

기초통계학 추측통계영역 교육시 R의 활용에 대한 연구

장대흥¹

¹부경대학교 수리과학부 통계학전공

(2009년 4월 접수, 2009년 5월 채택)

요약

대학교 기초통계학 교육 시 우리는 통계패키지로서 R을 사용할 수 있다. R은 대화식 처리방식을 따르기 때문에 실행결과를 즉시 볼 수 있다. 또한 R에서의 그래픽스는 아주 강력하다. 그리고 가장 큰 장점은 R의 사용이 무료라는 것이다. 이러한 많은 장점을 갖고 있는 R을 대학교 기초통계교육 현장에서 사용하는 표준 통계패키지로서 고려할 필요가 있다. 본 논문은 기초통계학 내용 중 추측통계 영역을 대상으로 R의 활용에 대하여 기술하고자 한다.

주요용어: 기초통계학 교육, R 패키지.

1. 서론

기초통계학 강의 중 추측통계 영역은 기술통계 영역에 비하여 상대적으로 많은 비중을 차지한다. 예로 김진경 등 (2008)이 저술한 기초통계학 교재를 보면 기술통계 영역이 전체 분량의 25%, 추측통계 영역이 75%를 차지한다. 이처럼 기초통계학 내용 중 추측통계 영역의 비중은 매우 크고 통계모형을 다루는 영역이기 때문에 학생들이 기초통계학을 배우기 어려워하는 시발점이 된다. 이러한 추측통계 영역에서 R을 어떻게 활용하면 학생들이 나오되지 않고 강사의 강의를 잘 이해하고 통계학의 여러 개념들을 습득할 수 있는 지를 살피고자 한다.

기초통계학 내용 중 기술통계 영역뿐만 아니라 추측통계 영역에서도 R은 유용한 통계패키지가 될 수 있다. R은 많은 다양한 분포에 대하여 확률밀도함수, 누적분포함수, 분위수, 확률변수를 제공한다. 또한 우리는 기초통계학에서 언급되는 통계기법들을 모두 R로 구현하여 볼 수 있다.

본 논문은 기초통계학 내용 중 추측통계 영역을 대상으로 R의 활용에 대하여 기술하고자 한다. 2절에서는 저자 본인의 강의 경험을 바탕으로 추측통계 영역에서 R을 어떻게 활용할 수 있는 지에 대하여 생각하여 보고 3절에서는 표본추출분포부터 검정까지 예제들과 이 예제들을 풀기 위한 R 프로그램을 제시하였다. 본 논문에서 제시하지 않은 기술통계영역(표와 자료를 통한 자료의 요약, 수치를 통한 연속형자료의 요약, 두 변수 자료의 요약), 추측통계영역인 확률, 이항분포와 그에 관련된 분포들, 정규분포, 두 모집단의 비교, 회귀분석 부분은 저자의 홈페이지(<http://myweb.pknu.ac.kr/daeheung>) 내 강의자료실에 pdf 파일로 탑재되어 있다. 4절에서 결론을 맺었다.

2. R의 활용

본 저자는 2007년 1학기와 2학기에 각 1반씩 기초통계학 강의에서 R을 활용하여 보았다. 매 학기 강의는 두 모집단의 비교까지 진도가 나갔다. 교재로는 김진경 등 (2008)이 저술한 기초통계학 교재를 사용

¹(608-737) 부산시 남구 대연3동 599-1 부경대학교 수리과학부 통계학전공, 교수. E-mail: dhjang@pknu.ac.kr

하였다. 이 교재는 통계소프트웨어로서 엑셀을 사용한다. 엑셀의 사용은 학생 개개인들이 사용해보도록 권장하고 엑셀과 R을 비교하여 보도록 하였다.

R을 사용하기 위해서는 명령어들의 문법을 일일이 알아야하는 번거로움이 있어 학생들이 R을 사용하는 데 걸림돌이 된다. 이를 완화시키기 위하여 R Commander (Fox, 2005 참조)를 학생들에게 소개하고 R과 병행하여 사용하도록 권장하였다. R Commander는 2009년 4월 6일 현재 버전 1.4-7이 개발되어 있다. 기초통계학 강의에서 각 장의 내용을 가르치며 예제들을 R로 구현하여 학생들에게 제시하였다. R을 기본으로 하고 보조수단으로서 R Commander에 교수데모(teaching demos('RcmdrPlugin.TeachingDemos'))가 들어가 있는 R Commander를 사용하였다. 교수데모가 들어가 있는 R Commander는 다음과 같은 특징이 있다.

1. R Commander상의 9개의 주 메뉴(File, Edit, Data, Statistics, Graphs, Models, Distributions, Tools, Help) 외에 'Demos'라는 주메뉴가 있고 이 'Demos' 메뉴 하에 7개의 데모용 부메뉴(Central limit theorem(중심극한정리 데모), Confidence interval for the mean(모평균에 대한 신뢰구간 데모), Power of the test(검정력 데모), Flip a coin(동전던지기 데모), Roll a die(주사위굴리기 데모), Simple linear regression(단순선형회귀분석 데모), Simple correlation(상관계수 데모))가 있다. 중심극한정리 데모를 이용하면 학생들이 중심극한 정리의 의미를 파악할 수 있고, 모평균에 대한 신뢰구간 데모를 통해서 학생이 모평균에 대한 신뢰구간의 의미를 알 수 있고, 검정력 데모를 이용하면 학생들이 제1종 오류와 제2종 오류와의 관계를 쉽게 파악할 수 있고, 동전던지기 데모와 주사위굴리기 데모를 이용하면 동전던지기과 주사위굴리기를 시뮬레이션할 수 있다. 단순선형회귀분석 데모를 통하여 학생들이 회귀분석의 의미를 알 수 있고, 상관계수 데모를 통하여 학생들이 상관계수의 의미를 파악할 수 있다. 이 모든 데모들이 동적그래픽스로 구현된다.
2. 주 메뉴 'Distributions' 하에 연속형과 이산형 분포들 각각에 대하여 분위수, 누적분포함수, 분포(확률질량함수나 확률밀도함수)의 그림, 분포에 따른 난수를 구하는 부메뉴들 외에 'Visualize distributions'라는 부메뉴가 있다. 4가지 분포(이항분포, 정규분포, t -분포, 감마분포)에 대하여 모수들을 조정해가며 분포들의 변하는 모습을 실시간으로 동적그래픽스로 구현하여 볼 수 있다.

기초통계학 내용 중 강사들이 가르치는 추측통계학 영역은 다음과 같다.

1. 확률
2. 이항분포와 그에 관련된 분포들
3. 정규분포
4. 표본추출분포
5. 구간추정
6. 검정
7. 두 모집단의 비교
8. 회귀분석

1학기 분량의 기초통계학 강의는 통상 두 모집단의 비교까지 진도가 나가며 조금 진도가 빠른 경우라면 회귀분석도 취급할 수 있다.

3. R의 활용 예

예제들은 김진경 등 (2008)이 저술한 기초통계학 교재에 나오는 예들을 중심으로 사용하였다. 기초통계학 내용 중 추측통계 영역에 대해서 기술하고자 한다.




그림 3.1. 정규분포 $N(3, 2^2)$ 에서 추출한 표본추출분포

3.1. 표본추출분포

표본추출분포는 표본평균의 분포를 중심으로 전개되나 표본비율과 표본분산의 분포에 대해서도 고려해 볼 필요가 있다. 중심극한정리는 모집단의 분포가 이산적이든 연속적이든, 대칭적이든 비대칭적이든 상관없이 평균과 분산이 존재하면 표본의 크기가 30개 이상일 때 표본평균의 분포가 근사적으로 정규분포를 이룬다는 정리임으로 이 사실을 R을 이용한 컴퓨터시뮬레이션을 실행하여 각인시킨다.

예제 3.1: (a) 대칭분포인 평균이 3이고 표준편차가 2인 정규분포에서 표본을 4개 뽑아 표본평균, 표본중앙값, 표본분산, 표본표준편차를 구하는 과정을 1,000번 시행한 후 표본평균, 표본중앙값, 표본분산, 표본표준편차의 분포를 히스토그램으로 나타내어 보고 $E(\bar{X}) = \mu$, $Var(\bar{X}) = \sigma^2/n$ 이고 $E(S^2) = \sigma^2$ 임을 계산하여 보아라. (b) 자유도가 5인 카이제곱분포는 평균이 5이고 분산이 10이 된다. 또한, 이 카이제곱분포는 전형적인 오른쪽으로 치우친 비대칭분포이다. 이 카이제곱분포에서 표본을 4개 뽑아 표본평균, 표본중앙값, 표본분산, 표본표준편차를 구하는 과정을 1,000번 시행한 후 표본평균, 표본중앙값, 표본분산, 표본표준편차의 분포를 히스토그램으로 나타내어 보고 $E(\bar{X}) = \mu$, $Var(\bar{X}) = \sigma^2/n$ 이고 $E(S^2) = \sigma^2$ 임을 계산하여 보아라.

풀이: (a) 다음 그림 3.1은 평균이 3이고 표준편차가 2인 정규분포에서 표본을 4개 뽑아 표본평균, 표본중앙값, 표본분산, 표본표준편차를 구하는 과정을 1,000번 시행한 후 표본평균, 표본중앙값, 표본분산, 표본표준편차의 분포를 히스토그램으로 나타낸 그림이다. 표본의 크기에 관계없이 표본평균의 분포는 대칭분포가 된다. 표본표준편차의 분포는 오른쪽으로 치우친 분포, 표본분산은 오른쪽으로 매우 치우친 분포가 된다.

그림 3.1을 그리기 위한 R 스크립트는 다음과 같다,

(표본평균, 표본중앙값, 표본분산, 표본표준편차의 분포)

```
# 평균이 3이고 표준편차가 2인 정규분포에서
# 표본의 크기가 4인 확률표본을 1000번 구하기
r.mean=rep(0,1000);r.median=rep(0,1000);r.var=rep(0,1000);r.sd=rep(0,1000)
for(i in seq(1000))
r=rnorm(n=4,mean=3,sd=2)
r.mean[i]=mean(r);r.median[i]=median(r);r.var[i]=var(r);r.sd[i]=sd(r)
par(mfrow=c(2,2))
hist(r.mean,xlim=c(-5,10),xlab="표본평균",main="표본평균의 분포")
hist(r.median,xlim=c(-5,10),xlab="표본중앙값",main="표본중앙값의 분포")
hist(r.var,xlab="표본분산",main="표본분산의 분포")
hist(r.sd,main="표본표준편차의 분포")
```

이렇게 구한 통계량들의 평균, 분산, 표준편차를 구하면 다음과 같다. 난수에 따른 계산상의 작은 차이를 무시하면 $E(\bar{X}) = \mu$, $\text{Var}(\bar{X}) = \sigma^2/n$ 이고 $E(S^2) = \sigma^2$ 임을 알 수 있다. 또한, 표본평균의 분산이 표본중앙값의 분산보다 작음을 알 수 있고, $E(S) < \sigma$ 임을 알 수 있다.

```
> # 표본평균, 표본중앙값, 표본분산, 표본표준편차의 기대값, 분산, 표준편차
> mean(r.mean);mean(r.median);mean(r.var);mean(r.sd)
[1] 3.055991
[1] 3.043938
[1] 4.097572
[1] 1.865406
> var(r.mean);var(r.median);var(r.var);var(r.sd)
[1] 0.9890213
[1] 1.214045
[1] 11.08310
[1] 0.6184521
> sd(r.mean);sd(r.median);sd(r.var);sd(r.sd)
[1] 0.9944955
[1] 1.101837
[1] 3.32913
[1] 0.7864173
```

(b) 다음 그림 3.2는 자유도가 5인 카이제곱분포에서 표본을 4개 뽑아 표본평균, 표본중앙값, 표본분산, 표본표준편차를 구하는 과정을 1,000번 시행한 후 표본평균, 표본중앙값, 표본분산, 표본표준편차의 분포를 히스토그램으로 나타낸 그림이다. 표본이 4개임에도 불구하고 표본평균의 분포는 대칭분포가 되려고 노력하고 있음을 알 수 있고 표본표준편차의 분포는 오른쪽으로 치우친 분포, 표본분산은 오른쪽으로 매우 치우친 분포가 된다.

그림 3.2를 그리기 위한 R 스크립트는 다음과 같다.

```
# (표본평균, 표본중앙값, 표본분산, 표본표준편차의 분포)
# 자유도가 5인 카이제곱분포에서
# 표본의 크기가 4인 확률표본을 1000번 구하기
```




그림 3.2. 자유도가 5인 카이제곱분포에서 추출한 표본추출분포

```
r.mean=rep(0,1000);r.median=rep(0,1000);r.var=rep(0,1000);r.sd=rep(0,1000)
for(i in seq(1000))
r=rchisq(n=4,df=5)
r.mean[i]=mean(r);r.median[i]=median(r);r.var[i]=var(r);r.sd[i]=sd(r)
par(mfrow=c(2,2))
hist(r.mean,xlim=c(0,20),main="표본평균의 분포")
hist(r.median,xlim=c(0,20),main="표본중앙값의 분포")
hist(r.var,main="표본분산의 분포")
hist(r.sd,main="표본표준편차의 분포")
```

이렇게 구한 통계량들의 평균, 분산, 표준편차를 구하면 다음과 같다. 난수에 따른 계산상의 작은 차이를 무시하면 $E(\bar{X}) = \mu$, $Var(\bar{X}) = \sigma^2/n$ 이고 $E(S^2) = \sigma^2$ 임을 알 수 있다. 또한, 표본평균의 분산이 표본중앙값의 분산보다 작음을 알 수 있고, $E(S) < \sigma$ 임을 알 수 있다.

```
> # 표본평균, 표본중앙값, 표본분산, 표본표준편차의 기대값, 분산, 표준편차
> mean(r.mean);mean(r.median);mean(r.var);mean(r.sd)
[1] 4.958888
[1] 4.599006
[1] 10.09648
[1] 2.819139
> var(r.mean);var(r.median);var(r.var);var(r.sd)
[1] 2.495527
[1] 2.687176
[1] 125.3678
```




그림 3.3. 편차제곱합

```
[1] 2.151090
> sd(r.mean);sd(r.median);sd(r.var);sd(r.sd)
[1] 1.579724
[1] 1.639261
[1] 11.19678
[1] 1.466659
```

예제 3.2: 확률표본을 X_1, X_2, \dots, X_n 이라 할 때 (a) 편차제곱합 $\sum_{i=1}^n (X_i - M)^2$ 을 최소화하는 값 M 은 모평균, 표본평균, 표본중앙값 중 어느 것인가? (b) 편차절대값 $\sum_{i=1}^n |X_i - M|$ 을 최소화하는 값 M 은 모평균, 표본평균, 표본중앙값 중 어느 것인가?

풀이: (a) 이를 확인하기 위하여 표준정규분포로부터 10개의 표본을 뽑아 모평균, 표본평균, 표본중앙값을 M 으로 하여 편차제곱합을 구한다. 이러한 과정을 100번 시행한 결과가 다음 그림 3.3이다. 100번 시행한 결과 모두 표본평균을 M 으로 하여 구한 편차제곱합이 제일 작음을 알 수 있다.

그림 3.3을 그리기 위한 R 스크립트는 다음과 같다.

```
# 편차제곱합
A=matrix(rep(0,300),ncol=3)
plot(0:10,type="n",xlim=c(1,100),ylim=c(0,30),xlab="순서",ylab="편차제곱합")
for(i in 1:100)
x=rnorm(10)
mean.x=mean(x)
median.x=median(x)
A[i,1]=sum((x-0)^2)
A[i,2]=sum((x-mean.x)^2)
```




그림 3.4. 편차절대값의 합

```
A[i,3]=sum((x-median.x)^2)
points(i,A[i,1],pch=3)
points(i,A[i,2])
points(i,A[i,3],pch=4)
va=c(A[i,1],A[i,2],A[i,3])
lines(c(i,i),c(min(va),max(va)),lty=2)
legend(locator(1),c("모평균","표본평균","표본중앙값"),pch=c(3,1,4))
```

(b) 이를 확인하기 위하여 표준정규분포로부터 10개의 표본을 뽑아 모평균, 표본평균, 표본중앙값을 M 으로 하여 편차절대값의 합을 구한다. 이러한 과정을 100번 시행한 결과가 다음 그림 3.4이다. 100번 시행한 결과 모두 표본중앙값을 M 으로 하여 구한 편차절대값의 합이 제일 작음을 알 수 있다.

그림 3.4를 그리기 위한 R 스크립트는 다음과 같다.

```
# 편차절대값의 합
B=matrix(rep(0,300),ncol=3)
plot(0:15,type="n",xlim=c(1,100),ylim=c(0,15),xlab="순서",ylab="편차절대값의 합")
for(i in 1:100)
x=rnorm(10)
mean.x=mean(x)
median.x=median(x)
B[i,1]=sum(abs(x-0))
B[i,2]=sum(abs(x-mean.x))
B[i,3]=sum(abs(x-median.x))
points(i,B[i,1],pch=3)
points(i,B[i,2],pch=4)
```




그림 3.5. 표본비율의 분포

```
points(i,B[i,3])
vb=c(B[i,1],B[i,2],B[i,3])
lines(c(i,i),c(min(vb),max(vb)),lty=2)
legend(locator(1),c("모평균", "표본평균", "표본중앙값"),pch=c(3,4,1))
```

예제 3.3: 모비율이 $p = 0.3$ 인 임의의 모집단에서 표본을 100개 뽑아 원하는 속성을 갖고 있는 것의 개수를 세고 표본비율을 구하라. 이런 과정을 1,000번 시행한 후 표본비율의 분포를 히스토그램으로 그려라. 무엇을 알 수 있나?

풀이: 표본의 크기가 대표본이므로 표본비율의 분포는 그림 3.5에서 보는 것처럼 근사적으로 평균이 $p = 0.3$ 이고 표준편차가 $\sqrt{(pq)/n} = \sqrt{(0.3 \times 0.7)/100} \approx 0.0458$ 인 정규분포를 따른다.

그림 3.5를 그리기 위한 R 스크립트는 다음과 같다.

```
# (표본비율의 분포)
# 성공률 p=0.3인 모집단에서
# 표본의 크기가 100인 확률표본을 1000번 구하기
r.mean=rep(0,1000);r.var=rep(0,1000)
for(i in seq(1000))
r=rbinom(n=100,1,0.3)
r.mean[i]=mean(r)
# 표본비율의 기대값과 분산
mean(r.mean)
var(r.mean)
sd(r.mean)
# 표본비율의 분포
h=hist(r.mean,plot=F)
ylim=range(0,h$density,dnorm(0.3,mean=0.3,sd=0.0458))
```




그림 3.6. 모집단이 균등분포인 경우의 표본평균의 분포

```
hist(r.mean,prob=TRUE,ylim=ylim,xlab=" 표본비율",ylab=" 밀도",main="")
x1=seq(min(r.mean),max(r.mean),length=200)
y1=dnorm(x=x1,mean=0.3,sd=0.0458)
lines(x1,y1)
```

예제 3.4: 모집단이 균등분포일 때 중심극한정리가 성립함을 모의실험을 통하여 보여라.

풀이: 모집단이 균등분포 $f(x) = 1(0 \leq X \leq 1)$ 일 때 다음 그림 3.6과 같이 중심극한정리가 성립함을 모의실험을 통하여 보일 수 있다. 표본의 크기가 커짐에 따라 점점 표본평균의 분포가 정규분포가 됨을 알 수 있고 평균 0.5를 중심으로 점점 집중됨을 알 수 있다.

그림 3.6을 그리기 위한 R 스크립트는 다음과 같다.

```
# 중심극한정리-모집단: 균등분포
par(oma=c(0,0,5,0))
par(mfrow=c(2,2))
central.Uniform=function(a,b)
nt = c(5, 15, 30, 100)
xbar = rep(0,1000)
for(i in 1:4)
for(j in 1:1000)
xbar[j] = sum(runif(nt[i],a,b))/nt[i]
hist(xbar,main=paste(" 표본의 크기는",nt[i]),xlim=c(0,1),xlab=" 표본평균",ylab=" 도수")
mtext(" 중심극한정리-모집단: 균등분포",side=3,outer=T,cex=1.5)
central.Uniform(0,1)
```

3.2. 구간추정

신뢰구간의 의미를 파악하는 일은 매우 중요하다. R을 통하여 이 신뢰구간의 의미를 파악해 볼 수 있다.

예제 3.5: 다음 자료는 40명에 대하여 심장병을 줄이기 위한 한 주당 육체 훈련 양을 분 단위로 조사한 값이다.

```
60, 40, 50, 30, 60, 50, 90, 30, 60, 60, 60, 80, 90, 90, 60, 30, 20, 120, 60, 50,
20, 60, 30, 120, 50, 30, 90, 20, 30, 40, 50, 40, 30, 40, 20, 30, 60, 50, 60, 80
```

한 주당 평균적인 육체 훈련 양에 대한 95% 신뢰구간을 구하라.

풀이: 표본의 크기가 40개이어서 대표본이므로 다음과 같은 R 스크립트를 사용하여 정규분포를 이용한 95% 근사신뢰구간을 구하면 (45.54, 61.46)가 된다.

```
# 모평균에 대한 구간추정(대표본의 경우)
one.sample.z.confidence.interval=function(x, confidence.level)
n=length(x)
xbar=mean(x)
se=sd(x)/sqrt(n)
alpha.half=(1-confidence.level)/2
z.alpha.half=qnorm(1-alpha.half)
c(xbar-z.alpha.half*se,xbar+z.alpha.half*se)
x=c(60,40,50,30,60,50,90,30,60,60,60,80,90,90,60,30,20,120,60,50,
,20,60,30,120,50,30,90,20,30,40,50,40,30,40,20,30,60,50,60,80)
one.sample.z.confidence.interval(x,0.95)
```

이 경우 t -분포를 이용한 95% 신뢰구간을 다음과 같은 R 스크립트를 사용하여 구하면 (45.29, 61.71)이다. 정규분포를 이용한 신뢰구간보다 폭이 조금 큰 것을 확인할 수 있다.

```
t.test(x)
```

예제 3.6: 모평균에 대한 95% 신뢰구간을 구한다는 것은 이러한 신뢰구간을 100개 구하였을 때 95개의 신뢰구간이 모평균을 포함하고 5개의 신뢰구간은 모평균을 포함하지 않는다는 의미이다. 우리는 다음과 같은 시뮬레이션 (허문열 등 (2005)이 작성한 R 스크립트)을 통하여 정규분포를 이용한 모평균에 대한 95% 신뢰구간의 의미를 파악할 수 있다. 모집단이 평균이 0이고 표준편차가 1인 정규모집단이라 할 때 표본의 크기가 50개인 신뢰구간의 개수를 5,000개까지 만들어보며 신뢰구간이 모평균 0을 포함하는 비율을 계산하여 보면 다음 그림 3.7과 같이 95%에 수렴함을 알 수 있다.

```
# 허문열 등 (2005)이 작성한 R 스크립트
confidence.normal =
function(n, nz, mu, std)
trial = rep(1,nz)
z.val = qnorm(0.975)
x = matrix(rnorm(n*nz, mu, std), nrow=nz)
xbar = apply(x,1,mean)
```




그림 3.7. 95% 신뢰구간의 의미(1)

```
xvar = apply(x,1,var)
limit = z.val * sqrt(xvar/n)
xbar = xbar - mu
trial[abs(xbar) > limit] = 0
trial = cumsum(trial) / 1:nz
plot(trial,ylim=c(0.9,1),type="l",xlab="신뢰구간의 개수",ylab="모평균을 포함하는 비율")
abline(0.95, 0)
confidence.normal(50,5000,0,1)
```

위의 R 스크립트를 변형한 다음과 같은 시뮬레이션을 통하여 정규분포를 이용한 모평균에 대한 95% 신뢰구간의 의미를 다시 한 번 파악할 수 있다. 모집단이 평균이 0이고 표준편차가 1인 정규모집단이라 할 때 신뢰구간의 개수를 300개까지 만들어보며 신뢰구간이 모평균 0을 포함하는지의 여부와 그 비율을 계산하여 보면 다음 그림 3.8과 같이 95%에 대략 수렴함을 알 수 있다. 물론 그림 3.7처럼 시행횟수를 많이 하면 95%에 수렴함을 알 수 있다.

```
confidence.normal2 =
function(n, nz, mu, std)
par(mfrow=c(2,1))
trial = rep(1,nz)
z.val = qnorm(0.975)
x = matrix(rnorm(n*nz, mu, std), nrow=nz)
xbar = apply(x,1,mean)
xvar = apply(x,1,var)
limit = z.val * sqrt(xvar/n)
ulimit=xbar+limit
llimit=xbar-limit
xbar = xbar - mu
```




그림 3.8. 95% 신뢰구간의 의미(2)

```

trial[abs(xbar) > limit] = 0
trial = cumsum(trial) / 1:nz
plot(c(0,nz),c(-1.5,1.5),type="n",xlab="시행횟수",ylab="신뢰구간")
for (k in 1:nz)
  points(c(k,k),c(llimit[k],ulimit[k]),type="l")
abline(0, 0)
plot(trial,type="l",,xlab="시행횟수",ylab="모평균을 포함하는 비율")
par(mfrow=c(1,1))
confidence.normal2(50,300,0,1)

```

예제 3.7: 휘발유의 옥탄가(정규분포로 가정함.)를 13일 연속 조사하니 다음과 같았다.

88.6 86.4 87.2 88.4 87.2 87.6 86.8 86.1 87.4 87.3 86.4 86.6 87.1

옥탄가 모평균에 대한 95% 신뢰구간을 구하라.

풀이: 표본의 크기가 13개이어서 소표본이므로 t 분포를 이용한 95% 신뢰구간을 다음과 같이 구하면 (86.71, 87.61)이다.

```

> # 모평균에 대한 구간추정(소표본의 경우)
>
x=c(88.6,86.4,87.2,88.4,87.2,87.6,86.8,86.1,87.4,87.3,86.4,86.6,87.1)
> t.test(x)

```

One Sample t -test

data: x

t = 423.4101, df = 12, p-value < 2.2e-16




그림 3.9. 휘발유의 옥탄가에 대한 정규확률그림

```
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
86.71302 87.61006
sample estimates: mean of x
87.16154
```

참고로 만일 휘발유의 옥탄가에 대하여 정규분포로 가정한다는 가정이 없다면 우리는 자료가 정규분포를 이루는 지를 검토하여야 한다. 다음 3.9와 같은 정규확률그림을 그리고 Shapiro-Wilk 검정을 행하여 보면 p -값이 0.44로서 정규분포라 할 만하다는 결론을 내릴 수 있다.

```
> qqnorm(x,main="휘발유의 옥탄가에 대한 정규확률그림")
> qqline(x,col="red")
> shapiro.test(x)
```

Shapiro-Wilk normality test

```
data: x
W = 0.9386, p-value = 0.4395
```

예제 3.8: 어느 지역의 실업률을 조사하기 위하여 1,000명을 조사하니 15명이 실업자이었다. 모실업률에 대한 95% 신뢰구간을 구하라.

풀이: 피어슨의 카이제곱통계량을 이용한 95% 신뢰구간을 구하면 (0.0087, 0.0252)이다.

```
> # 모비율에 대한 구간추정-피어슨의 카이제곱통계량 이용
> prop.test(15,1000)
```

1-sample proportions test with continuity correction

```

data: 15 out of 1000, null probability 0.5
X-squared = 938.961, df = 1, p-value < 2.2e-16
alternative hypothesis: true p is not equal to 0.5
95 percent confidence interval:
0.008733248 0.025217456
sample estimates:
p
0.015

```

표본의 크기가 1,000개이어서 대표본이므로 다음과 같은 R 스크립트를 사용하여 정규분포를 이용한 95% 근사신뢰구간을 구하면 (0.0075, 0.0225)이다.

```

# 모비율에 대한 구간추정-근사정규분포 이용
one.sample.p.confidence.interval=function(n,x,confidence.level)
p.hat=x/n
se=sqrt(p.hat*(1-p.hat)/n)
alpha.half=(1-confidence.level)/2
z.alpha.half=qnorm(1-alpha.half)
c(p.hat-z.alpha.half*se,p.hat+z.alpha.half*se)
one.sample.p.confidence.interval(1000,15,0.95)

```

3.3. 검정

검정에서 제 1종 오류와 제 2종 오류 사이의 관계, 유의수준의 의미, 양측검정과 단측검정의 차이, p -값의 의미에 대하여 예를 들어가며 학생들에게 자세히 가르친다.

예제 3.9: 검정에서 제 1종 오류와 제 2종 오류 사이의 관계를 알기위하여 교수데모가 들어가 있는 R Commander에서 교수데모 중 검정력 데모를 보면 다음 그림 3.10과 같다. 귀무가설 $H_0 : \mu \leq \mu_0$, 대립가설 $H_1 : \mu > \mu_0$ 일 때 모표준편차가 σ 인 정규모집단에서 표본을 n 개 뽑을 때 제 1종 오류의 값을 α 로 놓으면 표준오차(standard error)는 $se = \sigma/\sqrt{n}$, 기각역(rejection region)은 $\bar{X} \geq \mu_0 + z_\alpha \sigma/\sqrt{n}$, 검정력(= 1 - 제 2종 오류)는 $r(\mu_1) = \Pr[Z \geq (\mu_0 - \mu_1)/(\sigma/\sqrt{n}) + z_\alpha]$ 이 된다. 그림 3.10에서는 $\mu_0 = 0$ 이다. $n = 10$, σ (Standard Deviation로 표시) = 2, $\mu_1 - \mu_0$ (True Difference로 표시) = 2, $\alpha = 0.05$ 로 선택하면 표준오차는 $se = 0.63$, 기각역에서 $z^* = \mu_0 + z_\alpha \sigma/\sqrt{n} = 1.04$, 검정력은 $r(2) = 0.935$ 가 된다. 제 1종 오류를 작게 하면 제 2종 오류가 커지고 제 1종 오류를 크게 하면 제 2종 오류가 작게 되는 반비례 관계가 성립하는 것을 동적 그래픽스로 확인할 수 있다.

예제 3.10: 35세에서 55세까지의 여성 100명에 대한 비만지수(BMI, body mass index)를 조사하니 표본평균이 25.12이고 표본표준편차가 5.3이었다. 비만지수가 25보다 크다고 할 수 있나? 유의수준 5%에서 검정을 행하라.

풀이: 가설은 다음과 같다.

$$H_0 : \mu \leq 25, \quad H_1 : \mu > 25$$




그림 3.10. 교수데모가 들어가 있는 R Commander에서 검정력 데모 화면

표본의 크기가 100개로 대표본이므로 정규검정을 다음과 같이 행할 수 있다. p -값이 0.410이므로 0.05보다 크므로 귀무가설을 기각할 수 없다. 즉 비만지수가 25보다 크다고 할 수 없다.

```
> # 모평균에 대한 검정(대표본의 경우)
> one.sample.z.test=function(mean.x,sd.x,n,alt,mu)
+ {
+ se=sd.x/sqrt(n)
+ z=(mean.x-mu)/se
+ if(alt=="큼") print(1-pnorm(z))
+ if(alt=="작음") print(pnorm(z))
+ if(alt=="같음") print(1-pnorm(abs(z))+pnorm(-abs(z)))
+ }
> one.sample.z.test(25.12,5.3,100,"큼",25)
[1] 0.4104393
```

예제 3.11: 다음 자료는 어느 체리농장에서 15개 지역의 수확량(단위: 에이커당 톤수)을 조사한 결과이다. 평균 수확량이 4.35t/acre보다 크다고 할 수 있는가? 유의수준 5%에서 검정을 행하라(단, 수확량은 정규분포를 이룬다고 가정하자).

3.56, 5.00, 4.88, 4.93, 3.92, 4.25, 5.12, 5.13, 5.35, 4.81, 3.48, 4.45, 4.72, 4.79, 4.45

풀이: 가설은 다음과 같다.

$$H_0 : \mu \leq 4.35, \quad H_1 : \mu > 4.35$$

표본의 크기가 15개로 소표본이므로 t 검정을 다음과 같이 행할 수 있다. p -값이 0.063이므로 0.05보다 크므로 귀무가설을 기각할 수 없다. 즉 평균 수확량이 4.35t/acre보다 크다고 할 수 없다.




그림 3.11. 체리수확량에 대한 정규확률그림

```
> # 모평균에 대한 검정(소표본의 경우)
> x=c(3.56,5.00,4.88,4.93,3.92,4.25,5.12,5.13,5.35,4.81,3.48,4.45,4.72,4.79,4.45)
> t.test(x,alt="greater",mu=4.35)
```

One Sample *t*-test

```
data: x
t = 1.6314, df = 14, p-value = 0.06255
alternative hypothesis: true mean is greater than 4.35
95 percent confidence interval:
4.330935 Inf
sample estimates: mean of x
4.589333
```

참고로 만일 정규모집단이라는 가정이 없다면 검정을 행하기 전 자료를 이용하여 정규모집단이라고 할 수 있는지를 검토하여야 한다. 다음 그림 3.11과 같은 정규확률그림 및 Shapiro-Wilk 검정을 통하여 정규모집단이라고 할 수 있다.

```
> qqnorm(x,main=" 체리수확량에 대한 정규확률그림")
> qqline(x,col="red")
> shapiro.test(x)
```

Shapiro-Wilk normality test

```
data: x
W = 0.9109, p-value = 0.1396
```

예제 3.12: 인스턴트커피와 원두커피에 대한 선호도를 조사하기 위하여 100명을 대상으로 구별이 불가능한 두 개의 잔에 각각의 커피를 따른 후 좋아하는 커피를 선택하도록 하였더니 61명이 원두커피를 선호하였다. 원두커피에 대한 선호도가 65%보다 작다고 주장할 수 있는 지 유의수준 5%에서 검정을 행하라.

풀이: 가설은 다음과 같다.

$$H_0 : p \geq 0.65, \quad H_1 : p < 0.65$$

표본의 크기가 100개로 대표본이므로 정규검정을 다음과 같이 행할 수 있다. p -값이 0.232로서 0.05보다 크므로 귀무가설을 기각할 수 없다. 즉 선호도가 65%보다 작다고 할 수 없다. R에서는 모비율의 검정에서 피어슨의 카이제곱통계량을 이용하여 검정을 행한다.

```
> # 모비율에 대한 검정
> prop.test(61,100,p=0.65,alt="less")
```

1-sample proportions test with continuity correction

```
data: 61 out of 100, null probability 0.65
X-squared = 0.5385, df = 1, p-value = 0.2315
alternative hypothesis: true p is less than 0.65
95 percent confidence interval:
0.0000000 0.6910052
sample estimates:
p
0.61
```

4. 결론

R을 대학교 기초통계학 추측통계 영역 강의 시 활용하는 문제에 대하여 앞 절에서 살펴보았다. 추후 과제로서 한 학기 기초통계학 추측통계 영역 강의 시 통계패키지로서 기초통계학용 R GUI인 R Commander를 활용하는 연구가 있겠다.

참고문헌

- 김진경, 박진호, 박헌진, 이재준, 전용석, 황진수 (2008). <통계학-엑셀을 이용한 분석>, 자유아카데미.
 허문열, 이승천, 차경준, 박종선, 유종영 (2005). <R & 통계계산>, 박영사.
 Fox, J. (2005). The R commander: A basic-statistics graphical user interface to R, *Journal of Statistical Software*, 14, 1-42.

Applications of R for Inferential Statistics in the Elementary Statistics Course

Dae-Heung Jang¹

¹Division of Mathematical Sciences, Pukyong National University

(Received April 2009; accepted May 2009)

Abstract

We can use R package as a statistical package on the statistical education for college students. R is an interactive mode package and graphical presentation tools are powerful in R. The greatest advantage is that R is a general public license package. We need to consider R package as a standard statistical package on the statistical education for college students. We can consider the applications of R for inferential statistics in elementary statistics course.

Keywords: Statistical education, R package.

¹Professor, Division of Mathematical Sciences, Pukyong National University, 599-1 Daeyeon-dong, Nam-gu, Busan 608-737, Korea. E-mail: dhjang@pknu.ac.kr