

## ANALÝZA ROZPTYLU (JEDNODUCHÉ TŘÍDĚNÍ)

11.1.2018

## ÚVODNÍ NASTAVENÍ.

– Z internetové stránky [www.karlin.mff.cuni.cz/~hudecova/education/](http://www.karlin.mff.cuni.cz/~hudecova/education/) si stáhněte data `Med.txt`.

– Otevřete si program R Studio a načtěte si výše uvedená data

```
setwd("H:/nmsa331")
rm(list=ls())
Med=read.table("Med.txt",header=T)
```

POPIS DAT. Na pěti různých místech A, B, C, D a E bylo z řeky vyloveno vždy 7 ryb a byla zjišťována koncentrace mědi v jejich játrech. Naměřená data jsou obsažena v datech `Med.txt`. Otázkou je, zda je znečištění řeky stejné na všech zkoumaných místech nebo zda se nějak významně liší.

1. Prohlédněte si data `Med.txt`. V analýze budeme pracovat s logaritmem koncentrace, tj. s proměnnou `lnCu`.

- Podívejte se, kolik máme pozorování pro jednotlivá místa A, B, C, D a E.
- Porovnáme průměry a směrodatné odchylky na jednotlivých místech. Vše si znázorníme i graficky.

```
attach(Med)
tapply(lnCu,Misto,mean)
tapply(lnCu,Misto,sd)

boxplot(lnCu~Misto,col="orange")
```

2. Na náš problém budeme chtít použít analýzu rozptylu. Připomeňte si, jaké všechny předpoklady tato metoda má a posuďte graficky, zda se zdají být tyto předpoklady v našich datech splněny nebo nikoliv.

3. Dále si připomeňte, na jakých principech je analýza rozptylu založena: co je to celkový součet čtverců, součet čtverců skupin a reziduální součet čtverců.

Jednotlivé body a průměry si můžeme znázornit i graficky:

```
(prumery=tapply(lnCu,Misto,mean))
plot(lnCu~as.numeric(Misto), ,col="gray40", cex=1,pch=19,
      xlab="Misto",xaxt="n",xlim=c(0.5,5.5))
mtext(levels(Misto),1,line=1.2,at=1:5)
points(prumery~c(1:5),col="blue",pch=17,cex=1.2)
(celk.prumer=mean(lnCu))
abline(h=celk.prumer,col="red",lwd=2)
```

4. Otestujte, zda je znečištění řeky na zkoumaných pěti místech stejné. Formulujte  $H_0$  a  $H_1$ . Test provedeme následovně:

```

model<-aov(lnCu~Misto)
anova(model)
#totez jako
summary(model)

```

5. Nyní si spočítáme jednotlivé položky z tabulky manuálně.

```

(ni=table(Misto))
(N=sum(ni))
(SSc=sum((lnCu-celk.prumer)^2) )
(SSa=sum(ni*(prumery-celk.prumer)^2))
(SSe=sum((lnCu-fitted(model))^2))
# nebo zde taky takto:
(SSe=sum((lnCu-rep(prumery,7))^2))

p=length(levels(Misto))

SSa/(p-1)
SSe/(N-p)

# testova statistika
(Fa=SSa/(p-1)/(SSe/(N-p)))

# p-hodnota
1-pf(Fa,df1=p-1,df2=N-p)

```

6.  $F$ -test analýzy rozptylu zamítl nulovou hypotézu shody středních hodnot a prokázal, že existují (alespoň dvě) místa v řece, kde se znečištění statisticky významně liší. Přirozeně nás tedy zajímá, která místa řeky se od sebe významně liší co se týče znečištění. Jinými slovy nás zajímá porovnání znečištění v místě  $i$  a místě  $j$  pro všechna  $i \neq j$ .

- Jak bychom postupovali, kdybychom chtěli provést pouze jedno porovnání míst A a B?
- Kolik porovnání musíme provést, když chceme porovnat všechny dvojice?
- Uvažujte hypotetickou situaci, kdy uvažujeme sto různých nulových hypotéz a jim odpovídajících sto různých testů. Nechť jsou tyto testy nezávislé a všechny provádíme na hladině 5%. Předpokládejme, že všechny nulové hypotézy platí.
  - Kolik budeme očekávat falešných zamítnutí?
  - Jaká je pravděpodobnost, že alespoň jeden test falešně zamítne platnou nulovou hypotézu?
  - Jak se předchozí čísla změni, budeme-li uvažovat 20 hypotéz a jim příslušných nezávislých testů?

Z výše uvedených důvodů provedeme mnohonásobné porovnání pomocí Bonferroniho metody. Porovnáme tedy všechny dvojice  $(i, j)$  na hladině významnosti  $\alpha/m$ , kde  $m$  je počet porovnání z (b).

```
lev.mista=levels(Misto)
```

```

alpha=0.05
m=5*4/2

#vsechny testy na hladine:
alpha/m
for(i in 1:4) for(j in (i+1):5){
  print(paste(lev.mista[i], "-", lev.mista[j]))
  print(t.test(lnCu[Misto==lev.mista[i]], lnCu[Misto==lev.mista[j]])$p.val, var.equal=T)
}

```

Které místa se významně liší?

Můžeme si vytvořit i přehlednější výstup:

```

tabulka=matrix(0, ncol=4, nrow=m)
rownames(tabulka)=1:10
k=1
for(i in 1:4) for(j in (i+1):5){
  rownames(tabulka)[k]=paste(lev.mista[i], "-", lev.mista[j])
  test=t.test(lnCu[Misto==lev.mista[i]], lnCu[Misto==lev.mista[j]],
    conf.level = 1-alpha/m, var.equal=T)
  int=test$conf.int
  tabulka[k,1]=test$estimate[1]-test$estimate[2]
  tabulka[k,2]=int[1]
  tabulka[k,3]=int[2]
  tabulka[k,4]=ifelse(test$p.val<alpha/m, 1, 0)
  k=k+1
}
tabulka

```

7. Při vyšším počtu porovnání (tj. vyšším počtu kategorií) bývá Bonferroniho metoda příliš přísná. Existují tedy i specializované metody pro mnohonásobné porovnání, např. tzv. Tukeyho metoda.

```

TukeyHSD(model)
plot(TukeyHSD(model))

```

Na kterých místech v řece se znečištění statisticky významně liší?

8. V případě, že nelze předpokládat shodu rozptylů, můžeme namísto  $F$ -testu analýzy rozptylu použít Welchovu variantu testu, která je jakýmsi zobecněním Welchova dvouvýběrového  $t$ -testu pro více výběrů, viz skripta str. 129. Tento test využívá asymptotické chování příslušné testové statistiky pro  $n_i \rightarrow \infty$ ,  $n_i/N \rightarrow \lambda > 0$ . V našem případě máme  $n_i = 7$ , takže užití asymptotického testu není vhodné, ale ukážeme si, jak bychom jej v R zavolali:

```
oneway.test(lnCu~Misto)
```

V případě zamítnutí nulové hypotézy tímto testem, pak opět provedeme mnohonásobné porovnání, a to pomocí Bonferroniho metody a Welchova testu (Tukeyho metoda předpokládá shodu rozptylů, takže ji v tomto případě nelze použít).

Manuální výpočet (viz vzorec ze skript):

```
(Si2=tapply(lnCu,Misto,var))
(wi=ni/Si2)
(Lambda=sum(1/(ni-1)*(1-wi/sum(wi))^2)/(p^2-1))
(Ywbar=weighted.mean(prumery,w=wi))
(FW=sum(wi*(prumery-Ywbar)^2)/(p-1)*1/(1+2*Lambda*(p-2)))
oneway.test(lnCu~Misto)$stat

#df
oneway.test(lnCu~Misto)$param
1/(3*Lambda)

#p-hodnota
1-pf(FW,p-1,1/(3*Lambda))
oneway.test(lnCu~Misto)$p.val
```

9. Podíváme se, jaký je vztah dvouvýběrového t-testu a analýzy rozptylu pro případ  $p = 2$ . Z našich dat si tedy vybereme pouze místa A a B a ta porovnáme jak t-testem, tak pomocí  $F$ -testu.

```
detach(Med)
AB=Med[Med$Misto=="A"|Med$Misto=="B",]
AB$Misto=factor(AB$Misto)

(t=t.test(lnCu~Misto,data=AB,var.equal=T))
(a=anova(modelAB<-aov(lnCu~Misto,data=AB)))

#porovnaní testových statistik a p-hodnot
t$stat^2
a$F
t$p.val
a$Pr
```

Pomocí jakých rozdělení jsou spočtené výše uvedené p-hodnoty?

Podobné srovnání pak dostaneme pro Welchův test a Welchovu statistiku jednoduchého třídění

```
t.test(lnCu~Misto,data=AB)
oneway.test(lnCu~Misto,data=AB)
```

## SAMOSTATNÁ PRÁCE

- Data `dieta.txt` porovnávají efekt tří diet na hubnutí. Pro 76 osob máme k dispozici jejich pohlaví, věk, výšku, typ diety (kódováno 1, 2 a 3) a hmotnost před a po 6 týdnech diety. Zajímá nás, zda mají zkoumané tři diety stejný vliv na úbytek hmotnosti, nebo zda je mezi nimi významná odlišnost.

(a) Načtení dat

```

dieta=read.table("dieta.txt",header=T)
summary(dieta)
dim(dieta)
head(dieta)

dieta$ubytkek=dieta$pre.weight-dieta$weight6weeks
dieta$Diet=factor(dieta$Diet)

attach(dieta)
table(Diet)

```

- (b) Zkoumaný problém si vizualizujte pomocí boxplotů. Dále si spočtete průměry a směrodatné odchylky jednotlivých kategorií (použijte příkaz `tapply`). Podívejte se také na QQ grafy úbytků hmotnosti pro jednotlivé diety a posuďte splnění předpokladů analýzy rozptylu.
- (c) Pomocí analýzy rozptylu otestuje shodu středních hodnot úbytků hmotnosti pro zkoumané tři diety.
- (d) Pomocí mnohonásobného porovnání (Bonferroniho nebo Tukeyho metodou) zjistěte, které diety se od sebe významně liší.

2. Podívejte se na hustoty  $F_{m,n}$  rozdělení pro různé  $n$  a  $m$ .

```

curve(df(x,4,30),lwd=2,0,4,ylab="f",xlab="x",ylim=c(0,1))
curve(df(x,4,100),lwd=2,add=T,col="red")
curve(df(x,4,1000),lwd=2,add=T,col="brown")
curve(df(x,8,30),lwd=2,add=T,col="darkgreen")
curve(df(x,8,100),lwd=2,add=T,col="purple")
curve(df(x,8,1000),lwd=2,add=T,col="blue")
legend("topright",c("F(4,30)","F(4,100)","F(4,1000)","F(8,30)","F(8,100)","F(8,1000)",
col=c("black","red","brown","darkgreen","purple","blue"),lty=rep(1,6),lwd=rep(2,6))

```

- (a) Ověřte (přibližně graficky), zda je pravda, že hustota  $F_{n,m}$  rozdělení dosahuje maximum v bodě  $\frac{n-2}{n} \frac{m}{m+2}$ .
- (b) Jak se chová  $F_{m,n}$  rozdělení pro  $m$  pevné a  $n \rightarrow \infty$ ? Porovnejte grafy hustot  $F_{m,n}$  pro nějaké pevně zvolené  $m$  (malé) a  $n$  (velké) s tímto limitním rozdělením.
- (c) Podobně si vykreslete graf distribuční funkce (namísto `df` použijte `pf`) a sledujte, jak se chová  $F_{n,m}$  rozdělení pro  $n, m \rightarrow \infty$ . Zdůvodněte vše i teoreticky.

3. Závěrečné opakování: Rozhodněte, jaký test (postup) byste použili pro zkoumání následujících problému vztahujících se k datům `dieta.txt`:

- Měla dieta 1 efekt na hubnutí? Tj. mají osoby po jejím absolvování nižší hmotnost než před tím?
- Je pravdivé tvrzení, že díky dietě 3 lidé zhubnou v průměru více než 5 kg?
- Závisí úbytek hmotnosti na pohlaví?
- Je pravděpodobnost zhubnutí stejná pro muže a pro ženy?
- Jsou věkové skupiny  $< 30$  let,  $30 - 50$  let,  $> 50$  zastoupeny v populaci hubnoucích lidí v poměru  $1 : 2 : 1$ ?
- Je pravděpodobnost zhubnutí stejná pro výše uvedené tři věkové skupiny?