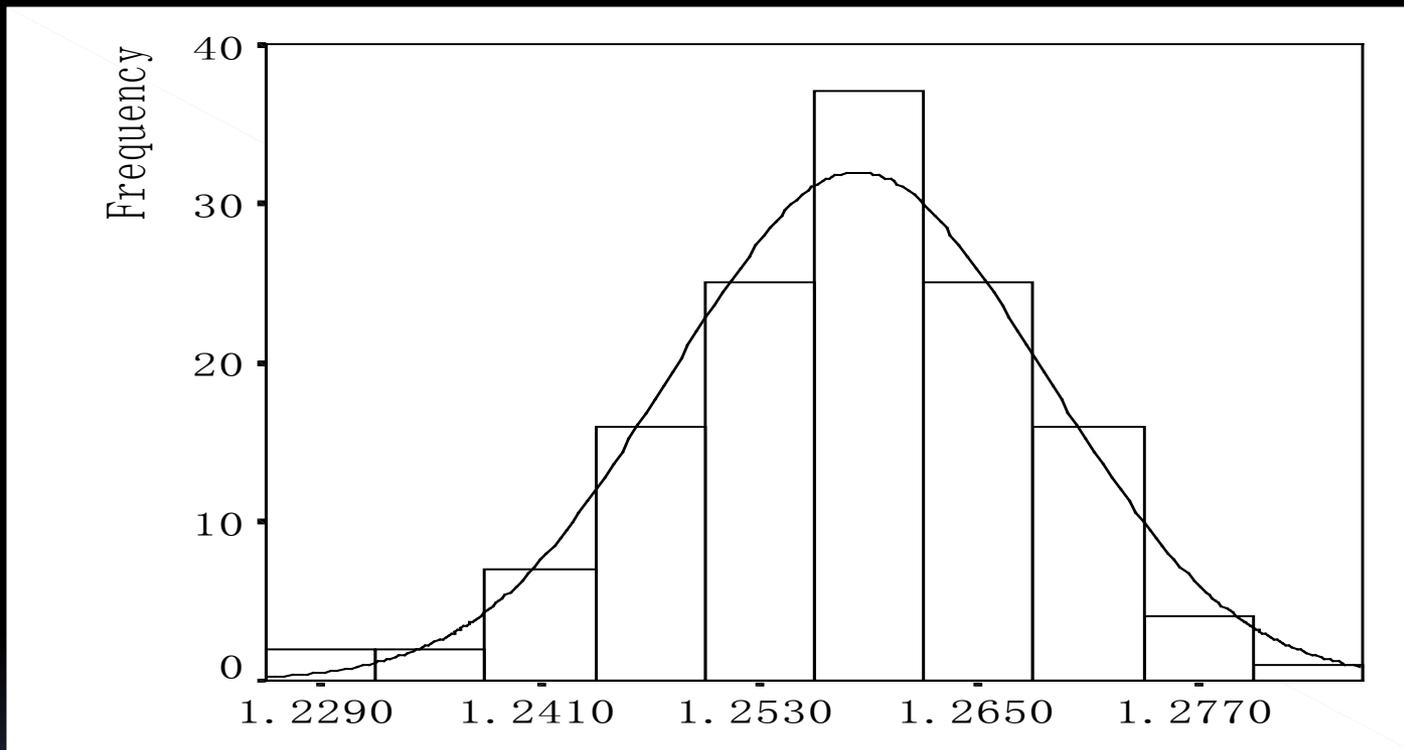
```
>>> rnorm(n, mu, sd) # 注意是sd而不是var
```

```
>>> dnorm(x, mu, sd) # 概率密度
```

```
>>> pnorm(x, mu, sd) # 累积概率密度
```

```
>>> qnorm(q, mu, sd) #  $0 \leq q \leq 1$ , 求分位点
```

正态分布

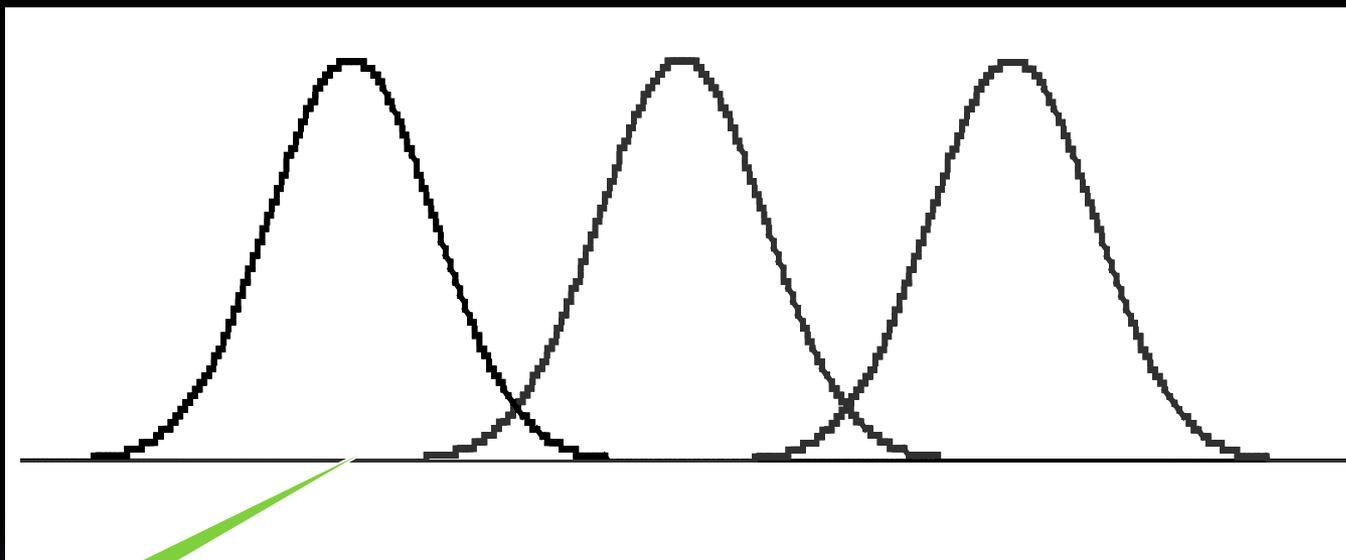


体模“骨密度”测量值的分布接近正态分布示意图（频率密度=频率/组距）

正态分布

- 正态概率密度曲线的位置与形状具有如下特点
- (1) 关于 $x=\mu$ 对称。
- (2) 在 $x=\mu$ 处取得该概率密度函数的最大值，在 $x=\mu\pm\sigma$ 处有拐点，表现为钟形曲线。
- (3) 曲线下面积为1。
- (4) μ 决定曲线在横轴上的位置， μ 增大，曲线沿横轴向右移；反之， μ 减小，曲线沿横轴向左移。
- (5) σ 决定曲线的形状，当 μ 恒定时， σ 越大，数据越分散，曲线越“矮胖”； σ 越小，数据越集中，曲线越“瘦高”。见图4-5。

正态分布



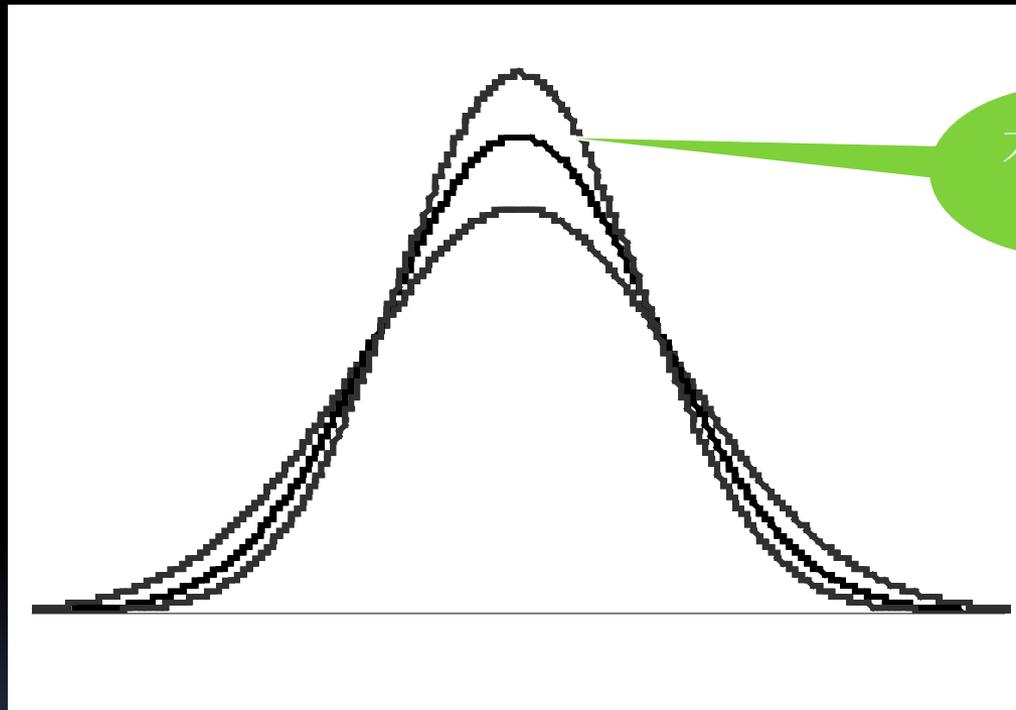
不同
均数

U_1

U_2

U_3

正态分布



不同标准差

正态分布

- 对任意一个服从正态分布 $N(\mu, \sigma^2)$ 的随机变量，可作如下的标准化变换，也称Z变换，

$$Z = \frac{X - \mu}{\sigma}$$

- Z服从总体均数为0、总体标准差为1的正态分布。我们称此正态分布为标准正态分布 (standard normal distribution)，用 $N(0, 1)$ 表示。

正态分布

已知 X 服从均数为 μ 、标准差为 σ 的正态分布，
试估计：

X 取值在区间 $\mu \pm 1.96\sigma$ 上的概率：

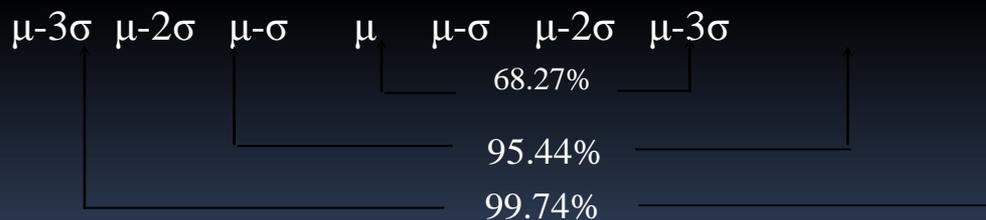
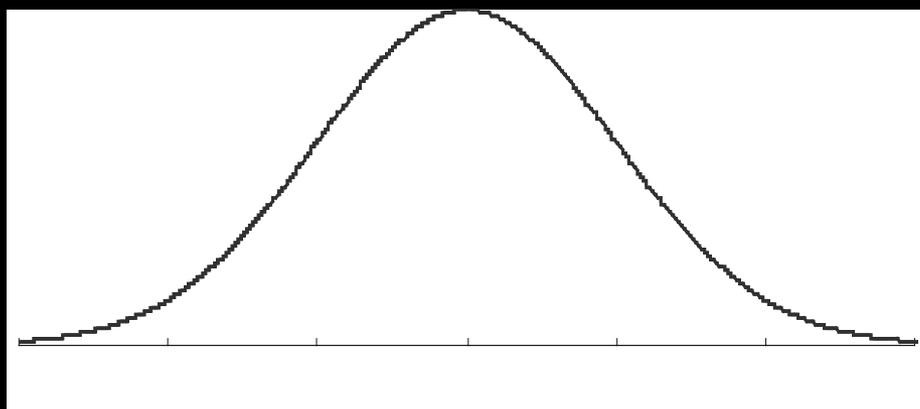
X 取值在区间 $\mu \pm 2.58\sigma$ 上的概率。

$$z_1 = \frac{x_1 - \mu}{\sigma} = \frac{(\mu - 1.96\sigma) - \mu}{\sigma} = -1.96$$

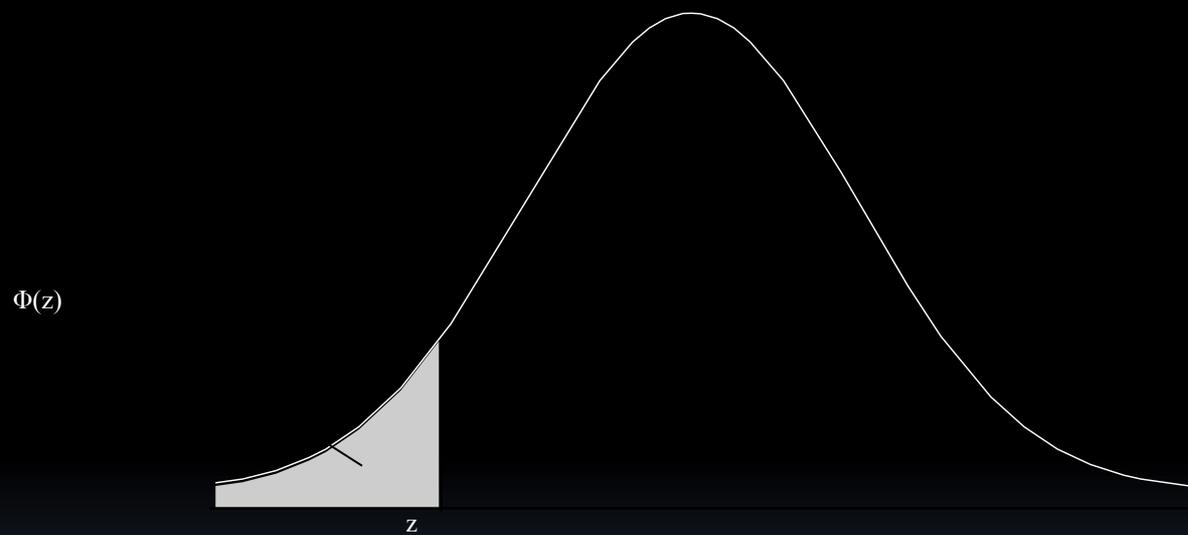
$$z_2 = \frac{x_1 - \mu}{\sigma} = \frac{(\mu + 1.96\sigma) - \mu}{\sigma} = 1.96$$

正态分布

- 正态曲线下面积的分布规律



正态分布



正态分布

- 某地1986年120名8岁男孩身高均数为 $\bar{X}=123.02\text{cm}$ ，标准差为 $S=4.79\text{cm}$ ，试估计
 - (1) 该地8岁男孩身高在130cm以上者占该地8岁男孩总数的百分比
 - (2) 身高在120cm ~ 128cm者占该地8岁男孩总数的百分比;
 - (3) 该地80%的男孩身高集中在哪个范围?

正态分布

- 求Z值:

$$Z = \frac{130 - 123.02}{4.79} = 1.46$$

- 查表:

$$\Phi(-1.46) = 0.0721$$

- 理论上该地8岁男孩身高在130cm以上者占该地8岁男孩总数的7.21%。

正态分布

- 先计算120 和128所对应的Z值

$$z_1 = \frac{120 - \bar{X}}{S} = \frac{120 - 123.02}{4.79} = -0.63$$

$$z_2 = \frac{128 - \bar{X}}{S} = \frac{128 - 123.02}{4.79} = 1.04$$

$$\Phi(-0.63) = 0.2643$$

$$\Phi(1.04) = 1 - \Phi(-1.04) = 1 - 0.1492 = 0.8508$$

- 正态曲线下区间 $(-0.63, 1.04)$ 上的面积等于
 $\Phi(1.04) - \Phi(-0.63) = 0.8508 - 0.2643 = 0.5865$

正态分布

- 80%的8岁男孩身高集中在 $\bar{X} \pm 1.28S$ 区间内，即116.9cm与129.2cm之间。

```
>>> xbar <- mean(x)
```

```
>>> x80 <- xbar + qnorm(c(0.10, 0.90))
```

正态分布

正态分布的应用

(一) 确定医学参考值范围

医学参考值范围(reference ranges):是指特定的“正常”人群数据中大多数个体的取值所在的范围。人们习惯用该人群95%的个体某项医学指标的取值范围作为该指标的医学参考值范围。

正态分布

确定医学参考值范围的方法有两种：

(1) 百分位数法:适用于任何分布型的资料。

双侧95%参考值范围: $(P_{2.5}, P_{97.5})$

单侧范围: P_{95} 以下, (如血铅、发汞),
或 P_5 以上 (如肺活量)。

(2) 正态分布法

$$\bar{X} \pm 1.96S$$

正态分布

- 调查某地120名健康女性血红蛋白，直方图显示，其分布近似于正态分布，

$\bar{X} = 117.4$ (g/L), $S = 10.2$ (g/L), 试估计该地健康女性血红蛋白的95%参考值范围。

因血红蛋白过高、过低均为异常，所以按双侧估计95%医学参考值范围

$$\bar{X} + 1.96S = 117.4 + 1.96 \times 10.2 = 137.9(g/l)$$

$$\bar{X} - 1.96S = 117.4 - 1.96 \times 10.2 = 97.41(g/l)$$