

シミュレーション統計学の勧め

岡山大学
垂水共之

統計学

- 理論統計学(数理統計学)
 - 確率論をベースに
 - 分布論
 - 推測統計学
- データ解析(応用統計学)
 - 実データの分析
 - 表計算ソフト
 - 統計ソフト

理論統計学
数理統計学


シミュレーション統計学

データ解析
応用統計学
計算機統計学


特定研究

- 「情報システムの形成過程と学術情報の組織化」(猪瀬博)昭和51年度～53年度
- A4班「統計プログラム・パッケージの研究」
(代表:丘本正)
 - NISAN
 - SALS
 - 行動科学
 - 方法論

- 汎用機のTSS処理によるシミュレーション教育の試み(千葉大学・田栗・現在大学入試センター)




- パソコン(NEC PC-8001)への焼き直し
– スピードが遅く挫折



- パソコンの低価格化と高性能化

シミュレーション統計学

- パソコンの低価格化と高性能化
 - 本体は3~4万円で充分の性能
- 統計解析用ソフト
 - XLisp-Stat
 - R/S-PLUS



R/S-PLUSによる統計解析入門
(2006年、共立出版)

R/S-PLUSによる統計解析入門

- 亂数によるシミュレーション
 - 円周率
- 標本分布のシミュレーション
 - 標準正規分から自由度1の χ^2 乗分布
 - χ^2 乗分布の再生性
 - 標準正規分と χ^2 乗分布の比としての t分布
 - 2つの χ^2 乗分布の比としてのF分布
- 中心極限定理
- 正規分布の母平均の区間推定
 - 信頼度
- 正規分布の母平均の検定
 - 有意水準
 - 検出力

S-PLUSの環境


- Windows版
 - S-PLUS 6.0 日本語版 Release 4
 - コマンド(CGI)での利用
- Linux版
 - Version 6.0 Release 1

中心極限定理

中心極限定理

Central Limit Theorem

- X_1, X_2, \dots, X_n は同じ分布 $F(x)$ に従い独立
- $E(X) = \mu$ 平均存在
- $\text{Var}(X) = \sigma^2$ 分散存在




- $\bar{X} = \sum X_i/n$ の分布は $n \rightarrow \infty$ のとき
 $N(\mu, \sigma^2/n)$ に収束
- 実用的には $n \geq 25$


一様分布の場合

- X が区間 $[0, 1]$ の一様分布
 $E(X)=1/2$, $\text{Var}(X)=1/12$

$n=2$



$n=3$



$$X_i \sim U[0,1]$$

$Z = X_1$ のpdf

$$u_1(x) = \begin{cases} 1 & 0 < x < 1 \\ 0 & \text{その他} \end{cases}$$

$Z = X_1 + X_2$ のpdf

$$u_2(x) = \begin{cases} z & 0 < z < 1 \\ 2-z & 1 < z < 2 \\ 0 & \text{その他} \end{cases}$$


$Z = X_1 + X_2 + X_3$ のpdf

$$u_3(x) = \begin{cases} z^2 & 0 < z < 1 \\ -z^2 + 3z - 3/2 & 1 < z < 2 \\ (z-3)^2/2 & 2 < z < 3 \\ 0 & \text{その他} \end{cases}$$

二個の一様乱数の和


```
> u2 <- function(z)
+   switch(length(which(c((z >= 0), (z >= 1), (z > 2))))) + 1, 0, z, 2 - z, 0)
> u2s <- function(z)
+   u2(z / sqrt(6) + 1) / sqrt(6)

> x <- seq(-3, 3, length = 101)
> plot(x, sapply(x, u2s), type = "l")
> curve(dnorm, -3, 3, add = T, col = 2)
```





三個の一様乱数の和

```
> u3 <- function(z)
+ switch(length(which(c((z >= 0), (z >= 1), (z > 2), (z > 3))))) + 1,
+ 0, z^2 / 2, -z^2 + 3 * z - 3 / 2, (z - 3)^2 / 2, 0)
> u3s <- function(z)
+ u3(1.5 + (z * 0.5)) * 0.5
> x <- seq(-3, 3, length = 101)
> plot(x, sapply(x, u3s), type = "l",
+ ylim = c(0, 0.4))
> curve(dnorm, -3, 3, add = T, col = 2)
```









種々の分布

- 一様分布
- 二次分布
- 三角分布
- 平方根分布
- 二項分布
- ...




種々の分布のpdf, cdf



シミュレーション(一様分布)






```
> cltplot <- function(data, n){  
+   hist(scale(data), nclass = 20, xlim = c(-4, 4),  
+     ylim = c(0, 0.5), freq = F, main = paste("N =", n))  
+   curve(dnorm, -4, 4, col = 2, add = T)  
+ }  
  
> clturand <- function(n, nsim){  
+   if(n == 1)  
+     result <- apply(matrix(sapply(rep(n, nsim), runif), n, nsim), 2, mean)  
+   else  
+     result <- apply(sapply(rep(n, nsim), runif), 2, mean)  
+   cltplot(result, n)  
+ }  
  
> clturand(5,1000)
```

clturand(5,1000) $n = 5$



cltunif(5) データ数を1から5まで

```
> cltunif <- function(nmax){  
+   for( i in 1:nmax){  
+     if (options()$device == "X11")  
+       X11()  
+     if (options()$device == "windows")  
+       win.graph()  
+     clturand(i, nsim)  
+   }  
+ }  
>  
> #####  
> nsim <- 500  
> # 標準のシミュレーション回数  
> cltunif(5)
```





シミュレーション 乱数(分布)を指定



```
cltrand <- function(n, nsim, rdist){  
  if(n == 1)  
    result <- apply(matrix(sapply(rep(n, nsim), rdist), n, nsim), 2, mean)  
  else  
    result <- apply(sapply(rep(n, nsim), rdist), 2, mean)  
  cltplot(result, n)  
}
```

```
clt <- function(nmax, rdist){  
  for(i in 1:nmax){  
    if (options()$device == "X11")  
      X11()  
    if (options()$device == "windows")  
      win.graph()  
    cltrand(i, nsim, rdist)  
  }  
}
```

> clt(5,rquad)



$\text{rsqrt}(5,500)$



シミュレーション(その他の分布)

- 二次分布 rquad
- 三角分布 rtriangular
- 平方根分布 rsqrt
- 二項分布 rbinom

...

```
> brinom10.01<-function(x) rbinom(n,10,0.01)
> clt(15, clt-binomial)
```

推定・検定

区間推定の信頼度 $1-\alpha$

$$\Pr(\hat{\theta}_L(X_1, X_2, \dots, X_n) < \theta < \hat{\theta}_U(X_1, X_2, \dots, X_n)) < 1 - \alpha$$

信頼度 $1-\alpha$ の信頼区間

$$(\hat{\theta}_L(X_1, X_2, \dots, X_n), \hat{\theta}_U(X_1, X_2, \dots, X_n))$$

- 信頼度 $1-\alpha=0.95$ とは
 - 求めた区間に真の値が入る確率が95%
 - 100回に5回ほどは外れても仕方がない

母平均の区間推定(分散既知)

- 正規母集団
 - 母分散: 1(既知)
 - 母平均: μ (未知)

$$\bar{x} \pm k_{\alpha/2} \sqrt{\frac{\sigma^2}{n}}$$

- データは
`rnorm()`
 $N(0,1)$ からのデータ
- 真の $\mu = 0$


```
> confinterval <- function(x, conf, sigma2)
+ {
+   n <- length(x)
+   alpha <- 1 - conf
+   k <- qnorm(1 - alpha / 2)
+   barx <- mean(x)
+   mL <- barx - k * sqrt(sigma2 / n)
+   mU <- barx + k * sqrt(sigma2 / n)
+   c(mL, mU)
+ }
> confinterval(rnorm(10), 0.95, 1)
[1] -0.547104  0.692486
> confinterval(rnorm(10), 0.95, 1)
[1] -0.6639466  0.5756434
> confinterval(rnorm(10), 0.95, 1)
[1] -0.8003083  0.4392818
> confinterval(rnorm(10), 0.95, 1)
[1] 0.01251542 1.25210548
```

100回中、何回程度間違える？


```
> confintervalsim <- function(nsim, n, conf){  
+   result <- c()  
+   for (i in 1:nsim){  
+     result <- rbind(result, confinterval(rnorm(n), conf, 1))  
+   }  
+   result  
+ }  
  
> r <- confintervalsim(100, 10, 0.95)  
> r[apply(r, 1, prod) > 0, ]  
      [,1]      [,2]  
[1,] -1.2425114 -0.002921355  
[2,]  0.3166913  1.556281376  
[3,]  0.1919863  1.431576354  
  
> which(apply(r, 1, prod) > 0)  
[1] 13 31 61
```

母分散、既知と未知

母分散:既知



母分散:未知



検定の有意水準

- 有意水準 $\alpha=5\%$ とは
 - 帰無仮説が正しいのに、誤って帰無仮説を棄却する、「検定の第一種の誤り」の確率
 - 誤った判定を下す許容範囲
 - 100回中5回程度は間違えても仕方がない！

母平均の検定

$$H_0 : \mu = 0$$

$$\sigma^2 = 1 \text{ (既知)}$$

$$H_1 : \mu \neq 0$$

母集団： 標準正規分布

標本数： n

有意水準： α

```
> ntest <- function(n, alpha)
+ {
+   k <- qnorm(1 - alpha / 2)
+   x <- rnorm(n)
+   barx <- mean(x)
+   z <- barx / sqrt(1 / n)
+   if (abs(z) > k)
+     T
+   else
+     F
+ }
```

```
> ntest(10,0.05)
```

```
[1] F
```

```
> ntest(10,0.05)
```

```
[1] T
```

100回中、何回程度間違える？

```
> ntestsim <- function(nsim, n, alpha)
+ {
+   r <-c()
+   for (i in 1:nsim)
+     r <-c(r, ntest(n, alpha))
+   r
+ }
```

```
> rslt <- ntestsim(100,10,0.05)
```

> rs1t

```
> which(rslt)
```

[1] 3 5 24 46 68 95

6

つづき

```
> which(ntestsim(100, 10, 0.05))
[1] 12 38 52 53 100      5回

> which(ntestsim(100, 10, 0.05))
[1] 4 24 30 77 78 81 90    7回

> which(ntestsim(100, 10, 0.05))
[1] 2 17 53 86 96 98      6回

> which(ntestsim(100, 10, 0.05))
[1] 3 4 18 37 80      5回

> which(ntestsim(100, 10, 0.05))
[1] 23 36 60 94      4回
```


何回ぐらい間違えることが多い？

```
> histsig <- function(nrepeat, nsim, n, alpha)
+ {
+   nsig <- c()
+   for (i in 1:nrepeat)
+     nsig <- c(nsig, length(which(ntestsim(100, 10, 0.05)))))
+   nsig
+ }
```

```
> rsim <- histsig(1000, 100, 10, 0.05)
```

```
> min(rsim)
[1] 0
```

```
> max(rsim)
[1] 14
```




```
> count<-hist(rsim,plot=F,breaks=(0:15)-0.5)
> count
$breaks:
[1] -0.5  0.5  1.5  2.5  3.5  4.5  5.5  6.5  7.5  8.5  9.5  10.5  11.5  12.5
[15] 13.5 14.5
```

```
$counts:
[1]  4 25 90 149 179 165
[7] 174 91 57 35 12 16
[13]  2  0  1
```


```
> hist(rsim,plot=T,breaks=(0:15)-0.5)
```

```
> mean(rsim)
[1] 4.979
```




二項分布 Bi(100,0.05)

```
> binsim<-rbinom(1000,100,0.05)
> hist(binsim)
> min(binsim)
[1] 0
> max(binsim)
[1] 14
> hist(binsim,breaks=(0:15)-0.5)
> hist(binsim,breaks=(0:15)-0.5)$counts
[1]  3 30 87 128 185 182 143 120  62  33
[10] 17  5  4  0  1
> mean(binsim)
[1] 5.016
```



母分散の検定

```
> chiL <- qchisq(0.025, 9); chiL  
[1] 2.700389  
> chiU <- qchisq(0.975, 9); chiU  
[1] 19.02277  
> curve(chisqdens9, 0, 30)  
> lines(c(chiU, chiU), c(0, dchisq(chiU, 9)), col = 2)  
> lines(c(chiL, chiL), c(0, dchisq(chiL, 9)), col = 3)  
> x <- matrix(rnorm(1000), 10, 100)  
> tmp1 <- apply(x, 2, sd)  
> ssq <- tmp1 * tmp1 * 9  
> chi0 <- ssq / 1  
> points(ssq, runif(100) * 0.001)  
> for (i in chi0){  
+   if(i < chiL || i > chiU)  
+     print(i)  
+ }  
[1] 26.50768  
[1] 26.99475  
[1] 1.471944  
[1] 2.700377
```



検出力

- 対立仮説が正しいときに、それを検出する確率

$$H_0 : \mu = \mu_0$$

$$H_1 : \mu = \mu_1$$

$$L(\mu_1) = \Pr(H_1 \mid \mu = \mu_1)$$

母平均の場合

$$H_0 : \mu = 0$$

$N(\mu_1, 1)$ のときに、 H_0 を棄却

$$H_1 : \mu = \mu_1$$

```
> test.power.1 <- function(n, alpha, mu1)
```

```
+ {
```

```
+   k <- qnorm(1 - alpha / 2)
```

```
+   x <- rnorm(n, mean = mu1)
```

```
+   barx <- mean(x)
```

```
+   z <- barx / sqrt(1 / n)
```

```
+   if (abs(z) > k)
```

```
+     T
```

```
+   else
```

```
+     F
```

```
+ }
```

```
> test.power.1(10, 0.05, 0)
```

```
[1] F
```

標本数 $n=10$ 有意水準 $\alpha=0.05$

$\mu_1 = 0$ のとき、検定は受容(F)

```
> test.power.1(10, 0.05, 0.5)
```

```
[1] T
```

標本数 $n=10$ 有意水準 $\alpha=0.05$

$\mu_1 = 0.5$ のとき、検定は棄却(T)

nsim回繰り返したとき、どの程度棄却するか？

```
> test.power <- function(nsim, n, alpha, mu1)
+ {
+   r <- c()
+   for (i in 1:nsim)
+     r <-c(r, test.power.1(n, alpha, mu1))
+   length(which(r)) / nsim
+ }
```

```
> test.power(1000, 10, 0.05, 0)
[1] 0.066
> test.power(1000, 10, 0.05, 0.1)
[1] 0.062
```


```
> mu1 <- seq(-2, 2, 0.1)       $\mu_1$  の値を-2から2まで0.1刻みで

> calc.power <- function(nsim, n, alpha, mu) {
+   rsIt <- c()
+   for(i in mu)
+     rsIt <-c(rsIt, test.power(nsim, n, alpha, i))
+   rsIt
+ }
```

標本数n=10,有意水準 $\alpha=0.05$
で各 μ_1 に対して1000回の実験


```
> prsIt <- calc.power(1000, 10, 0.05, mu1)
> prsIt
[1] 1.000 1.000 1.000 1.000 0.999 0.995 0.992 0.987 0.973 0.919 0.888 0.807 0.712
[14] 0.594 0.490 0.344 0.246 0.144 0.090 0.061 0.041 0.063 0.094 0.147 0.262 0.360
[27] 0.460 0.584 0.738 0.817 0.878 0.916 0.971 0.979 0.992 0.998 1.000 1.000 1.000
[40] 1.000 1.000
> plot(mu1, prsIt, type = "l")
```

シミュレーションによる検出力関数



理論的には

```
> power.theo <- function(mu, alpha, n) {      > x <- seq(-3, 3, 0.01)
+   qa <- qnorm(1 - alpha / 2)                  > plot(x, power.theo(x, 0.05, 10), type = "l")
+   tmp <- (mu - 0) / sqrt(1 / n)
+   err2 <- pnorm(qa - tmp) - pnorm(- qa - tmp)
+   1 - err2
+ }
```



標本相關係数の分布





- 母相關係数 ρ 、標本数 N

$$f(r) = \frac{2^{n-2} (1-\rho^2)^{n/2} (1-r^2)^{(n-3)/2}}{(n-2)! \pi} \sum_{\alpha=0}^{\infty} \frac{(2\rho r)^\alpha}{\alpha!} \Gamma^2[(n+\alpha)/2], \quad -1 \leq r \leq 1$$

where

$$n = N - 1$$

```
> cordistsim <- function(nsim, n, r){  
+   rslt <- c()  
+   for (i in 1:nsim){  
+     rdat <- normal2rand(n, r)  
+     rslt <-c(rslt, cor(rdat$z1, rdat$z2))  
+   }  
+   rslt  
+ }  
> par(mfrow = c(2,2))  
> hist(cordistsim(1000, 10, 0))  
> hist(cordistsim(1000, 10, 0.5))  
> hist(cordistsim(1000, 100, 0))  
> hist(cordistsim(1000, 100, 0.5))
```




bootstrapデモ


- 関数(R用)、使い方
 - http://case.f7.ems.okayama-u.ac.jp/simulation/bootstrap/bootstrap_r.html
- 関数(S-PLUS用)
 - <http://face.f7.ems.okayama-u.ac.jp/~t2/pukiwiki/index.php?bootstrap>

bootstrapdemo

```
> x<-c(1,23,23,32,41,22,18,19,23)  
> bootstrapdemo(x, 100)
```



10回目



100回目

Bootstrap Distribution

