

Lecture 6: 统计推断中的Monte Carlo 方法

张伟平

Monday 12th October, 2009

Contents

1	Monte Carlo Methods in Inference	1
1.1	Monte Carlo Methods for Estimation	1
1.1.1	Monte Carlo Estimation and Standard Error	2
1.1.2	Estimation of MSE	5
1.2	Estimating a confidence level	10
1.3	Monte Carlo Methods for Hypothesis Tests	16
1.4	Empirical Type I error rate	17
1.4.1	Power of a Test	24
1.4.2	Power Comparisons	30
1.5	Application: “Count Five” Test for Equal Variance	34

Chapter 1

Monte Carlo Methods in Inference

Monte Carlo方法可以指统计推断或者数值分析中任何使用随机数模拟的方法. 本章 我们讨论一些统计推断中的Monte Carlo方法. Monte Carlo方法可以用于估计统计量分布 中的参数, 均方误差, 分位数等, 也可以用于估计置信区间覆盖真实参数的概率(置信水平), 假设检验中检验的一型错误率, 功效等等.

1.1 Monte Carlo Methods for Estimation

假设 X_1, \dots, X_n 为从总体 X 中抽取的随机样本, 参数 θ 的估计量记为

$$\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$$

记 $x = (x_1, \dots, x_n)^T \in \mathcal{R}^n$, 以及 $x^{(1)}, x^{(2)}, \dots$ 为从总体 X 中抽取的一系列独立的随机样本观测值. 则有关于 $\hat{\theta}$ 的性质, 可以通过估计值序列 $\hat{\theta}(x_1^{(j)}, \dots, x_n^{(j)})$, $j = 1, 2, \dots$ 来研究.

1.1.1 Monte Carlo Estimation and Standard Error

例 1: 假设 $X_1, X_2 \text{ i.i.d. } \sim N(0, 1)$, 估计 $E|X_1 - X_2|$.

显然, $\theta = E|X_1 - X_2|$ 的 Monte Carlo 估计可用通过从标准正态分布中产生 m 个样本 $x^{(j)} = (x_1^{(j)}, x_2^{(j)})$, $j = 1, \dots, m$. 然后计算 $\hat{\theta}^{(j)} = |x_1^{(j)} - x_2^{(j)}|$, $j = 1, \dots, m$. 以及 θ 的估计

$$\hat{\theta} = \frac{1}{m} \sum_{j=1}^m \hat{\theta}^{(j)} = \frac{1}{m} \sum_{j=1}^m |x_1^{(j)} - x_2^{(j)}|.$$

在 \mathbf{R} 中很容易实现:

```
m <- 1000
```

[↑ Code](#)

```
g <- numeric(m)
for (i in 1:m) {
  x <- rnorm(2)
  g[i] <- abs(x[1] - x[2])
}
est <- mean(g)
est
```

[↓Code](#)

我们也可以计算出 $E|X_1 - X_2| = 2/\sqrt{\pi} \doteq 1.128379$ 以及方差 $Var(|X_1 - X_2|) = 2 - 4/\pi$. 因此 $E\hat{\theta} = 2/\sqrt{\pi}, Var(\hat{\theta}) = [2 - 4/\pi]/m$.

对标准差的Monte Carlo 估计我们可以从一般场合出发讨论. 由于样本量为 n 的样本均值 \bar{X} 的标准差为 $\sqrt{Var(X)/m}$, 当 X 的分布未知时, 可以使用”Plug-in”法估计: 由

$$\hat{Var}(X) = \frac{1}{m} \sum_{i=1}^m (x_i - \bar{x})^2.$$

因此 \bar{x} 标准差的估计为

$$\hat{se}(\bar{x}) = \frac{1}{\sqrt{m}} \left[\frac{1}{m} (x_i - \bar{x})^2 \right]^{1/2} = \frac{1}{m} [(x_i - \bar{x})^2]^{1/2}.$$

或者也可以使用无偏估计量

$$\hat{se}(\bar{x}) = \frac{1}{\sqrt{m}} \left[\frac{1}{m-1} (x_i - \bar{x})^2 \right]^{1/2}.$$

因此, 前例中的标准差估计为

$$\hat{se}(\hat{\theta}) = \frac{1}{m} \left[\sum_{j=1}^m (\hat{\theta}^{(j)} - \hat{\theta})^2 \right].$$

计算程序如下

```
sqrt(sum((g-mean(g))^2))/m  
#sd(g)/sqrt(m) #for unbiased estimator
```

[↑Code](#)

[↓Code](#)

1.1.2 Estimation of MSE

Monte Carlo 方法可以用于计算一个估计量的MSE. 一个估计量的MSE定义为 $MSE(\hat{\theta}) = E[\hat{\theta} - \theta]^2$. 如果从总体 X 中产生了 m 个样本 $x^{(1)}, \dots, x^{(m)}$, 则 $\hat{\theta}$ 的MSE的Monte Carlo估计为

$$M\hat{S}E = \frac{1}{m} \sum_{j=1}^m (\hat{\theta}^{(j)} - \theta)^2,$$

其中 $\hat{\theta}^{(j)} = \hat{\theta}(x^{(j)})$.

例 2: 使用Monte Carlo方法估计标准正态分布的截尾均值 $\bar{X}_{[-1]}$ 的MSE.

当样本存在异常点时, 截尾的样本均值常常被用来估计总体的中心. 假设 X_1, \dots, X_n 为一个随机样本, $X_{(1)}, \dots, X_{(n)}$ 为相应的次序统计量, 则一个 k 水平的截尾样本均值为

$$\bar{X}_{[-k]} = \frac{1}{n - 2k} \sum_{i=k+1}^{n-k} X_{(i)}.$$

本例中, 目标参数为 $\theta = E\bar{X} = E\bar{X}_{[-1]} = 0$. 记 $T = \bar{X}_{[-1]}$, 则其MSE的一个 Monte Carlo 估计算法如下

1. 通过如下步骤产生 m 个重复 $T^{(j)}, j = 1, \dots, m$:

- 产生总体 X 的样本: $x_1^{(j)}, \dots, x_n^{(j)}$.
- 从小到大排序 $x_{(1)}^{(j)} \leq \dots \leq x_{(n)}^{(j)}$
- 计算 $T^{(j)} = \frac{1}{n-2} \sum_{i=2}^{n-1} x_{(i)}^{(j)}$.

2. 计算MSE $M\hat{S}E(T) = \frac{1}{m} \sum_{j=1}^m (T^{(j)} - \theta)^2 = \frac{1}{m} (T^{(j)})^2$.

实现程序如下

```
n <- 20
m <- 1000
tmean <- numeric(m)
```

[↑Code](#)


```
for (i in 1:m) {
  x <- sort(rnorm(n))
  tmean[i] <- sum(x[2:(n-1)]) / (n-2)
}
mse <- mean(tmean^2)
mse
sqrt(sum((tmean - mean(tmean))^2)) / m    #se
```

[↓Code](#)

截尾均值的MSE的估计为0.0504531($\hat{se} \doteq 0.007$). 样本均值的MSE为 $Var(X)/n = 1/20 = 0.05$. 另一方面, 中位数本质上也是一种截尾均值, 其截掉了除中间的一个或两个点外的所有点. 样本中位数的MSE估计如下

```
n <- 20
m <- 1000
tmean <- numeric(m)
for (i in 1:m) {
  x <- sort(rnorm(n))
  tmean[i] <- median(x)
}
```

[↑Code](#)

```
mse <- mean(tmean^2)
mse
sqrt(sum((tmean - mean(tmean))^2)) / m      #se
```

[↓Code](#)

从而样本中位数的MSE估计为0.075($\hat{se} = 0.0086$).

例 3: 比较标准正态分布与如下混合(“污染”)正态分布下的 k 水平截尾均值估计的MSE.

$$pN(0, \sigma^2 = 1) + (1 - p)N(0, \sigma^2 = 100)$$

我们写一个函数来对不同的 k 和 p 计算截尾均值 $\bar{X}_{[-k]}$ 的MSE. 从混合正态中产生样本时, 要根据 $P(\sigma = 1) = p; P(\sigma = 10) = 1 - p$ 来随机选择 σ . 注意正态随机数产生函数**rnorm**可以使用参数向量作为标准偏差. 考虑 $p = 1.0, 0.95, 0.9$ 以及 $k = 0, 1, \dots, n/2$. 因此程序如下

```
n <- 20; K <- n/2 - 1; m <- 1000;
mse <- matrix(0, n/2, 6)
```

[↑Code](#)

```

trimmed.mse <- function(n, m, k, p) {
  #MC est of mse for k-level trimmed mean of
  #contaminated normal  $pN(0,1) + (1-p)N(0,100)$ 
  tmean <- numeric(m)
  for (i in 1:m) {
    sigma <- sample(c(1, 10), size = n,
      replace = TRUE, prob = c(p, 1-p))
    x <- sort(rnorm(n, 0, sigma))
    tmean[i] <- sum(x[(k+1):(n-k)]) / (n-2*k)
  }
  mse.est <- mean(tmean^2)
  se.mse <- sqrt(mean((tmean-mean(tmean))^2)) / sqrt(m)
  return(c(mse.est, se.mse))
}
for (k in 0:K) {
  mse[k+1, 1:2] <- trimmed.mse(n=n, m=m, k=k, p=1.0)
  mse[k+1, 3:4] <- trimmed.mse(n=n, m=m, k=k, p=.95)
  mse[k+1, 5:6] <- trimmed.mse(n=n, m=m, k=k, p=.9)
}
round(n*mse,3)

```

[↓ Code](#)

结果表明, 均值的稳健估计(截尾均值估计)在总体分布被污染时能降低 MSE.

1.2 Estimating a confidence level

在应用统计中经常遇到的一个问题是估计总体的分布. 比如, 许多常用的统计推断方法和工具都是基于正态性假设下的. 而在实际中, 总体分布非正态是经常的, 估计量的分布可能不知道或者没有显示表示, 此时, Monte Carlo 方法则可以用来进行统计推断.

假设 (U, V) 是未知参数 θ 的置信区间, 则统计量 U, V 的分布都依赖于抽样分布 X 的分布 F_X . 置信水平就是区间 (U, V) 能够覆盖 θ 真值的概率. 因此估计置信水平就是一个积分估计问题.

比如考虑方差的置信区间估计问题. 标准的方法是对正态性假设很敏感的, 在数据(样本) 偏离正态分布时, 我们来使用Monte Carlo方法估计真实的置信水平. 首先看正态假定下方差的置信区间估计(标准方法):

例 4: 方差的置信区间 假设 $X_1, \dots, X_n, i.i.d \sim N(\mu, \sigma^2), n \geq 2, S^2$ 为样本方差, 则由

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$$

知道 σ^2 的一个 $100(1-\alpha)$ 置信上界为

$$(0, (n-1)S^2/\chi_{\alpha}^2(n-1))$$

从而从正态总体 $N(0, \sigma^2 = 4)$ 中随机抽取 $n = 20$ 个样本, 则计算 σ^2 的 %95 置信上界的程序如下

```
n <- 20
alpha <- .05
x <- rnorm(n, mean=0, sd=2)
UCL <- (n-1) * var(x) / qchisq(alpha, df=n-1)
```

[↑Code](#)

[↓Code](#)

我们可以使用图来直观上判断经验的置信水平:

[↑Code](#)

```
m<-100000
ucls<-numeric(m)
for(i in 1:m){
  x <- rnorm(n, mean=0, sd=2)
  ucls[i] <- (n-1) * var(x) / qchisq(alpha, df=n-1)
}
ind<-ucls>4
cov.rate<-cumsum(ind)/1:m
plot(2:m,cov.rate[-1],type="l")
abline(h=0.95)
```

[↓Code](#)

经验的置信水平是通过模拟, 对理论的置信水平进行估计. 其一般做法如下

假设 $X \sim F_X$, 感兴趣的参数为 θ . 则对 $j = 1, \dots, m$:

1. 产生第 j 个随机样本 $x_1^{(j)}, \dots, x_n^{(j)}$.
2. 计算基于第 j 个样本的置信区间 C_j
3. 计算 $y_j = I(\theta \in C_j)$
4. 计算经验的置信水平 $\bar{y} = \frac{1}{m} \sum_{j=1}^m y_j$.

例 5: 置信水平的Monte Carlo估计 在上一个例子中, 我们使用了 **for** 循环来实现计算 σ^2 的 m 个置信上界. 我们也可以使用 **replicate** 函数:

```
n <- 20
alpha <- .05
UCL <- replicate(1000, expr = {
  x <- rnorm(n, mean = 0, sd = 2)
  (n-1) * var(x) / qchisq(alpha, df = n-1)
})
```

[↑Code](#)

```
#计算包含sigma^2=4的区间数
sum(UCL > 4)
#计算经验的覆盖率(置信水平)
mean(UCL > 4)
```

[↓Code](#)

replicate函数要重复执行的代码放在{ }中, 参数**expr**可以调用一个函数:

```
calCI <- function(n,alpha){
  x <- rnorm(n, mean = 0, sd = 2)
  return((n-1) * var(x) / qchisq(alpha, df = n-1))
}
UCL<-replicate(1000,expr=calCI(n=20,alpha=.05))
mean(UCL>4)
```

[↑Code](#)

[↓Code](#)

以上所说的置信区间构造方法是建立在正态性假设之上的, 如果数据(样本)不服从正态分布, 则 真正的置信水平为

$$P\left(\frac{(n-1)S^2}{\chi_{\alpha}^2(n-1)} > \sigma^2\right) = P\left(S^2 > \frac{\sigma^2 \chi_{\alpha}^2(n-1)}{n-1}\right) = 1 - G\left(\frac{\sigma^2 \chi_{\alpha}^2(n-1)}{n-1}\right).$$

这里 G 为统计量 S^2 的分布. 因此估计置信水平等价于要估计 $G(t) = P(S^2 < t) = \int_0^t g(x)dx$, 从而Monte Carlo积分估计方法可以被用来估计此积分.

例 6: 经验的置信水平 在例5中, 假设样本服从 χ_2^2 , 则经验的置信水平是多少? 此时 方差仍然是4.

```
n <- 20; alpha <- .05
UCL <- replicate(1000, expr = {
  x <- rchisq(n, df = 2) # 从chi^2(2)中抽样
  (n-1) * var(x) / qchisq(alpha, df = n-1) })
sum(UCL > 4)
mean(UCL > 4)
```

↑Code

↓Code

前面的例子中考虑的问题都是在总体分布已知的情形下, 对参数进行Monte Carlo估计. 因此这种 情况下的Monte Carlo方法也称为是参数 *Bootstrop* 方法. 有关于Bootstrap 方法我们将在后面 学习.

1.3 Monte Carlo Methods for Hypothesis Tests

假定我们要考虑如下形式的假设检验问题:

$$H_0 : \theta \in \Theta_0 \quad vs \quad H_1 : \theta_1 \in \Theta_1$$

这里 Θ_0, Θ_1 为参数空间 Θ 的划分.

统计假设检验中会出现两种错误:

- Type I error: 零假设被拒绝, 但实际上零假设是正确的;
- Type II error: 零假设被接受, 但实际上零假设是错误的.

检验的**显著性水平**, α , 是一型错误率的上界. 拒绝零假设的概率 依赖于参数 θ 的真值, 记 $\pi(\theta)$ 为拒绝零假设的概率, 则

$$\alpha = \sup_{\theta \in \Theta_0} \pi(\theta).$$

一型错误率是当零假设正确时, 零假设被拒绝的概率. 因此当一个检验在零假设条件下 被重复很多次后, 观察到的一型错误率就应该逼近 α .

若 T 为检验统计量, T^* 为检验统计量的观测值, 则称 T^* 是**显著的**, 如果基于 T^* 的检验结论 是拒绝零假设 H_0 . **显著概率或p值**是使得检验统计量显著的最小的可能 α 值.

1.4 Empirical Type I error rate

Monte Carlo模拟可以用来计算一个检验方法的经验一型错误率. 检验过程在零假设条件下大量重复, 则 经验一型错误率为检验统计量在重复中是显著的比例.

Monte Carlo模拟来计算经验的一型错误率:

1. 对每个重复 j , $j = 1, \dots, m$.

(a) 从零分布产生第 j 个随机样本 $x_1^{(j)}, \dots, x_n^{(j)}$;

(b) 基于第 j 个样本计算检验统计量 T_j ;

(c) 记录决策结果 $I_j = 1$, 若 H_0 在显著性水平 α 下被拒绝; 否则 $I_j = 0$.

2. 计算显著的检验比例 $\frac{1}{m} \sum_{j=1}^m I_j$, 此比例即为观测到的一型错误率.

用 \hat{p} 表示估计的一型错误率, 则其标准方差的估计为

$$\widehat{se}(\hat{p}) = \sqrt{\frac{\hat{p}(1 - \hat{p})}{m}} \leq \frac{0.5}{\sqrt{m}}.$$

例7: 经验的一型错误率 假设 X_1, \dots, X_{20} *i.i.d* $N(\mu, \sigma^2)$, 假设 $H_0 : \mu = 500$ $H_1 : \mu > 500$. 在零假设下,

$$T^* = \frac{\bar{X} - 500}{S/\sqrt{20}} \sim t_{19}.$$

大的 T^* 值是支持对立假设. 我们使用Monte Carlo方法来计算在 $\sigma = 100$ 时的一型错误率, 来检测其是否逼近0.05.

```
n <- 20; alpha <- .05; mu0 <- 500; sigma <- 100;
m <- 10000          #number of replicates
p <- numeric(m)    #storage for p-values
for (j in 1:m) {
  x <- rnorm(n, mu0, sigma)
  ttest <- t.test(x, alternative = "greater", mu = mu0)
  p[j] <- ttest$p.value
}
p.hat <- mean(p < alpha)
se.hat <- sqrt(p.hat * (1 - p.hat) / m)
print(c(p.hat, se.hat))
```

[↑Code](#)

```
plot(1:m,cumsum(p<alpha)/1:m,type="l")
abline(h=0.05)
```

[↓Code](#)

例8: 正态分布的偏度检验 一个随机变量 X 的偏度系数定义为

$$\beta_1 = \frac{E[(X - \mu)^3]}{\sigma^2},$$

其中 $\mu = EX, \sigma^2 = Var(X)$. 一个分布称为是对称的, 如果 $\beta_1 = 0$; 称为是正偏的, 如果 $\beta_1 > 0$; 称为是负偏的, 如果 $\beta_1 < 0$. 偏度系数的估计为

$$b_1 = \frac{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3}{(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2)^{3/2}}.$$

可以证明, $\sqrt{n}(b_1 - \beta_1) \xrightarrow{Asy} N(0, 6)$. 正态分布是对称的分布, 因此偏度系数可以用来检验一个分布是否为对称分布. 假设为

$$H_0 : \beta_1 = 0 \quad vs \quad H_1 : \beta_1 \neq 0.$$

从而可以基于检验统计量 b_1 构建一个检验法则.

$$|b_1| \geq z_\alpha \sqrt{6/n}, \text{Reject } H_0; \text{ Otherwise, Accept } H_0.$$

对大样本来说, 检验的显著性水平达到指定的显著性水平, 比如 $\alpha = 0.05$;
对小样本来说, 由于 b_1 的理论分布不可得到, 从而确切的显著性水平不可得到,
但其经验的一型错误率可以通过Monte Carlo方法来估计.

```
n <- c(10, 20, 30, 50, 100, 500) #sample sizes
cv <- qnorm(.975, 0, sqrt(6/n)) #asymptotical crit. values for each n

sk <- function(x) {
  #computes the sample skewness coeff.
  xbar <- mean(x)
  m3 <- mean((x - xbar)^3)
  m2 <- mean((x - xbar)^2)
  return( m3 / m2^1.5 )
}
```

[↑Code](#)

```
#n is a vector of sample sizes
#we are doing length(n) different simulations
p.reject <- numeric(length(n)) #to store sim. results
m <- 10000                      #num. repl. each sim.
for (i in 1:length(n)) {
  sktests <- numeric(m)        #test decisions
  for (j in 1:m) {
    x <- rnorm(n[i])
    #test decision is 1 (reject) or 0 (Accept)
    sktests[j] <- as.integer(abs(sk(x)) >= cv[i] )
  }
  p.reject[i] <- mean(sktests) #proportion rejected
}
names(p.reject)<-as.character(n)
p.reject
```

[↓Code](#)

结果表明对较少的样本量时, 这种检验的显著性水平偏低, 没有达到理论值0.05. 在正态总体下, 可以求出

$$\text{Var}(b_1) = \frac{6(n-2)}{(n+1)(n+3)}.$$

因此, 对小样本, 应该使用此方差来计算检验的临界值:

```
cv<-qnorm(.975, 0, sqrt(6*(n-2)/((n+1)*(n+3)))) # crit. values for each n
p.reject <- numeric(length(n)) #to store sim. results
m <- 10000 #num. repl. each sim.
for (i in 1:length(n)) {
  sktests <- numeric(m) #test decisions
  for (j in 1:m) {
    x <- rnorm(n[i])
    #test decision is 1 (reject) or 0 (Accept)
    sktests[j] <- as.integer(abs(sk(x)) >= cv[i] )
  }
  p.reject[i] <- mean(sktests) #proportion rejected
}
p.reject
```

[↑Code](#)

现在得到的估计就比较靠近名义值0.05了.

1.4.1 Power of a Test

一个检验的功效定义为

$$\pi(\theta) = P_{\theta}(\text{Reject } H_0)$$

当有一个 $\theta_1 \in \Theta_1$ 时, 犯二型错误的概率为 $1 - \pi(\theta_1)$. 理想中, 我们希望一个检验的错误率越低越好. 一型错误率通过显著性水平 α 的选择而控制, 较低的二型错误率对应于较高的功效. 因此, 在比较两个具有同样显著性水平的检验时, 我们感兴趣的是比较它们的功效. 一般来说这种比较不是简单的问题, 比如一个检验的功效 $\pi(\theta_1)$ 依赖于在对立假设下的 θ_1 值. 当一个检验的功效函数没有分析的表达式时, 功效函数 在特定的 $\theta_1 \in \Theta_1$ 处的值可以通过Monte Carlo方法得到.

Monte Carlo 方法计算检验的功效:

1. 选择一个特定的 $\theta_1 \in \Theta$.
2. 对每个重复 $j, j = 1, \dots, m$.
 - (a) 在对立假设空间 $\theta = \theta_1$ 的情况下产生第 j 个随机样本 $x_1^{(j)}, \dots, x_n^{(j)}$;
 - (b) 基于第 j 个样本计算检验统计量 T_j ;
 - (c) 记录决策结果 $I_j = 1$, 若 H_0 在显著性水平 α 下被拒绝; 否则 $I_j = 0$.
3. 计算显著的检验比例 $\frac{1}{m} \sum_{j=1}^m I_j$, 此比例即为观测到的一型错误率.

例9: 使用模拟方法估计例7中 t 检验的功效并画出经验功效函数曲线

```
n <- 20
m <- 1000
```

[↑Code](#)

```
mu0 <- 500
sigma <- 100
mu <- c(seq(450, 650, 10)) #alternatives
M <- length(mu)
power <- numeric(M)
for (i in 1:M) {
  mu1 <- mu[i]
  pvalues <- replicate(m, expr = {
    #simulate under alternative mu1
    x <- rnorm(n, mean = mu1, sd = sigma)
    ttest <- t.test(x,
      alternative = "greater", mu = mu0)
    ttest$p.value } )
  power[i] <- mean(pvalues <= .05)
}
```

[↓Code](#)

估计的功效 $\hat{\pi}(\theta)$ 存在向量`power`中, 下面画出经验功效函数的图像, 我们这里使用**Hmisc**包里的**errbar**函数.

[↑Code](#)

```
par(ask = TRUE)
library(Hmisc) #for errbar
plot(mu, power)
abline(v = mu0, lty = 1)
abline(h = .05, lty = 1)

#add standard errors
se <- sqrt(power * (1-power) / m)
errbar(mu, power, yplus = power+se, yminus = power-se,
       xlab = bquote(theta))
lines(mu, power, lty=3)
detach(package:Hmisc)
par(ask = FALSE)
```

[↓Code](#)

注意对 t 检验, 对假设 $H_0 : \mu = \mu_0$ vs $H_1 : \mu \neq \mu_0$ 而言, 检验统计量 $T = (\bar{X} - \mu)/(S/\sqrt{n})$ 在零假设下服从中心的 t 分布, 而在对立假设下, T 服从非中心的 t 分布, 非中心参数为 $\delta = (\mu - \mu_0)\sqrt{n}/\sigma$. 在R中,可以使用函数**power.t.test**来计算 t 检验的功效或者在给定功效下确定各参数的值.

例10: 混合正态分布下正态性偏度检验的功效 在例8中, 我们考虑了正态性偏度检验的一型错误率. 对混合正态分布

$$pN(0, \sigma^2 = 1) + (1 - p)N(0, \sigma^2 = 100), 0 \leq p \leq 1.$$

当 $p = 0, 1$, 为正态分布; 而当 $0 < p < 1$, 不再为正态分布. 因此, 我们可以计算一下偏度检验用于检验正态性的功效. 这里考虑显著性水平 $\alpha = 0.1$, 样本量 $n = 30$. 我们重复此过程 $m = 2500$ 次来计算功效.

```
alpha <- .1
n <- 30
m <- 2500
epsilon <- c(seq(0, .15, .01), seq(.15, 1, .05))
N <- length(epsilon)
pwr <- numeric(N)
#critical value for the skewness test
cv <- qnorm(1-alpha/2, 0, sqrt(6*(n-2) / ((n+1)*(n+3))))

for (j in 1:N) {                #for each epsilon
```

[↑Code](#)

```
e <- epsilon[j]
sktests <- numeric(m)
for (i in 1:m) {      #for each replicate
  sigma <- sample(c(1, 10), replace = TRUE,
    size = n, prob = c(1-e, e))
  x <- rnorm(n, 0, sigma)
  sktests[i] <- as.integer(abs(sk(x)) >= cv)
}
pwr[j] <- mean(sktests)
}

#plot power vs epsilon
plot(epsilon, pwr, type = "b",
  xlab = bquote(epsilon), ylim = c(0,1))
abline(h = .1, lty = 3)
se <- sqrt(pwr * (1-pwr) / m) #add standard errors
lines(epsilon, pwr+se, lty = 3)
lines(epsilon, pwr-se, lty = 3)
```

[↓ Code](#)

经验的功效函数曲线在 $p = 0$ 和 $p = 1$ 两点接近 $\alpha = 0.1$, 对 $0 < p < 1$, 功效函数大于0.1, 最大值大约在 $p = 0.15$ 处达到.

1.4.2 Power Comparisons

Monte Carlo方法经验用于比较不同检验的功效. 本节我们讨论对于正态性偏度检验问题几种检验 的功效差异. 文献中对于正态性检验已有很多不同的方法. 我们这里考虑三种检验方法.

例11: 正态性检验的功效比较 对一元正态性检验问题, 比较Shapiro-Wilk检验, Energy检验 和偏度检验三种检验的功效差异.

假设 \mathcal{N} 为一个一元正态分布类, 检验假设

$$H_0 : F_X \in \mathcal{N} \quad \text{vs} \quad H_1 : F_X \notin \mathcal{N}.$$

Shapiro-Wilk 检验是基于样本次序统计量对它们在正态性成立下的期望作回归, 因此它属于一般基于回归 和相关的类别检验方法. 对样本量 $7 \leq n \leq 2000$, 近似的检验统计量临界值通过将统计量 W 变换到 正态分布随机变量而得到. 参考阅读材料了解更多Shapiro-Wilk检验方法. 在R中, 可以通过[shapiro.test](#) 函数作Shapiro-Wilk检验.

Energy检验是基于抽样分布和正态分布之间的“energy”距离进行检验，因此大的检验统计量值意味着显著性。energy检验是用来检验多元正态性的一种方法，这里我们考虑的是其特例 $d = 1$ ，在一元正态检验下，energy检验类似于Anderson-Darling检验。energy检验统计量为

$$Q_n = n \left[\frac{2}{n} \sum_{i=1}^n E\|x_i - X\| - E\|X - X'\| - \frac{1}{n^2} \sum_{i,j=1}^n \|x_i - x_j\| \right],$$

其中 X, X' 为*i.i.d*的正态分布随机变量。大的 Q_n 值表明显著性。在一元情形下， Q_n 可以表示为

$$Q_n = n \left[\frac{2}{n} \sum_{i=1}^n (2Y_i\Phi(Y_i) + 2\phi(Y_i)) - \frac{2}{\sqrt{\pi}} - \frac{1}{n^2} \sum_{k=1}^n (2k - 1 - n)Y_{(k)} \right],$$

其中 $Y_i = \frac{X_i - \mu_X}{\sigma_X}$ ， $Y_{(k)}$ 为 Y_1, \dots, Y_n 的第 k 个次序统计量。若参数 μ_X, σ_X 未知，则用样本均值和样本方差。在多元情形也有类似的计算公式，在R中energy检验包含在energy包中，名称为mvnorm.etest。

第三种检验就是我们前面例子中的偏度检验. 我们取显著性水平为 $\alpha = 0.1$, 对立假设为

$$(1 - p)N(\mu = 0, \sigma^2 = 1) + pN(\mu = 0, \sigma^2 = 100), 0 \leq p \leq 1$$

当 $p = 0$ 或者 1 时, 分布为正态分布, 此时经验的一型错误率应该被名义的错误率 $\alpha = 0.1$ 控制住, 我们感兴趣的是在 $0 < p < 1$ 时三种检验的功效比较.

```
library(energy)
alpha <- .1
n <- 30
m <- 500      #try small m for a trial run
test1 <- test2 <- test3 <- numeric(m)

#critical value for the skewness test
cv <- qnorm(1-alpha/2, 0, sqrt(6*(n-2) / ((n+1)*(n+3))))
sim <- matrix(0, 11, 4)

# estimate power
```

[↑Code](#)

```

for (i in 0:10) {
  epsilon <- i * .1
  for (j in 1:m) {
    e <- epsilon
    sigma <- sample(c(1, 10), replace = TRUE,
      size = n, prob = c(1-e, e))
    x <- rnorm(n, 0, sigma)
    test1[j] <- as.integer(abs(sk(x)) >= cv)
    test2[j] <- as.integer(
      shapiro.test(x)$p.value <= alpha)
    test3[j] <- as.integer(
      mvnorm.etest(x, R=200)$p.value <= alpha)
  }
  print(c(epsilon, mean(test1), mean(test2), mean(test3)))
  sim[i+1, ] <- c(epsilon, mean(test1), mean(test2), mean(test3))
}
detach(package:energy)

# plot the empirical estimates of power
plot(sim[,1], sim[,2], ylim = c(0, 1), type = "l",
  xlab = bquote(epsilon), ylab = "power")

```

```
lines(sim[,1], sim[,3], lty = 2)
lines(sim[,1], sim[,4], lty = 4)
abline(h = alpha, lty = 3)
legend("topright", 1, c("skewness", "S-W", "energy"),
      lty = c(1,2,4), inset = .02)
```

[↓ Code](#)

结果表明Shapiro-Wilks检验和energy检验在检验此假设中有着差不多的功效, 模拟比较中设定 $n = 30$ 和 $p < 0.5$. 此两个检验的功效都比偏度检验的功效大, energy检验看起来在 $0.5 \leq p \leq 0.8$ 时 功效最大.

1.5 Application: “Count Five” Test for Equal Variance

本节中我们介绍一个简单两样本方差齐性检验方法. ”Count five” 检验方差齐性方法由McGrath 和 Yeh 引入, 通过对一组样本相对于另外一组样本的样本范围的极值点个数. 假设两组样本的均值和样本量都相同. 一组样本下的一个观测值如果不在另一组样本的样本范围中, 则就是一个极值点. 如果每组样本

都有至少 5 个极值点, 则拒绝等方差的假设.

例 12: Count Five test statistic 通过如下数值例子来说明此检验.

```
x1 <- rnorm(20, 0, sd = 1)
x2 <- rnorm(20, 0, sd = 1.5)
y <- c(x1, x2)

group <- rep(1:2, each = length(x1))
boxplot(y ~ group, boxwex = .3, xlim = c(.5, 2.5), main = "")
points(group, y)
```

[↑Code](#)

[↓Code](#)

对此两组样本, 通过Box图就可以直观上计算出相应的极值点个数. 也可以计算如下

```
# now identify the extreme points
range(x1)
range(x2)
```

[↑Code](#)

```
i <- which(x1 < min(x2))
j <- which(x2 > max(x1))

x1[i]
x2[j]

out1 <- sum(x1 > max(x2)) + sum(x1 < min(x2))
out2 <- sum(x2 > max(x1)) + sum(x2 < min(x1))
max(c(out1, out2))
```

[↓Code](#)

此时我们不能拒绝方差齐性的假设.

例 13: 考虑从同一正态分布中独立抽样的两组样本, 估计Count Five检验中极值点个数最大值的分布, 并找出0.80,0.90和0.95分位数.

下面的函数**maxout**计算极值点的最大值.其分布可以通过Monte Carlo方法估计.

[↑Code](#)

```
maxout <- function(x, y) {  
  X <- x - mean(x)  
  Y <- y - mean(y)  
  outx <- sum(X > max(Y)) + sum(X < min(Y))  
  outy <- sum(Y > max(X)) + sum(Y < min(X))  
  return(max(c(outx, outy)))  
}
```

```
n1 <- n2 <- 20;  mu1 <- mu2 <- 0;  sigma1 <- sigma2 <- 1;  m <- 1000
```

```
# generate samples under H0  
stat <- replicate(m, expr={  
  x <- rnorm(n1, mu1, sigma1)  
  y <- rnorm(n2, mu2, sigma2)  
  maxout(x, y)  
})  
print(cumsum(table(stat)) / m)  
print(quantile(stat, c(.8, .9, .95)))
```

[↓Code](#)

注意`quantile`函数给出的0.95分位数是6, 但是如果 $\alpha = 0.05$, 则5作为临界值更合适. `quantile`函数 给出的分位数并不是总是最好的, 因此一般要注意和经验分布函数比较.

McGrath 和 Yeh证明了 Count Five 检验用于检验中心化数据方差齐性时显著性水平最多为0.0625. 实际中, 总体均值一般是不知道的, 每组样本可以通过减去各自的样本均值来中心化.

例 14: 当总体均值未知, 每组样本减去各自的样本均值来中心化, 使用Monte Carlo方法估计 此时Count Five检验的显著性水平.

```
count5test <- function(x, y) {  
  X <- x - mean(x)  
  Y <- y - mean(y)  
  outx <- sum(X > max(Y)) + sum(X < min(Y))  
  outy <- sum(Y > max(X)) + sum(Y < min(X))  
  # return 1 (reject) or 0 (do not reject H0)  
  return(as.integer(max(c(outx, outy)) > 5))  
}
```

[↑Code](#)


```
n1 <- n2 <- 20; mu1 <- mu2 <- 0; sigma1 <- sigma2 <- 1;
m <- 10000
tests <- replicate(m, expr = {
  x <- rnorm(n1, mu1, sigma1)
  y <- rnorm(n2, mu2, sigma2)
  x <- x - mean(x) #centered by sample mean
  y <- y - mean(y)
  count5test(x, y)
} )

alphahat <- mean(tests)
print(alphahat)
```

[↓ Code](#)

如果总体均值是已知的, 则经验的一型错误率大约为0.055(前面的例子中估计出的). 本例中 使用样本均值代替总体均值, 一型错误率大约为0.0565($se = 0.0022$).

例 15: 重复例 13, 当两组样本的样本量不相同, 计算经验的一型错误率.

```
n1 <- 20
n2 <- 30
mu1 <- mu2 <- 0
sigma1 <- sigma2 <- 1
m <- 10000

alphahat <- mean(replicate(m, expr={
  x <- rnorm(n1, mu1, sigma1)
  y <- rnorm(n2, mu2, sigma2)
  x <- x - mean(x) #centered by sample mean
  y <- y - mean(y)
  count5test(x, y)
}))

print(alphahat)
```

[↑Code](#)

[↓Code](#)

结果表明当两组样本的样本量不同时, Count Five检验并没有用0.0625控制住一型错误率.

例 16: 使用Monte Carlo方法估计Count Five检验的功效. 抽样分布为 $N(\mu_1 = 0, \sigma_1^2 = 1)$ 和 $N(\mu_2 = 0, \sigma_2^2 = 1.5^2)$, 样本量为 $n_1 = n_2 = 20$.

```
# generate samples under H1 to estimate power
sigma1 <- 1
sigma2 <- 1.5

power <- mean(replicate(m, expr={
  x <- rnorm(20, 0, sigma1)
  y <- rnorm(20, 0, sigma2)
  count5test(x, y)
}))

print(power)
```

[↑Code](#)

[↓Code](#)

在对立假设 $\sigma_1 = 1, \sigma_2 = 1.5$ 下检验的经验功效约为0.3025($se \leq 0.005$) .