

# 贝叶斯统计

续本达

清华大学 工程物理系

2023-12-13

贝叶斯统计

续本达

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

复习

把样本看作总体的估计，用经验分布函数  $F_n$  估计总体分布函数  $F$   
其它一切统计量都不变。

## 对应关系

$$E_F(\hat{\theta}) \rightarrow E_{F_n}(\hat{\theta}) \xrightarrow{\text{Monte Carlo}} \bar{\theta}^*$$

- $\theta \rightarrow \hat{\theta}$   
 $\hat{\theta}$  是  $F_n$  下的“真值”

## 应用

自助法通过给出统计量的分布估计，可以与点估计、区间估计、假设检验、回归分析、方差分析相结合。

贝叶斯统计

续本达

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

## 二项总体

工物系学生节的魔术节目需要橙子道具。你接到了购买橙子的任务，发现某电商有两家店：

- 溯源店出货 200 件，好评率 97%
- 跃迁店出货 20 年，好评率 100%



问题

- 应该从哪家店购买？哪一家店更可能给你良好的购物体验？

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

- ① 好评数越大越好
- ② 好评率越高越好
- ③ 打分的人越多，好评率越可靠
- ④ 最好能有一种通用规则适用不同人数



- 满足二项分布的问题，可使用“本达指数”
- 假想有额外两位顾客，分别给店铺打“好评”与“差评”。
- 重新算出的好评率，称为本达指数  $B$ 。

$$B = \frac{k + 1}{n + 2}$$

店铺	顾客数 ( $n$ )	好评率	好评数 ( $k$ )	本达指数 ( $B$ )
溯源	200	97%	194	
跃迁	20	100%	20	

-

- 满足二项分布的问题，可使用“本达指数”
- 假想有额外两位顾客，分别给店铺打“好评”与“差评”。
- 重新算出的好评率，称为本达指数  $B$ 。

$$B = \frac{k + 1}{n + 2}$$

店铺	顾客数 ( $n$ )	好评率	好评数 ( $k$ )	本达指数 ( $B$ )
溯源	200	97%	194	0.965
跃迁	20	100%	20	0.955

- 溯源店胜出!



- 满足二项分布的问题，可以使用 本达指数 Laplace 法则
- 假想有额外的两位顾客，分别给店铺打“好评”与“差评”，重新算出好评率，称为 Laplace 指数  $L$

$$L = \frac{k + 1}{n + 2}$$

- Laplace 法则来源于哲学问题：我今年 36 岁，我知道每天太阳都升起了，明天太阳升起的概率是多少？
  - 每一天都是一次 0-1 试验，太阳升起“成功”还是“失败”。过年的 36 年里，试验都成功了。  
 $k = n = 365.25 \times 36 = 13149$
  - 明天太阳升起的概率是

$$\frac{13149 + 1}{13149 + 2} = 99.992\%$$



- 满足二项分布的问题，可以使用 本达指数 Laplace 法则
- 假想有额外的两位顾客，分别给店铺打“好评”与“差评”，重新算出好评率，称为 Laplace 指数  $L$

$$L = \frac{k + 1}{n + 2}$$

- Laplace 法则来源于哲学问题：我今年 36 岁，我知道每天太阳都升起了，明天太阳升起的概率是多少？
  - 每一天都是一次 0-1 试验，太阳升起“成功”还是“失败”。过年的 36 年里，试验都成功了。  
 $k = n = 365.25 \times 36 = 13149$
  - 明天太阳升起的概率是

$$\frac{13149 + 1}{13149 + 2} = 99.992\%$$



贝叶斯统计

续本达

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

# 频率派

## 假设

- 店铺的服务质量不随时间变化，顾客对溯源和跃适打“好评”的概率分别是  $p_A$  和  $p_B$ ,
- 顾客对服务打分时相互独立
- $n$  位顾客给出的“好评”数  $k$  服从二项分布

$$P(k|n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

- 溯源，200 位顾客，其中 194 位顾客给出好评，假设  $p_A = 0.97$ ，那么
  - $P(k = 194) = \binom{200}{194} 0.97^{194} (1-0.97)^6 = 0.16$
  - $P(k \geq 194) = 0.61$
- 跃迁，20 位顾客，其中 20 位顾客给出好评，假设  $p_B = 0.97$ ，那么
  - $P(k = 20) = \binom{20}{20} 0.97^{20} (1-0.97)^0 = 0.54$
  - $P(k \geq 20) = 0.54$

## 假设

- 店铺的服务质量不随时间变化，顾客对溯源和跃适打“好评”的概率分别是  $p_A$  和  $p_B$ ,
- 顾客对服务打分时相互独立
- $n$  位顾客给出的“好评”数  $k$  服从二项分布

$$P(k|n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

- 溯源，200 位顾客，其中 194 位顾客给出好评，假设  $p_A = 0.97$ ，那么
  - $P(k = 194) = \binom{200}{194} 0.97^{194} (1-0.97)^6 = 0.16$
  - $P(k \geq 194) = 0.61$
- 跃迁，20 位顾客，其中 20 位顾客给出好评，假设  $p_B = 0.97$ ，那么
  - $P(k = 20) = \binom{20}{20} 0.97^{20} (1-0.97)^0 = 0.54$
  - $P(k \geq 20) = 0.54$

复习

二项总体


频率派

贝叶斯方法

模型选择

总结

```
par(mfrow = c(1, 2))
k <- seq(180, 200)
plot(k, dbinom(k, 200, 0.97), type='h', ylab="概率", main="n=200, p=0.97")
k <- seq(13, 20)
plot(k, dbinom(k, 20, 0.97), type='h', ylab="概率", main="n=20, p=0.97")
```



试验次数不同，分布的形状差异明显。综合考虑很难。

- 比较  $p_A$  和  $p_B$  的最大似然估计：
  - $\hat{p}_A = 0.97, \hat{p}_B = 1$ , 与 Laplace 法则的结论相反
- 比较  $p_A$  和  $p_B$  的区间估计, 对  $p_A \geq p_B$  进行假设检验：
  - 二项分布的置信区间不对称, 当  $n$  较小时, 难以找到枢轴量, 无简洁的构造方法

## 0-1 分布参数的区间估计

从一个 0-1 总体, 获得一个容量为  $n$  的样本, 那么成功次数  $k$  是二项分布。

- 由中心极限定理,  $n$  较大时, 可构造枢轴量:

$$\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}} = \frac{n\bar{X} - np}{\sqrt{np(1-p)}} \sim N(0, 1)$$

- 根据  $z$  统计量构造  $p$  的置信区间。

我们学习的区间估计和假设检验方法围绕正态总体构造。离开正态总体遇到困难。

- 比较  $p_A$  和  $p_B$  的最大似然估计：
  - $\hat{p}_A = 0.97, \hat{p}_B = 1$ , 与 Laplace 法则的结论相反
- 比较  $p_A$  和  $p_B$  的区间估计, 对  $p_A \geq p_B$  进行假设检验：
  - 二项分布的置信区间不对称, 当  $n$  较小时, 难以找到枢轴量, 无简洁的构造方法

## 0-1 分布参数的区间估计

从一个 0-1 总体, 获得一个容量为  $n$  的样本, 那么成功次数  $k$  是二项分布。

- 由中心极限定理,  $n$  较大时, 可构造枢轴量:

$$\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}} = \frac{n\bar{X} - np}{\sqrt{np(1-p)}} \sim N(0, 1)$$

- 根据  $z$  统计量构造  $p$  的置信区间。

我们学习的区间估计和假设检验方法围绕正态总体构造。离开正态总体遇到困难。



- 比较  $p_A$  和  $p_B$  的最大似然估计：
  - $\hat{p}_A = 0.97, \hat{p}_B = 1$ , 与 Laplace 法则的结论相反
- 比较  $p_A$  和  $p_B$  的区间估计, 对  $p_A \geq p_B$  进行假设检验：
  - 二项分布的置信区间不对称, 当  $n$  较小时, 难以找到枢轴量, 无简洁的构造方法

## 0-1 分布参数的区间估计

从一个 0-1 总体, 获得一个容量为  $n$  的样本, 那么成功次数  $k$  是二项分布。

- 由中心极限定理,  $n$  较大时, 可构造枢轴量:

$$\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}} = \frac{n\bar{X} - np}{\sqrt{np(1-p)}} \sim N(0, 1)$$

- 根据  $z$  统计量构造  $p$  的置信区间。

我们学习的区间估计和假设检验方法围绕正态总体构造。离开正态总体遇到困难。

- 比较  $p_A$  和  $p_B$  的最大似然估计：
  - $\hat{p}_A = 0.97, \hat{p}_B = 1$ , 与 Laplace 法则的结论相反
- 比较  $p_A$  和  $p_B$  的区间估计, 对  $p_A \geq p_B$  进行假设检验：
  - 二项分布的置信区间不对称, 当  $n$  较小时, 难以找到枢轴量, 无简洁的构造方法

## 0-1 分布参数的区间估计

从一个 0-1 总体, 获得一个容量为  $n$  的样本, 那么成功次数  $k$  是二项分布。

- 由中心极限定理,  $n$  较大时, 可构造枢轴量:

$$\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}} = \frac{n\bar{X} - np}{\sqrt{np(1-p)}} \sim N(0, 1)$$

- 根据  $z$  统计量构造  $p$  的置信区间。

我们学习的区间估计和假设检验方法围绕正态总体构造。离开正态总体遇到困难。

- 0-1 总体，容量为 200 的样本，194 个 1，6 个 0
  - bootstrap 是从  $B(200, 0.97)$  采样。
- 容量为 20 的样本，20 个 1。
  - bootstrap 是从  $B(20, 1)$  采样。
- 可见 bootstrap 方法等价于最大似然估计，仍无法解决非正态分布的问题。

- 0-1 总体，容量为 200 的样本，194 个 1，6 个 0
  - bootstrap 是从  $B(200, 0.97)$  采样。
- 容量为 20 的样本，20 个 1。
  - bootstrap 是从  $B(20, 1)$  采样。
- 可见 bootstrap 方法等价于最大似然估计，仍无法解决非正态分布的问题。

- 0-1 总体，容量为 200 的样本，194 个 1，6 个 0
  - bootstrap 是从  $B(200, 0.97)$  采样。
- 容量为 20 的样本，20 个 1。
  - bootstrap 是从  $B(20, 1)$  采样。
- 可见 bootstrap 方法等价于最大似然估计，仍无法解决非正态分布的问题。

贝叶斯统计

续本达

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

# 贝叶斯方法

- Laplace 在 18 世纪回答一个哲学问题
  - 明天我见到太阳从东方升起的概率是多少?
- 把太阳升起与否看成 Bernoulli 实验
  - 明日见日的概率是 Bernoulli 实验的成功率  $p$
  - 如何合理估算  $p$ ?
- 关键问题:  $p$  是不是随机变量?
  - 贝叶斯派: 是
  - 频率派: 不是

- Laplace 在 18 世纪回答一个哲学问题
  - 明天我见到太阳从东方升起的概率是多少?
- 把太阳升起与否看成 Bernoulli 实验
  - 明日见日的概率是 Bernoulli 实验的成功率  $p$
  - 如何合理估算  $p$ ?
- 关键问题:  $p$  是不是随机变量?
  - 贝叶斯派: 是
  - 频率派: 不是



- Laplace 在 18 世纪回答一个哲学问题
  - 明天我见到太阳从东方升起的概率是多少?
- 把太阳升起与否看成 Bernoulli 实验
  - 明日见日的概率是 Bernoulli 实验的成功率  $p$
  - 如何合理估算  $p$ ?
- 关键问题:  $p$  是不是随机变量?
  - 贝叶斯派: 是
  - 频率派: 不是

- $n$  次  $p$  成功率的 Bernoulli 实验的成功次数  $k$ , 满足二项分布

$$P(k|n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

- 把  $p$  看成随机变量, 按贝叶斯公式,

$$P(p|k, n) = \frac{P(k|p, n)P(p|n)}{P(k|n)}$$

- $P(p|n)$  是  $p$  的 先验分布
- $P(p|k, n)$  是  $p$  的 后验分布
- $P(k|p, n)$  是  $p$  的 似然函数
- $P(k|n)$  叫做 evidence
- 当先验分布  $P(p|n) \equiv 1$  时,  $p$  作为随机变量的后验分布为

$$P(p|k, n) \propto P(k|p, n) \propto p^k (1-p)^{n-k} \sim \text{Beta}(k+1, n-k+1)$$

服从贝塔分布。

- $n$  次  $p$  成功率的 Bernoulli 实验的成功次数  $k$ , 满足二项分布

$$P(k|n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

- 把  $p$  看成随机变量, 按贝叶斯公式,

$$P(p|k, n) = \frac{P(k|p, n)P(p|n)}{P(k|n)}$$

- $P(p|n)$  是  $p$  的 **先验分布**
- $P(p|k, n)$  是  $p$  的 **后验分布**
- $P(k|p, n)$  是  $p$  的 **似然函数**
- $P(k|n)$  叫做 **evidence**
- 当先验分布  $P(p|n) \equiv 1$  时,  $p$  作为随机变量的后验分布为

$$P(p|k, n) \propto P(k|p, n) \propto p^k (1-p)^{n-k} \sim \text{Beta}(k+1, n-k+1)$$

服从贝塔分布。

- $n$  次  $p$  成功率的 Bernoulli 实验的成功次数  $k$ , 满足二项分布

$$P(k|n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

- 把  $p$  看成随机变量, 按贝叶斯公式,

$$P(p|k, n) = \frac{P(k|p, n)P(p|n)}{P(k|n)}$$

- $P(p|n)$  是  $p$  的 **先验分布**
- $P(p|k, n)$  是  $p$  的 **后验分布**
- $P(k|p, n)$  是  $p$  的 **似然函数**
- $P(k|n)$  叫做 **evidence**
- 当先验分布  $P(p|n) \equiv 1$  时,  $p$  作为随机变量的后验分布为


$$P(p|k, n) \propto P(k|p, n) \propto p^k (1-p)^{n-k} \sim \text{Beta}(k+1, n-k+1)$$

服从贝塔分布。

```

library(ggplot2)
d <- data.frame(店铺=c("跃迁", "溯源"), 顾客数=c(20, 200), 好评率=c(1, 0.97))
d$好评数 <- d$顾客数 * d$好评率
post <- data.frame()
x <- seq(0.8, 1, 0.001)
for (i in 1:2) {
  post <- rbind(post, rbind(data.frame(p=x, 店铺=d$店铺[i], 值="概率密度",
                                     value=dbeta(x, d$好评数[i] + 1, d$顾客数[i] - d$好评数[i] + 1)),
                           data.frame(p=x, 店铺=d$店铺[i], 值="分布函数",
                                     value=pbeta(x, d$好评数[i] + 1, d$顾客数[i] - d$好评数[i] + 1))))}
p <- ggplot(post, aes(x=p, y=value, color=店铺)) + geom_line() + ggtitle("店铺好评率的后验分布")
print(p + ylab("") + facet_wrap(~值, scales="free_y"))

```



取后验分布的期望，是贝叶斯参数的一样点估计方法

$$p \sim \text{Beta}(a, b), p \in [0, 1]$$

有  $E(p) = \frac{a}{a+b} = \frac{k+1}{n+2}$ ，即 Laplace 指数。

- 溯源店  $p_A$

$$\hat{p}_A = E(p_A) = 0.965$$

- 跃迁店  $p_B$

$$\hat{p}_B = E(p_B) = 0.955$$

后验期望估计是 Laplace 法则的数学依据。

取后验分布的期望，是贝叶斯参数的一样点估计方法

$$p \sim \text{Beta}(a, b), p \in [0, 1]$$

有  $E(p) = \frac{a}{a+b} = \frac{k+1}{n+2}$ ，即 Laplace 指数。

- 溯源店  $p_A$

$$\hat{p}_A = E(p_A) = 0.965$$

- 跃迁店  $p_B$

$$\hat{p}_B = E(p_B) = 0.955$$

后验期望估计是 Laplace 法则的数学依据。

- 贝叶斯的区间估计里，直接使用参数的后验分布，不必构造枢轴量
  - ① 选取枢轴量
  - ② 由分位点定义建立不等式
  - ③ 解出不等式

```
qbeta(1-0.9, 195, 7)  
qbeta(1-0.9, 21, 1)
```

```
[1] 0.9481917  
[1] 0.8961505
```

- 溯源店  $p_A$  的 90% 置信区间为  $[0.95, 1]$
- 跃迁店  $p_B$  的 90% 置信区间为  $[0.90, 1]$



贝叶斯统计

续本达

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

## 模型选择

- 大多数情况下，参数  $\theta$  的后验分布无法解析表达，

$$P(\theta|D, H) = \frac{P(D|\theta, H)P(\theta|H)}{P(D|H)}$$

其中  $H$  代表理论假设， $D$  代表数据。

- $P(D|H)$  是最难计算的

$$P(D|H) = \int P(D|\theta, H)P(\theta|H)d\theta$$

- 它与  $\theta$  无关，通过从  $P(\theta|D, H) \propto P(D|\theta, H)P(\theta|H)$  采样取得一组  $\{\theta_i\}$ ，使用马尔可夫链法进行
- 可构造 后验期望估计量

$$E(\theta) = \bar{\theta}$$

- 可用  $\{\theta_i\}$  的样本分位数构造  $\theta$  后验分布的区间

- 考虑贝叶斯公式的先验分布  $P(\theta|H)$ ，如果  $H$  本身也可以两种可能  $H_0$ ,  $H_1$ 。
- 同样可以通过数据进行假设检验，也叫作 **模型选择**

$$P(H_i|D) = \frac{P(D|H_i)P(H_i)}{P(D|H_0)P(H_0) + P(D|H_1)P(H_1)}$$

- $P(D|H_i)$  的积分较难计算，可使用马尔可夫链蒙特卡罗法完成。

贝叶斯统计

续本达

复习

二项总体

频率派

贝叶斯方法

模型选择

总结

# 总结

### 贝叶斯学派

“好评率”是随机变量  
概率依赖人的认知  
需要先验知识  
计算复杂  
无需正态假设  
18 世纪出现  
21 世纪被广泛使用

### 频率学派

“好评率”是常数  
概率是假想重复实验的平均  
不需要先验知识  
计算相对简单  
大多依赖正态假设  
20 世纪由概率论公理化成为主流

- 学术界从频率派死忠向“哪个好用就用哪个”的骑墙派转变

Forecasting neutrino masses from combining KATRIN and the CMB observations: Frequentist and Bayesian analyses

Ole Host, Ofer Lahav, Filipe B. Abdalla, and Klaus Eitel  
Phys. Rev. D **76**, 113005 – Published 27 December 2007

- 在偏离正态总体时，两种方法往往给出不同结果
  - 例如，中微子质量不能为负，参数空间有界，正态假设不成立。
- 有学者开始同时使用两种方法，由读者自己选择。