
统计模拟和实证分析介绍

秦永松

(广西师范大学 数学与统计学院, 广西 桂林 541006)

我们在此简单介绍基于模型(model-based)的统计方法的统计模拟和实证分析, 统计模拟和实证分析不仅仅局限于基于模型的统计方法, 但基于模型的统计方法是数理统计的最大分支。在假定已有数据满足模型的前提下, 对模型参数(未知量)进行估计或者对模型涉及的统计假设进行检验, 这就是数理统计的理论(简称统计理论)或者方法。统计模拟就是依据设定的统计模型, 通过计算机模拟相应的数据, 并依据统计理论的结果, 计算模拟数据下的结果并由此检验统计方法的性能或者优劣, 其道理完全等同于物理或者化学实验, 不同的是物理和化学实验是在实验室通过实物材料进行操作(比如甲醇制作芳烃的实验), 统计模拟是利用计算机软件(常用的有R和Matlab)进行操作, 所以统计模拟又可以称为统计实验; 实证分析是在已有实际数据的情况下, 利用统计理论结果, 代入公式, 给出实际数据下的结论。

1 基于正态逼近的方法

统计理论

定理1 (基于正态逼近方法). 设总体 $X \in R$ 的期望(设为 μ)和方差均存在, X_1, X_2, \dots, X_n 为其简单随机样本, 则 μ 的(一个)矩估计为

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i,$$

且由中心极限定理知, 当 $n \rightarrow \infty$ 时, 有

$$\sqrt{n}(\hat{\mu} - \mu)/s \xrightarrow{d} N(0, 1),$$

其中, s^2 为样本方差, 即 $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$. 由此得到 μ 的置信水平为 $1 - \alpha$ ($0 < \alpha < 1$)的渐近置信区间为

$$[\bar{X} - su_{1-\alpha/2}/\sqrt{n}, \bar{X} + su_{1-\alpha/2}/\sqrt{n}],$$

其中, $u_{1-\alpha/2}$ 为 $N(0, 1)$ 的 $1 - \frac{\alpha}{2}$ 分位数。

统计模拟

下面用统计实验证实上述理论。

1. 点估计 $\hat{\mu}$ 的优劣

在模型条件“总体 $X \in R$ 的期望(设为 μ)和方差均存在, X_1, X_2, \dots, X_n 为其简单随机样本”下, 独立重复生成 $m(= 1,000)$ 个随机样本: $X_{k1}, X_{k2}, \dots, X_{kn}, k = 1, 2, \dots, m$ 。有以下几个衡量估计优劣的标准:

- Mean: $M = \frac{1}{m} \sum_{k=1}^m \bar{X}_k$, 其中, $\bar{X}_k = \frac{1}{n} \sum_{i=1}^n X_{ki}, k = 1, 2, \dots, m$;
 - Empirical Bias: $M - \mu_0$, 其中, μ_0 为总体均值(取样前设定);
-

-
- c. Empirical 标准差(E-SD): $\bar{X}_k, k = 1, 2, \dots, m$ 的标准差, 即 $E-SD = \left\{ \frac{1}{m-1} \sum_{k=1}^m (\bar{X}_k - M)^2 \right\}^{1/2}$;
- d. Empirical root mean square error (RMSE): $E-RMSE = \left\{ \frac{1}{m-1} \sum_{k=1}^m (\bar{X}_k - \mu_0)^2 \right\}^{1/2}$ 。
- R 程序举例: 取 $\mu_0 = 10$, 总体设为正态分布 $N(\mu_0, 2)$, 样本容量 $n = 100$, 重复次数 $m = 1000$:

```

n = 100
nsim = 1000
m = 1
y = rep(0, nsim)
for(m in 1 : nsim){
  x = rnorm(n = 100, mean = 10, sd = sqrt(2))
  y[m] = sum(x)/n
  m = m + 1
}
Mean = sum(y)/nsim
Bias = Mean - 10
SD = sqrt(sum(y - Mean)^2/(nsim - 1))
RMSE = sqrt(sum(y - 10)^2/(nsim - 1))
Mean
Bias
SD
RMSE

```

Mean 9.999951, Bias -4.92973e-05, SD 6.23836e-15, RMSE 0.001559698

为了使模拟结果更有说服力, 可以加大模拟量, 比如, 样本容量可以变化, 总体均值可以变化, 总体分布可以变化, 等等。

2. 区间估计的优劣

覆盖概率(CP) 和区间长度 (AL) 两个指标:

a. 覆盖概率: $CP = m$ 次模拟中真值 μ_0 落在区间 $[\bar{X} - su_{1-\alpha/2}/\sqrt{n}, \bar{X} + su_{1-\alpha/2}/\sqrt{n}]$ 内的频率;

b. 区间 (平均) 长度: $AL = m$ 个区间的平均长度 = $2 (\sum_{k=1}^m s_k u_{1-\alpha/2}/n) / m$, 其中 s_k 为第 k 次模拟的样本标准差。

R 程序举例: 取 $\mu_0 = 10$, 总体设为正态分布 $N(\mu_0, 2)$, $\alpha = 0.05$, 样本容量 $n = 100$, 重复次数 $m = 1000$:

```

n = 100
nsim = 1000
mu0 = 10
m = 1
CP = 0

```

```

AL = 0
for(m in 1 : nsim){
  x = rnorm(n = 100, mean = mu0, sd = sqrt(2))
  bar = sum(x)/n
  t0 = sum((x - bar)^2)/(n - 1)
  temp = sqrt(t0) * 1.96/sqrt(n)
  if(bar - temp <= mu0 & mu0 <= bar + temp)CP = CP + 1
  AL = AL + 2 * temp
  m = m + 1
}
CP = CP/nsim
AL = AL/nsim
CP
AL

```

模拟结果如下：

CP 0.955, AL 0.5523

3. Q-Q 图

检验 $\sqrt{n}(\hat{\mu} - \mu)/s \xrightarrow{d} N(0, 1)$ 结论的正确性，可用Q-Q图表示。

R 程序举例：取 $\mu_0 = 10$ ，总体设为正态分布 $N(\mu_0, 2)$ ，样本容量 $n = 100$ ，重复次数 $m = 1000$ ：

```

n = 100
nsim = 1000
mu0 = 10
m = 1
T = rep(0, nsim)
for(m in 1 : nsim){
  x = rnorm(n = 100, mean = mu0, sd = sqrt(2))
  bar = sum(x)/n
  t0 = sum((x - bar)^2)/(n - 1)
  T[m] = sqrt(n) * (bar - mu0)/sqrt(t0)
  m = m + 1
}
qqnorm(T); qqline(T, col = 2)

```

2 基于经验似然方法（单总体情形）

统计理论

定理2 (基于经验似然方法) . 设总体 $X \in R$ 的期望(设为 μ)和方差均存在, X_1, X_2, \dots, X_n 为其简单随机样本, 则 μ 的经验似然比统计量为

$$\ell(\mu) = 2 \sum_{i=1}^n \log\{1 + m \cdot (X_i - \mu)\},$$

其中, $m = m(\mu)$ 满足

$$\frac{1}{n} \sum_{i=1}^n \frac{X_i - \mu}{1 + m(X_i - \mu)} = 0$$

且

$$\ell(\mu) \xrightarrow{d} \chi_1^2,$$

其中, χ_1^2 表示自由度为1 的服从卡方分布的随机变量。由此得到 μ 的置信水平为 $1 - \alpha$ ($0 < \alpha < 1$) 的渐近置信区间为

$$\{\mu : \ell(\mu) \leq \chi_1^2(1 - \alpha)\},$$

其中, $\chi_1^2(1 - \alpha)$ 为 χ_1^2 的 $1 - \alpha$ 分位数。

统计模拟

下面用统计实验证实上述理论。

在模型条件“总体 $X \in R$ 的期望(设为 μ)和方差均存在, X_1, X_2, \dots, X_n 为其简单随机样本”下, 独立重复生成 $m(= 1,000)$ 个随机样本: $X_{k1}, X_{k2}, \dots, X_{kn}, k = 1, 2, \dots, m$ 。

1. 区间估计的优劣

覆盖概率(CP) 和区间长度(AL) 两个指标。

R 程序举例: 取 $\mu_0 = 10$, 总体设为正态分布 $N(\mu_0, 2)$, $\alpha = 0.05$, 样本容量 $n = 100$, 重复次数 $m = 1000$ 。

注: 程序中的 $< -$ 表示赋值, 等同于 $=$ 。

```
lambda <- function(x, mu)
{
  L = -1/max(x - mu)
  R = -1/min(x - mu)
  dif <- -1
  tol <- -1e - 08
  while(dif > tol){
    M <- -(L + R)/2
    glam <- -sum((x - mu)/(1 + M * (x - mu)))
    if(glam > 0)L <- -M
```

```
if(glam < 0)R < -M
dif < -abs(glam)
}
return(M)
}
nsim < -1000
a < -0.95
cut < -qchisq(a, 1)
mu0 = 10
f < -0
L < -0
U < -0
m = 1
for(m in 1 : nsim){
x < -rnorm(n = 100, mean = mu0, sd = sqrt(2))
tol < -1e - 08
t1 < -mean(x)
t2 < -max(x)
dif < -t2 - t1
while(dif > tol){
tau < -(t1 + t2)/2
M < -lambda(x, tau)
elratio < -2 * sum(log(1 + M * (x - tau)))
if(elratio > cut)t2 < -tau
if(elratio <= cut)t1 < -tau
dif < -t2 - t1
}
UB < -(t1 + t2)/2
t1 < -mean(x)
t2 < -min(x)
dif < -t1 - t2
while(dif > tol){
tau < -(t1 + t2)/2
M < -lambda(x, tau)
elratio < -2 * sum(log(1 + M * (x - tau)))
if(elratio > cut)t2 < -tau
```

```

if(elratio <= cut)t1 < -tau
dif < -t1 - t2
}
LB < -(t1 + t2)/2
el < -2 * sum(log(1 + lambda(x, mu0) * (x - mu0)))
if(el <= cut)f = f + 1
L = LB + L
U = UB + U
m = m + 1
}
fL = L/nsim
fU = U/nsim
CP = f/nsim
AL = fU - fL
fL
fU
CP
AL

```

(1)

模拟结果如下：

置信区间[9.72797, 10.28292], CP 0.946, AL 0.554955

2. Q-Q 图

检验 $\ell(\mu) \xrightarrow{d} \chi_1^2$ 结论的正确性，可用Q-Q图表示。

R 程序举例：取 $\mu_0 = 10$ ，总体设为正态分布 $N(\mu_0, 2)$ ， $\alpha = 0.05$ ，样本容量 $n = 100$ ，重复次数 $m = 1000$ 。

```

lambda < -function(x, mu)
{
L < - - 1/max(x - mu)
R < - - 1/min(x - mu)
dif < -1
tol < -1e - 08
while(dif > tol){
M < -(L + R)/2
glam < -sum((x - mu)/(1 + M * (x - mu)))
if(glam > 0)L < -M
if(glam < 0)R < -M
}
}

```

```

dif < -abs(glam)
}
return(M)
}
n = 100
mu0 = 10
nsim < -1000
T = rep(0, nsim)
m = 1
for(m in 1 : nsim){
x = rnorm(n = 100, mean = mu0, sd = sqrt(2))
T[m] = 2 * sum(log(1 + lambda(x, mu0) * (x - mu0)))
m = m + 1
}
qqplot(qchisq(ppoints(1000), df = 1), T,
main = expression(Q - Q plot for  $\chi^2[nu == 1]$ ))
qqline(T, distribution = function(p)qchisq(p, df = 1),
probs = c(0.1, 0.6), col = 2)

```

3 基于经验似然方法（线性模型）

统计理论

定理3 (线性模型中的经验似然方法) . 设有线性模型

$$Y_i = X_i' \beta + \epsilon_i, 1 \leq i \leq n,$$

其中, $\beta \in R^k$, $\{\epsilon_i, 1 \leq i \leq n\}$ 为均值为0 且3 阶矩有限的独立随机变量序列, 则 β 的经验似然比统计量为

$$\ell(\beta) = 2 \sum_{i=1}^n \log\{1 + m'(\beta) X_i (Y_i - X_i' \beta)\},$$

其中, $m = m(\beta)$ 满足

$$\frac{1}{n} \sum_{i=1}^n \frac{X_i (Y_i - X_i' \beta)}{m'(\beta) X_i (Y_i - X_i' \beta)} = 0$$

则在一定的正则条件下, 当 $n \rightarrow \infty$ 时, 有

$$\ell(\beta) \xrightarrow{d} \chi_k^2,$$

其中, χ_k^2 表示自由度为 k 的服从卡方分布的随机变量。由此得到 β 的置信水平为 $1 - \alpha$ ($0 < \alpha < 1$)

的渐近置信区间为

$$\{\beta : \ell(\beta) \leq \chi_k^2(1 - \alpha)\},$$

其中, $\chi_k^2(1 - \alpha)$ 为 χ_k^2 的 $1 - \alpha$ 分位数。

统计模拟

下面用统计实验证实上述理论。

1. 区间估计的优劣

覆盖概率(CP)

R 程序举例: 取 $\epsilon \sim U(-0.5, 0.5)$, $\alpha = 0.05$, 样本容量 $n = 200$, 重复次数 $m = 1000$ 。

注: 程序中的 $<-$ 表示赋值, 等同于 $=$ 。

```
lambda <- function(u){
  M <- -c(0,0)
  dif <- -1
  tol <- -1e - 8
  k <- -0
  while(dif > tol & k <= 15){
    D1 <- -c(0,0)
    DD <- -D1% * %t(D1)
    for(i in 1 : n){
      aa <- -as.numeric(1 + t(M)% * %u[i,])
      D1 <- -D1 + u[i,]/aa
      DD <- -DD - (u[i,]% * %t(u[i,]))/aa^2
    }
    D2 <- -solve(DD, D1, tol = 1e - 8)
    dif <- -max(abs(D2))
    rule <- -1
    while(rule > 0){
      rule <- -0
      if(min(1 + t(M - D2)% * %t(u)) <= 0)rule <- -rule + 1
      if(rule > 0)D2 <- -D2/2
    }
    M <- -M - D2
    k <- -k + 1}
  if(k >= 15)M <- -c(0,0)
  return(M)
}
```

```

nsim = 1000
a < -0.95
k < -2
n = 200
cut < -qchisq(a, k)
beta = c(0, 1)
f < -0
m = 1
for(m in 1 : nsim){
x0 < -rnorm(n)
x1 < -c(x0, x0^2)
x = matrix(x1, nrow = n, ncol = 2)
e = runif(n, -0.5, 0.5)
e = t(t(e))
y = x%*%beta + e
el = 0
z = matrix(rep(0, 2 * n), nrow = n, ncol = 2)
i = 1
for(i in 1 : n){
z[i,] = x[i,] * e[i]
i = i + 1
}
lam = lambda(z)
for(i in 1 : n){
el = el + 2 * log(1 + t(lam)%*%x[i,] * e[i])
i = i + 1
}
if(el <= cut)f = f + 1
m = m + 1
}
CP = f/nsim
CP

```

模拟结果如下：

CP 0.937

2. Q-Q 图

检验 $\ell(\beta) \xrightarrow{d} \chi_k^2$ 结论的正确性，可用Q-Q图表示。

R 程序举例：取 $\epsilon \sim U(-0.5, 0.5)$ ，样本容量 $n = 200$ ，重复次数 $m = 1000$ 。

```
lambda <- function(u){
  M <- -c(0,0)
  dif <- -1
  tol <- -1e-8
  k <- -0
  while(dif > tol & k <= 15){
    D1 <- -c(0,0)
    DD <- -D1%*%t(D1)
    for(i in 1:n){
      aa <- -as.numeric(1 + t(M)%*%u[i,])
      D1 <- -D1 + u[i,]/aa
      DD <- -DD - (u[i,]%*%t(u[i,]))/aa^2
    }
    D2 <- -solve(DD, D1, tol = 1e-8)
    dif <- -max(abs(D2))
    rule <- -1
    while(rule > 0){
      rule <- -0
      if(min(1 + t(M - D2)%*%t(u)) <= 0)rule <- -rule + 1
      if(rule > 0)D2 <- -D2/2
    }
    M <- -M - D2
    k <- -k + 1}
  if(k >= 15)M <- -c(0,0)
  return(M)
}
nsim = 1000
k <- -2
n = 200
beta = c(0,1)
T = rep(0, nsim)
m = 1
for(m in 1:nsim){
  x0 <- -rnorm(n)
  x1 <- -c(x0, x0^2)
```

```
x = matrix(x1, nrow = n, ncol = 2)
e = runif(n, -0.5, 0.5)
e = t(t(e))
y = x% * %beta + e
el = 0
z = matrix(rep(0, 2 * n), nrow = n, ncol = 2)
i = 1
for(i in 1 : n){
z[i,] = x[i,] * e[i]
i = i + 1
}
lam = lambda(z)
for(i in 1 : n){
el = el + 2 * log(1 + t(lam)% * %x[i,] * e[i])
i = i + 1
}
T[m] = el
m = m + 1
}
qqplot(qchisq(ppoints(1000), df = 2), T,
main = expression("Q - Qplot for" chi^2[nu == 2]))
qqline(T, distribution = function(p)qchisq(p, df = 2),
probs = c(0.1, 0.6), col = 2)
```
