

# Estatística Básica e Experimentação no R

Walmes Marques Zeviani\*

## Sumário

<b>1</b>	<b>Introdução à manipulação de objetos e funções</b>	<b>3</b>
1.1	Instalação do R . . . . .	3
1.2	Pedindo ajuda . . . . .	3
1.3	Criação, atribuição, acesso e modificação de objetos . . . . .	4
1.4	Informações sobre objetos (atributos) . . . . .	5
1.5	Operações matemáticas . . . . .	6
1.6	Operações estatísticas . . . . .	6
1.7	Construindo funções . . . . .	7
<b>2</b>	<b>Importação de dados e análise exploratória</b>	<b>8</b>
2.1	Importando dados . . . . .	8
2.2	Explorações gráficas (1) . . . . .	9
2.3	Explorações gráficas (2) . . . . .	9
2.4	Recursos gráficos avançados . . . . .	10
<b>3</b>	<b>Regressão linear</b>	<b>11</b>
3.1	Importando e manipulando dados . . . . .	11
3.2	Régressão linear simples . . . . .	12
3.3	Régressão linear múltipla . . . . .	12
3.4	Seleção de modelos/variáveis . . . . .	13
3.5	Remoção de pontos discrepantes . . . . .	13
3.6	Predição de valores a partir do modelo escolhido . . . . .	14
3.7	Representação gráfica do ajuste . . . . .	14
3.8	Mais sobre análise de resíduos e $R^2$ (quarteto de Anscombe) . . . . .	15
<b>4</b>	<b>Regressão não linear</b>	<b>15</b>
4.1	Motivação . . . . .	15
4.2	Definição . . . . .	16
4.3	Exemplo de modelos não lineares . . . . .	16
4.4	Uso de recursos gráficos para entender o significado dos parâmetros . . . . .	17
4.5	Estimação de parâmetros em modelos não lineares . . . . .	18
4.6	Ajuste de modelo não linear aos dados de DAP . . . . .	19
4.7	Comparação de curvas ajustadas . . . . .	21
4.8	Ajuste de modelos não lineares com a library{nlme} . . . . .	22

---

\*Documento concluído em 1 de dezembro de 2010 às 18:08:02 – Centro Politécnico – Universidade Federal do Paraná.

<b>5 Análise de experimento com um fator em DIC</b>	<b>23</b>
5.1 Importando dados . . . . .	23
5.2 Análise de variância . . . . .	24
5.3 Aplicando teste de Tukey para comparar médias . . . . .	24
5.4 Aplicando teste de Scott-Knott para agrupar médias . . . . .	24
5.5 Aplicando contrastes . . . . .	25
5.6 Estudo das taxas de erro tipo I dos testes . . . . .	25
<b>6 Análise de experimentos de um fator em DBC</b>	<b>26</b>
6.1 Entrada de dados . . . . .	26
6.2 Análise de variância . . . . .	26
6.3 Teste de médias . . . . .	27
6.4 Observações perdidas . . . . .	27
<b>7 Análise de experimento fatorial duplo em DIC</b>	<b>28</b>
7.1 Análise de variância . . . . .	28
7.2 Testes de médias . . . . .	29
<b>8 Análise de fatorial duplo em DBC</b>	<b>30</b>
8.1 Entrando com os dados . . . . .	30
8.2 Análise de variância e desdobramento das somas de quadrados . . . . .	30
8.3 Desdobramento da interação com testes de médias . . . . .	31
<b>9 Análise de experimento fatorial com um tratamento adicional</b>	<b>32</b>
<b>10 Análise de covariância</b>	<b>33</b>
10.1 Análise de variância . . . . .	33
10.2 Constraste entre níveis dos fatores . . . . .	34
<b>11 Experimento fatorial com fatores qualitativos e quantitativos</b>	<b>35</b>
11.1 Desdobramento da interação . . . . .	35
11.2 Obtenção das equações de regressão e $R^2$ . . . . .	36
<b>12 Fatorial com fatores quantitativos - superfície de resposta</b>	<b>37</b>
12.1 Análise de variância e obtenção do modelo empírico . . . . .	37
12.2 Gráfico do modelo final . . . . .	37
<b>13 Análise de experimentos em parcela subdividida</b>	<b>38</b>
13.1 Análise de variância . . . . .	38
13.2 Teste de médias . . . . .	38
<b>14 Experimentos em parcelas subsubdivididas</b>	<b>39</b>
14.1 Análise de variância . . . . .	39
14.2 Testes de médias . . . . .	40
<b>15 Recursos gráficos</b>	<b>42</b>
15.1 Gráficos do pacote <i>graphics</i> . . . . .	42
15.2 Gráficos do pacote <i>lattice</i> . . . . .	44

# 1 Introdução à manipulação de objetos e funções

## 1.1 Instalação do R

---

```
#-----  
# página do R  
browseURL(URLencode("http://www.r-project.org/"))  
#-----  
# página de download  
browseURL(URLencode("http://cran.stat.ucla.edu/bin/windows/base/"))  
#-----  
# documento com instruções de instalação e primeiros passos  
browseURL(URLencode("http://cran.r-project.org/doc/contrib/Itano-installation.pdf"))  
#-----  
# curiosidades  
browseURL(URLencode("http://www.nytimes.com/2009/01/07/technology/business-computing/07program.html"))  
browseURL(URLencode("http://jeromyanglim.blogspot.com/2010/05/abbreviations-of-r-commands-explained.html"))  
#-----  
# quando não souber os links consulte o google  
browseURL(URLencode("http://www.lmgtfy.com/?q=R+download+windows"))  
browseURL(URLencode("http://www.lmgtfy.com/?q=R+reference+card"))  
#-----  
#-----  
.
```

---

## 1.2 Pedindo ajuda

---

```
#-----  
# quando você só sabe algo sobre  
apropos("tukey")  
apropos("help")  
#-----  
# fazendo a busca do termo  
help(TukeyHSD)  
help(TukeyHSD, help_type="html")  
?TukeyHSD  
#-----  
# buscando em pacotes o termo  
help.search("Tukey")  
??Tukey  
#-----  
# fazendo a busca na web  
RSiteSearch("curve fitting")  
#-----  
.
```

---

### 1.3 Criação, atribuição, acesso e modificação de objetos

---

```
#-----  
# vetores, sequências e números aleatórios  
c(2,4,7,3,8,9)  
1:7  
seq(0, 20, by=3.1)  
seq(0, 20, length=4)  
rep(1:3, times=3)  
rep(1:3, each=3)  
rnorm(5, 3, 2)  
rnorm(5, sd=2, mean=3)  
rnorm(5, mean=3, sd=2)  
runif(5)  
#-----  
# matrizes  
matrix(c(1,5,38,400), 2, 2)  
matrix(1:6, 2, 3)  
matrix(rnorm(9), 3, 3)  
matrix(c("a","c","b","j"), 2, 2)  
#-----  
# estrutura de dados (planiilha)  
data.frame(A=1:4, B=runif(4), C=letters[1:4])  
data.frame(trat=c(1:2,1:2), bloc=rep(1:2, e=2))  
expand.grid(cult=c("A","B"), bloc=c("I","II","III"), dose=1:3)  
#-----  
# listas  
list(A=rnorm(4),  
     B=matrix(1:4,2,2),  
     C=data.frame(a=1:4, b=runif(4), c=letters[1:4]),  
     D="O R é livre")  
#-----  
# atribuição, acesso e modificação de vetores  
x <- seq(12, 18, 2); x  
x[1]  
x[2:3]  
x[-4]  
x[3:4] <- c(20,22); x  
#-----  
# atribuição, acesso e modificação de matrizes  
x <- matrix(rnorm(9), 3, 3); x  
x[,]  
x[,1]  
x[2,2]  
x[-3,-3]  
x[3,1] <- 19; x  
x[3,1] <- "19"; x  
#-----  
# atribuição, acesso e modificação de tabelas de dados  
x <- data.frame(A=1:4, B=runif(4), C=letters[1:4]); x  
x[,1]  
x[,"A"]  
x[1,2]  
x[-3,-3]  
x[1,"A"] <- 200  
x  
#-----  
# atribuição, acesso e modificação de "planilhas"
```

```

x <- list(A=rnorm(4),
          B=matrix(1:4,2,2),
          C=data.frame(a=1:4, b=runif(4), c=letters[1:4]))
x
x[[1]]
x[[3]][,1]
x$B
x[["C"]]
x[["C"]][1,1] <- 0
#
#-----#
.

```

---

## 1.4 Informações sobre objetos (atributos)

---

```

.
#
# como obter informações sobre um objeto?
v <- c(a=1, b=2, c=3)
v
length(v)
class(v)
class("R")
names(v)                                #

#
m <- matrix(1:3,2,2)
m
dim(m)
class(m)
colnames(m)
colnames(m) <- c("i","j")
colnames(m)
m                                         #

#
d <- expand.grid(A=1:2, B=c("A", "B"))
dim(d)
nrow(d); ncol(d)
names(d)
names(d) <- c("trat", "bloc")
d                                         #

#
l <- list(A=rnorm(4), B=matrix(1:4,2,2))
dim(l)
class(l)
names(l)
l                                         #

#
# como saber praticamente tudo sobre um objeto?
str(v)
str(m)
str(d)
str(l)
ls()                                     #

#
.
```

---

## 1.5 Operações matemáticas

---

```
#-----#
# as operações fundamentais e mais
1+100
3-5
2*8
3/4
2^3
sqrt(4)
exp(3)
2.71^3
log(10)
log10(1000)
log(30, base=3)                                #

#-----#
# as operações em vetores
x <- 1:3
x-1
x+c(5:7)
x/3
x/c(1:2)
x^2
log(x)                                         #

#-----#
# as operações com matrizes
x <- matrix(1:4, 2, 2)
y <- matrix(4:1, 2, 2)
z <- matrix(1:6, 3, 2)
x*10
x-4
x+y
x*y
x%*%y
x+z
z%*%x
det(x)
diag(x)
solve(x)
t(z)                                              #

#-----#
# operações trigonométricas
x <- seq(0, 2, 0.5)
pi
sin(x*pi)
cos(x*pi)
tan(x*pi)
asin(1)/pi
acos(-1)/pi
atan(1)/pi                                         #

#-----#
.
```

---

## 1.6 Operações estatísticas

---

```
#-----#
```

```

# em vetores
x <- rnorm(1000)
mean(x)
sum(x)
var(x)
sd(x)
median(x)
max(x)
min(x)
range(x)
summary(x)
plot(x)
hist(x)

#-----
x <- matrix(rnorm(20), 4, 5)
colSums(x)
rowMeans(x)
mean(x)
var(x)
cor(x)
sd(x)
apply(x, 1, mean)
apply(x, 1, max)
apply(x, 2, min)

#-----
# operações com data.frames
x <- expand.grid(A=c("H", "M"), B=c("sim", "não"), rep=1:4)
x
x$alt <- rnorm(x$A, 1.7)
x
tapply(x$alt, x$A, mean)
with(x, tapply(alt, A, mean))
with(x, tapply(alt, B, var))
with(x, tapply(alt, list(A, B), sum))
with(x, aggregate(alt, list(A, B), mean))

#-----
.
```

---

## 1.7 Construindo funções

---

```

#-----
# criação e uso de funções
f0 <- function(x, y){
  (x+y)^2
}
class(f0)
args(f0)
f0(3, 2)

#-----
# função para obtenção das raízes de uma função de 2 grau
baskara <- function(a,b,c){
  x1 <- (-b-sqrt(b^2-4*a*c))/(2*a)
  x2 <- (-b+sqrt(b^2-4*a*c))/(2*a)
  c(x1, x2)
}
baskara(-3,2,1)
baskara(3,2,1)
curve(3*x^2+2*x+1, -1, 2)
```

```

curve(-3*x^2+2*x+1, -1, 2)
abline(h=0, v=baskara(-3,2,1), lty=2)
#
#-----#
# função para obtenção da nota necessária para ser aprovado na 3 prova
nota3 <- function(nota1, nota2){
  n3 <- 21-nota1-nota2
  if(n3<=10){
    cat("nota mínima:", n3, "(pode ser aprovado sem exame)")
  } else {
    cat("nota mínima:", n3, "(terá que fazer o exame)")
  }
}
nota3(3,5)
nota3(8,9.5)
#
#-----#
.

```

---

## 2 Importação de dados e análise exploratória

### 2.1 Importando dados

```

.
#-----#
# como importar/ler dados?
apropos("read")
help(read.table)
#
#-----#
# onde os dados devem estar?
getwd()
setwd("/home/walmes/Documentos/Curso R")
apropos("system")
system("ls")
#
#-----#
# importando dados
soja <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/soja.txt", header=TRUE, sep="\t", dec=",")
class(soja)
names(soja)
dim(soja)
str(soja)
head(soja)
soja
#
#-----#
# exploração númerica
with(soja, tapply(rengrao, list(potassio), mean))
with(soja, tapply(rengrao, list(potassio, agua), mean))
#
#-----#
# selecionando subconjuntos dos dados
subset(soja, potassio==0)
subset(soja, bloco=="I")
subset(soja, potassio==0 & bloco=="I")
subset(soja, rengrao<15)
subset(soja, rengrao<15 & pesograo<11)
#
#-----#
# um pouco sobre perguntas lógicas
1==1

```

```

2==1
1!=3
3!=3
1<2
1<2
1<1
1<=1
1<=1 & 2>1
1<=1 & 1>1
1<3 | 2<3
1<3 | 4<3
5<3 | 4<3
"joão"=="João"
"joão"=="joao"
#
# -----
.

```

---

## 2.2 Explorações gráficas (1)

```

# -----
# matriz de diagramas de dispersão
pairs(soja) #
# -----
# gráficos simples de dispersão
plot(rengrao~potassio, data=subset(soja, agua==50))
plot(rengrao~potassio, data=subset(soja, agua==50),
     xlab="Dose de potássio", ylab="Rendimento de grãos",
     col=2, pch=19, cex=1.2) #
# -----
# boxplot
boxplot(rengrao~potassio, data=subset(soja, agua==50))
boxplot(rengrao~potassio, data=soja, col="yellow") #
# -----
# todos níveis de água ao mesmo tempo
par(mfrow=c(1,3))
plot(rengrao~potassio, data=subset(soja, agua==37.5), main="37.5% de água")
plot(rengrao~potassio, data=subset(soja, agua==50), main="50.0% de água")
plot(rengrao~potassio, data=subset(soja, agua==62.5), main="62.5% de água") #
# -----
# gráficos de barras
par(mfrow=c(1,1))
pot.m <- with(soja, tapply(rengrao, potassio, mean))
pot.m
bp <- barplot(pot.m) # ylim=c(0,32)
text(bp, pot.m, label=round(pot.m, 3)) # pos=3
title("Médias dos tratamentos")
box() #
# -----
.
```

---

## 2.3 Explorações gráficas (2)

```

# -----
.
```

```

# lendo novos dados
agr <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/agreg.txt", header=TRUE, sep="\t")
names(agr)
str(agr)
#
#-----#
# como os dados se distribuem (marginal)?
pairs(agr)
hist(agr$roundness)
plot(agr$roundness, col=agr$prof)
plot(density(agr$roundness))
#
#-----#
# mas as médias não mudam com a profundidade?
with(agr, tapply(roundness, profundidade, mean))
with(agr, tapply(aspecto, profundidade, mean))
#
#-----#
# os dados têm distribuição normal? como checar?
par(mfrow=c(1,2))
qqnorm(agr$roundness); qqline(agr$roundness)
qqnorm(agr$aspecto); qqline(agr$roundness)
with(subset(agr, profundidade==5), { qqnorm(roundness); qqline(roundness) })
with(subset(agr, profundidade==20), { qqnorm(roundness); qqline(roundness) })
qqnorm(scale(agr$roundness), asp=1); qqline(scale(agr$roundness))
hist(scale(agr$roundness), freq=FALSE)
curve(dnorm(x), add=TRUE, col=2); lines(density(scale(agr$roundness)), col=3)
#
#-----#
# o que fazer? transformar? qual transformação?
require(MASS)
agr5 <- subset(agr, profundidade==5)
boxcox(agr5$roundness~1, lambda=seq(-1,6,l=100))
qqnorm(agr5$roundness^4); qqline(agr5$roundness^4)
shapiro.test(agr5$roundness)
shapiro.test(agr5$roundness^4)
#
#-----#
# o que fazer em casos como esse?
boxcox(agr5$aspecto~1, lambda=seq(-1,6,l=100))
qqnorm(agr5$aspecto^3); qqline(agr5$aspecto^3)
#
#-----#
.

```

---

## 2.4 Recursos gráficos avançados

```

.
#-----#
# biblioteca para gráficos
require(lattice)
#
#-----#
# de volta aos dados de soja
xyplot(rengrao-potassio, groups=agua, data=soja)
xyplot(rengrao-potassio, groups=agua, data=soja, type=c("p", "a"))
xyplot(rengrao-potassio|agua, data=soja, type=c("p", "a"))
xyplot(rengrao-potassio|agua, data=soja, type=c("p", "smooth"))
#
#-----#
# de volta aos dados de agragados
qqmath(~roundness, groups=profundidade, data=agr)
qqmath(~roundness|profundidade, data=agr)
```

```

qqmath(~roundness+aspecto|profundidade, data=agr)
#
#-----
histogram(~roundness|profundidade, data=agr)
densityplot(~roundness+aspecto|profundidade, data=agr)
#
#-----
# matriz de dispersão
str(agr)
splom(agr[,-1], group=agr$profundidade)
#
#-----
# os dados abaixo têm distribuição normal?
m <- gl(15,8)
x <- rnorm(m, as.numeric(m), 0.1)
xp <- qnorm(x); qqline(x)
rug(xp$x)
rug(xp$y, side=2)
m0 <- lm(x~m)
xp <- qnorm(residuals(m0)); qqline(residuals(m0))
rug(xp$x)
rug(xp$y, side=2)
#
#-----
# uma mistura de distribuições
par(mfrow=c(1,1))
curve(dnorm(x,0,1), 0, 20)
for(i in seq(0,20,l=7)) { curve(dnorm(x,i,1), add=TRUE, col=i); abline(v=i, col=i, lty=3) }
#
#-----
.

```

---

### 3 Regressão linear

#### 3.1 Importando e manipulando dados

```

#
# -----
# importando dados
dap <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/dap.txt", header=TRUE, sep="\t")
str(dap)
names(dap) <- c("d", "h")
#
# -----
# criando novas variáveis regressoras
dap$d2 <- dap$d^2
dap <- transform(dap, d2=d^2, d3=d^3, dr=sqrt(d), dl=log(d), di=1/d, di2=1/d^2)
str(dap)
pairs(dap)
dap <- dap[order(dap$d),]
dapcc <- dap[complete.cases(dap),]
rownames(dapcc) <- NULL
head(dapcc)
str(dapcc)
#
# -----
.
```

---

## 3.2 Regressão linear simples

---

```
#-----  
# ajustando a equação da reta (regressão linear simples)  
m0 <- lm(h~d, data=dapcc)  
summary(m0)  
str(m0) #  
#-----  
# verificando o ajuste  
plot(h~d, dapcc) # xlab=, ylab=  
lines(fitted(m0)~d, dapcc, col="red")  
abline(m0, col=3, lty=2) #  
#-----  
# análise de resíduos  
par(mfrow=c(2,2))  
plot(m0) #  
#-----  
.
```

---

## 3.3 Regressão linear múltipla

---

```
#-----  
# ajuste do modelo quadrático  
m1 <- lm(h~d+d2, data=dapcc) # ou lm(h~d+I(d^2), data=dapcc)  
summary(m1)  
layout(matrix(c(1,1,2,3,4,5),2,3))  
plot(h~d, dapcc)  
lines(fitted(m1)~d, dapcc)  
plot(m1) #  
#-----  
# modelo cúbico  
m2 <- lm(h~d+d2+d3, data=dapcc) # ou lm(h~d+I(d^2)+I(d^3), data=dapcc)  
summary(m2)  
plot(h~d, dapcc)  
lines(fitted(m2)~d, dapcc)  
plot(m2) #  
#-----  
# modelo recíproco  
m3 <- lm(h~d+di, data=dapcc)  
summary(m3)  
plot(h~d, dapcc); lines(fitted(m3)~d, dapcc); plot(m3) #  
#-----  
# modelo quadrado do recíproco  
m4 <- lm(h~d+di2, data=dapcc)  
summary(m4)  
plot(h~d, dapcc); lines(fitted(m4)~d, dapcc); plot(m4) #  
#-----  
# modelo raíz quadrada  
m5 <- lm(h~d+dr, data=dapcc)  
summary(m5)  
plot(h~d, dapcc); lines(fitted(m5)~d, dapcc); plot(m5) #  
#-----
```

```

# modelo logarítmo
m6 <- lm(h~d+dl, data=dapcc)
summary(m6)
plot(h~d, dapcc); lines(fitted(m6)~d, dapcc); plot(m6)
#
#-----#

```

---

### 3.4 Seleção de modelos/variáveis

```

#-----#
# modelo com todas as variáveis
m7 <- lm(h~, data=dapcc)
summary(m7)
plot(h~d, dapcc); lines(fitted(m7)~d, dapcc); plot(m7)
#
#-----#
# seleção de modelos/variáveis
step(m7, direction="both")
step(m7, direction="both", k=log(nrow(dapcc)))
#
#-----#
# modelo m5 foi escolhido pelo critério BIC
summary(m5)
anova(m5)
plot(h~d, dapcc); lines(fitted(m5)~d, dapcc); plot(m5)
#
#-----#

```

---

### 3.5 Remoção de pontos discrepantes

```

#-----#
# identificar/remover os pontos discrepantes/influentes
layout(1)
plot(residuals(m5)~d, dapcc)
id <- identify(dapcc$d, residuals(m5))
id
#
#-----#
# análise com os pontos removidos
dapcc2 <- dapcc[-c(15,41,209),]
str(dapcc2)
dapcc2 <- dapcc[-id,]
m5b <- lm(h~d+dr, data=dapcc2)
summary(m5b)
layout(matrix(c(1,1,2,3,4,5),2,3))
plot(h~d, dapcc2); lines(fitted(m5b)~d, dapcc2); plot(m5b)
#
#-----#
# e se tentarmos transformar?
require(MASS)
layout(1)
bc <- boxcox(m5b, lambda=seq(0.5,2,l=100))
bc
str(bc)
bc$x[which.max(bc$y)]

```

```

#-----#
# usando a resposta transformada
m5c <- lm(h^(1.2)~d+dr, data=dapcc2)
summary(m5c)
layout(matrix(c(1,1,2,3,4,5),2,3))
plot(h~d, dapcc2); lines(fitted(m5c)^(1/1.2)~d, dapcc2); plot(m5c)
shapiro.test(rstudent(m5c))
ks.test(rstudent(m5c), "pnorm")
shapiro.test(rstudent(m5))
ks.test(rstudent(m5), "pnorm")
#
#-----#
.
```

---

### 3.6 Predição de valores a partir do modelo escolhido

```

#-----#
# tudo para encontrar o modelo, vamos predizer a altura das árvores e salvar num arquivo
hpred <- predict(m5, newdata=dap)
str(hpred)
dap$hpred <- hpred
str(dap)
write.table(dap, "dap.xls", sep="\t", quote=FALSE, row.names=FALSE, dec=",")
#
#-----#
.
```

---

### 3.7 Representação gráfica do ajuste

```

#-----#
# escolhendo o intervalo de predição
range(dapcc2$d)
d.new <- seq(4, 30, length=100)
d.new
#
#-----#
# fazendo predição com intervalo de confiança e predição futura
Yp <- predict(m5b, newdata=data.frame(d=d.new, dr=sqrt(d.new)), interval="confidence")
Yf <- predict(m5b, newdata=data.frame(d=d.new, dr=sqrt(d.new)), interval="prediction")
head(Yp)
#
#-----#
# plotando
layout(1)
plot(h~d, dapcc2, xlab="DAP (cm)", ylab="Altura (m)")
matlines(d.new, Yp, col=c(1,2,2), lty=c(1,2,2))
matlines(d.new, Yf, col=c(1,3,3), lty=c(1,3,3))
#
#-----#
# fazendo anotações dentro do gráfico
legend("topleft", c("Predito", "ICpredito", "ICobsfutura"),
      lty=c(1,2,3), col=c(1,2,3), bty="n")
summary(m5b)
text(20, 15, expression(hat(h)==-16.8-1.12*d+14.8*sqrt(d)~~~(R^2==84.6)), bty="n")
#
#-----#
.
```

---

```

# mais sobre gráficos no R
demo(plotmath)
demo(graphics)
#
#-----#
.
```

---

### 3.8 Mais sobre análise de resíduos e $R^2$ (quarteto de Anscombe)

```

.
#-----#
# mais sobre resíduos e R2
data(anscombe)
ans1 <- lm(y1~x1, anscombe)
ans2 <- lm(y2~x2, anscombe)
ans3 <- lm(y3~x3, anscombe)
ans4 <- lm(y4~x4, anscombe)
summary(ans1)
summary(ans2)
summary(ans3)
summary(ans4)
#
#-----#
# gráficos
par(mfrow=c(4,5), oma=c(0,0,0,0), mar=c(2,2,2,2))
plot(y1~x1, anscombe); abline(ans1, col=2); plot(ans1)
plot(y2~x2, anscombe); abline(ans2, col=2); plot(ans2)
plot(y3~x3, anscombe); abline(ans3, col=2); plot(ans3)
plot(y4~x4, anscombe); abline(ans4, col=2); plot(ans4)
#
#-----#
# o significado dos leverages
hatvalues(ans1)
sapply(list(ans1, ans2, ans3, ans4), hatvalues)
#
#-----#
browseURL(URLencode("http://animation.yihui.name/lm:least_squares"))
#
#-----#
.
```

---

## 4 Regressão não linear

### 4.1 Motivação

```

#-----#
# dados de motivação
lines <- "
dia eclog
2 13.00
4 56.50
6 97.50
8 168.00
10 246.50
12 323.00
14 374.00
16 389.00
"
```

---

```

"
da <- read.table(textConnection(lines), header=TRUE); closeAllConnections()
str(da)
plot(eclod~dia, da) #  

#-----  

# ajuste de modelos lineares e não lineares  

new <- data.frame(dia=seq(0,30,l=100))
plot(eclod~dia, da, xlim=c(0,30), ylim=c(0,600)) #  

#-----  

# modelo linear da reta  

m0 <- lm(eclod~dia, da)
lines(predict(m0, newdata=new)~new$dia, col=1) #  

#-----  

# modelo polinômio cúbico  

m1 <- lm(eclod~poly(dia, 3), da)
lines(predict(m1, newdata=new)~new$dia, col=2) #  

#-----  

# modelo não linear (logístico)  

m2 <- nls(eclod~SSlogis(dia, Asym, xmid, scal), data=da)
lines(predict(m2, newdata=new)~new$dia, col=3) #  

#-----  

#
.
```

---

## 4.2 Definição

---

```

#
#-----  

# as derivadas de y em relação a theta não são livres de theta  

# y = A*x/(B+x) : modelo michaelis mentem  

D(expression(A*x/(B+x)), "A")
D(expression(A*x/(B+x)), "B") #  

#-----  

# y = A/(1+exp(B+C*x)) : modelo logístico simples  

D(expression(A/(1+exp(B+C*x))), "A")
D(expression(A/(1+exp(B+C*x))), "B")
D(expression(A/(1+exp(B+C*x))), "C") #  

#-----  

.
```

---

## 4.3 Exemplo de modelos não lineares

---

```

#
#-----  

# modelo michaelis mentem
layout(1)
A <- 10; B <- 3
curve(A*x/(B+x), 0, 50, ylim=c(0,10), col=2, lwd=3)
abline(h=c(A, A/2), v=B, lty=3) #  

#-----  

# modelo logístico
A <- 10; B <- 25; C <- 3
```

```

curve(A/(1+exp((B-x)/C)), 0, 50, col=2, lwd=3)
abline(h=c(A, A/2), v=B, lty=3)                                            #
#-----#
# modelo resposta platô
A <- 1; B <- 0.5; x0 <- 5
curve(A+B*x*(x<x0)+B*x0*(x>=x0), 0, 20, col=2, lwd=3)
abline(h=c(A, A+B*x0), v=x0, lty=3)                                            #
#-----#
# modelo de produção-competição (Bleasdale & Nelder, 1960)
A <- 10; B <- 2; C <- 0.5
curve(x*(A+B*x)^(-1/C), 0, 50, col=2, lwd=3)
C <- 1
curve(x*(A+B*x)^(-1/C), 0, 50, col=2, lwd=3)
C <- 2
curve(x*(A+B*x)^(-1/C), 0, 50, col=2, lwd=3)                                            #
#-----#
# modelo de curva de água no solo (van Genuchten, 1980)
A <- 0.7; B <- 0.3; C <- 1.3; D <- 1.6
curve(B+(A-B)/(1+(C*10^x)^D)^(1-1/D), -3, 4, col=2, lwd=3)
abline(h=c(A,B), lty=3)
curve(eval(D(expression(B+(A-B)/(1+(C*10^x)^D)^(1-1/D))), "x")), -3, 3)          #
#-----#
#
.

```

---

#### 4.4 Uso de recursos gráficos para entender o significado dos parâmetros

```

#-----#
# pacote que permite a construção de interfaces gráficas
library(gWidgetsRGtk2)                                                       #
#-----#
# modelo michaelis mentem (reações químicas, liberação de nutrientes no solo)
limits <- list(A=c(0,20), B=c(0,6))
plottest <- function(...){ curve(svalue(A)*x/(svalue(B)+x), 0, 15) }           #
#-----#
# função que contrói a janela gráfica com deslizadores
#func <-
w <- gwindow("Slider and spinbox example")
tbl <- glayout(cont=w)
for(i in 1:length(limits)){
  tbl[i,1] <- paste("Slide to ajuste parameter", names(limits)[i])
  tbl[i,2, expand=TRUE] <- (assign(names(limits)[i],
    gslider(from=limits[[i]][1], to=limits[[i]][2],
    by=diff(limits[[i]])/20, value=mean(limits[[i]]),
    container=tbl, handler=plottest)))
}
plottest()
#' ; writeLines(func, "func.R")                                              #
#-----#
# modelo logístico (curva de crescimento)
limits <- list(A=c(0,20), B=c(10,60), C=c(1,7))
plottest <- function(...){ curve(svalue(A)/(1+exp((svalue(B)-x)/svalue(C))), 0, 50) }
source("func.R")                                                               #
#-----#
# modelo resposta platô (ensaios com fertilizante)
```

```

limits <- list(A=c(0,2), B=c(0,2), x0=c(2,7))
plottest <- function(...){
  curve(svalue(A)+svalue(B)*x*(x<svalue(x0))+svalue(B)*svalue(x0)*(x>=svalue(x0)), 0, 20)
}
source("func.R")
#
#-----
# modelo de produção-competição (Bleasdale & Nelder, 1960)
limits <- list(A=c(0,20), B=c(0,2), C=c(0,2))
plottest <- function(...){ curve(x*(svalue(A)+svalue(B)*x)^(-1/svalue(C)), 0, 50) }
source("func.R")
#
#-----
# modelo de curva de água no solo (van Genuchten, 1980)
limits <- list(A=c(0.5,0.8), B=c(0.1,0.3), C=c(0.5,1.5), D=c(1,2))
plottest <- function(...){
  curve(svalue(B)+(svalue(A)-svalue(B))/(1+(svalue(C)*10^x)^svalue(D))^(1-1/svalue(D)),
        -3, 4)
}
source("func.R")
#
#-----
.

```

---

## 4.5 Estimação de parâmetros em modelos não lineares

```

#-----
# como funciona o procedimento iterativo para estimar parâmetros?
# exemplo com o modelo michaelis mentem e dados de mentirinha
theta <- c(A=10, B=3)
da <- data.frame(x=seq(1,20,2))
da$y <- theta["A"]*da$x/(theta["B"]+da$x)+rnorm(da$x, 0, 0.2)
plot(y~x, da)
#
# sequência de estimativas até a convergência do procedimento de estimação
# caminho pela superfície de mínimos quadrados
sqe <- function(A, B, y, x){ hy <- (A*x)/(B+x); sum((y-hy)^2) }
SQE <- Vectorize(sqe, c("A", "B"))
A.grid <- seq(0,40,l=100)
B.grid <- seq(0,20,l=100)
sqa.surf <- outer(A.grid, B.grid, SQE, da$y, da$x)
contour(A.grid, B.grid, sqa.surf, levels=(1:35)^2,
         xlab="A", ylab="B", col="gray70")
start.list <- list(s1=c(A=0.1,B=0.1), s2=c(A=40,B=20),
                     s3=c(A=35,B=2.5), s4=c(A=18,B=18))
par(mfrow=c(2,2))
for(lis in 1:4{
  contour(A.grid, B.grid, sqa.surf, levels=(seq(1,35,2))^2,
          xlab="A", ylab="B", col="gray70")
  sink("trace.txt")
  n0 <- nls(y~A*x/(B+x), data=da, start=start.list[[lis]], trace=TRUE)
  sink()
  trace <- read.table("trace.txt")
  for(i in seq(nrow(trace)-1)){
    arrows(trace[i,"V3"], trace[i,"V4"],
           trace[i+1,"V3"], trace[i+1,"V4"],
           col=2, length=0.1)
    abline(v=trace[i+1,"V3"], h=trace[i+1,"V4"], col="orange", lty=3)
    Sys.sleep(1)
    print(c(i, trace[i+1,"V3"], trace[i+1,"V4"]))
  }
}
```

```

}

#-----#
# olhando a convergência pelo gráficos dos observados vs preditos
for(lis in 1:4){
  sink("trace.txt")
  n0 <- nls(y~A*x/(B+x), data=da, start=start.list[[lis]], trace=TRUE)
  sink()
  plot(y~x, da)
  trace <- read.table("trace.txt")
  for(i in seq(nrow(trace))){
    curve(trace[i,"V3"]*x/(trace[i,"V4"]+x), add=TRUE, col=2)
    Sys.sleep(1)
  }
}
#-----#
# curva ajustada
plot(y~x, da)
curve(coef(n0)[ "A"]*x/(coef(n0)[ "B"]+x), add=TRUE, col=2)
#
#-----#
# estimativas dos parâmetros
summary(n0)
#
#-----#
.

```

---

## 4.6 Ajuste de modelo não linear aos dados de DAP

---

```

#
#-----#
# importando dados
dap <- read.table(file.choose(), header=TRUE)
dap <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/dap.txt", header=TRUE)
names(dap) <- c("d", "h")
#
#-----#
# ordenando e tomando só os casos completos
dap <- dap[order(dap$d),]
dapcc <- dap[complete.cases(dap),]
str(dapcc)
#
#-----#
# análise gráfica exploratória dos dados
plot(h~d, dapcc)
#
#-----#
# análise gráfica do modelo candidato  $h = b_0 * (1 - \exp(-b_1 * d))^{b_2}$ 
limits <- list(b0=c(25,35), b1=c(0,0.5), b2=c(0.7, 1.3))
plottest <- function(...){
  plot(h~d, dapcc)
  curve(svalue(b0)*(1-exp(-svalue(b1)*x))^(svalue(b2)), add=TRUE, col=2)
}
source("func.R")
#
#-----#
# ajustar o modelo não linear (com bons chutes)
n0 <- nls(h~b0*(1-exp(-b1*d))^b2, data=dapcc,
           start=list(b0=35, b1=0.1, b2=1.3), trace=TRUE)
summary(n0)
#
#-----#

```

```

# ajustar o modelo não linear (com chutes sem noção)
n0 <- nls(h~b0*(1-exp(-b1*d))^b2, data=dapcc,
           start=list(b0=35, b1=0, b2=1.3), trace=TRUE)
n0 <- nls(h~b0*(1-exp(-b1*d))^b2, data=dapcc,
           start=list(b0=35, b1=-1, b2=1.3), trace=TRUE)
n0 <- nls(h~b0*(1-exp(-b1*d))^b2, data=dapcc,
           start=list(b0=35, b1=0.1, b2=-1), trace=TRUE)
#-----#
# verificação do ajuste
plot(h~d, dapcc)
lines(fitted(n0)~d, dapcc, col=2)
#-----#
# não temos os gráficos de resíduos prontos para modelos não lineares, vamos construí-los
# extraíndo valores
r.cru <- residuals(n0)
var(r.cru)
r.pad <- residuals(n0, type="pearson")
var(r.pad)
fitd <- fitted(n0)
#-----#
# fazendo os gráficos
par(mfrow=c(1,3))
plot(r.cru~fitd)
abline(h=0, lty=3)
scatter.smooth(sqrt(abs(r.pad))-fitd)
qqnorm(r.pad); qqline(r.pad, lty=2)
#-----#
# intervalo de confiança para as estimativas
confint.default(n0)
confint(n0)
#-----#
# o intervalo de confiança de b2 contém o 1, será que preciso de b2?
n1 <- nls(h~b0*(1-exp(-b1*d)), data=dapcc,
           start=list(b0=30, b1=0.1))
summary(n1)
#-----#
# como ficou?
layout(1)
plot(h~d, dapcc)
lines(fitted(n0)~d, dapcc, col=2)
lines(fitted(n1)~d, dapcc, col=3)
#-----#
# teste da razão de verossimilhança para exclusão de b2
anova(n1, n0)
#-----#
# comparar o ajuste do modelo não linear com o linear escolhido na aula passada
-2*c(logLik(n1))+2*2
# AIC (k=2 parâmetros)
# -2*c(logLik(m5))+3*2
# 966.5362 (k=3 parâmetros)
-2*c(logLik(n1))+2*log(221)
# BIC (k=2 parâmetros)
-2*c(logLik(m5))+3*log(221)
#-----#
# R2 em modelos não lineares (danger!)
R2 <- function(nls.obj){
  da <- eval(nls.obj$data)
  resp.name <- all.vars(summary(nls.obj)$formula)[1]

```

```

names(da)[which(names(da)==resp.name)] <- "y"
sqn <- deviance(nls.obj)
sqa <- deviance(lm(y~1, da))
1-(sqn/sqa)
}
R2(n0)
R2(n1)
#
#-----#

```

---

## 4.7 Comparação de curvas ajustadas

---

```

#
#-----#
# dados
frango <- expand.grid(dia=2:42, sistema=factor(c("A", "B")))
frango$peso <- c( 80.18145, 89.98167, 132.14629, 192.04534, 167.68245, 191.45191,
220.74227, 212.98519, 230.82651, 346.32728, 391.14474, 407.79706,
441.54167, 499.63470, 575.36996, 603.35279, 678.09090, 763.96071,
787.66652, 921.68731, 959.13005, 1069.59008, 1150.70054, 1269.26359,
1313.35194, 1419.24574, 1532.63279, 1647.94630, 1722.91144, 1832.84384,
1921.09935, 1960.50372, 2062.17519, 2204.45014, 2258.73203, 2311.79432,
2466.26338, 2505.48039, 2521.81638, 2625.00725, 2728.60234, 201.41506,
240.71230, 289.29251, 215.56332, 294.79948, 297.17629, 346.07243,
358.03428, 393.36050, 388.47739, 477.51108, 420.89742, 490.44854,
605.53948, 629.18954, 659.28526, 713.87248, 773.69469, 887.45404,
943.04904, 970.29292, 980.20056, 1142.43274, 1197.28398, 1187.79456,
1243.54212, 1340.48431, 1453.78205, 1542.45519, 1596.08595, 1702.33500,
1801.46693, 1847.62131, 1860.69871, 2018.38835, 2046.97753, 2077.06034,
2236.60287, 2238.75234, 2302.30264, 2354.35641)
#
#-----#
# análise gráfica exploratória
require(lattice)
xyplot(peso~dia, groups=sistema, data=frango, type=c("p", "smooth"))
xyplot(peso~dia|sistema, data=frango, type=c("p", "smooth"))
#
#-----#
# ajuste de curvas individuais com modelo logístico
nA <- nls(peso~A/(1+exp(-(dia-d50)/S)),
           data=subset(frango, sistema=="A"),
           start=list(A=3000, d50=25, S=10))
summary(nA)
#
nB <- nls(peso~A/(1+exp(-(dia-d50)/S)),
           data=subset(frango, sistema=="B"),
           start=list(A=3000, d50=25, S=10))
summary(nB)
#
#-----#
# fazer o ajuste das duas curvas num único nls(), estimativa do QMR é mais consistente
nAB <- nls(peso~A[sistema]/(1+exp(-(dia-d50[sistema])/S[sistema])),
           data=frango,
           start=list(
             A=c(3200,3200),
             d50=c(28,30),
             S=c(8,10)))
summary(nAB)
#
#-----#
# as estimativas de A são tão próximas, será que direrem?

```

```

confint.default(nAB) # baseado em normalidade assintótica
confint(nAB)          # baseado em perfil de verossimilhança
#-----#
# ajustar um modelo em que A seja comum aos dois sistemas
nAB2 <- nls(peso~A/(1+exp(-(dia-d50[sistema])/S[sistema])),
            data=frango,
            start=list(
              A=c(3200),
              d50=c(28,30),
              S=c(8,10)))
summary(nAB2)
#-----#
# empregar o teste da razão de verossimilhança para testar a restrição em A
anova(nAB2, nAB)
#-----#
# fazer o gráfico dos valores ajustados/preditos
new <- expand.grid(dia=0:70, sistema=factor(c("A", "B")))
new$fit <- predict(nAB2, newdata=new)
#-----#
# gráfico
with(frango, plot(peso~dia, col=sistema, xlim=c(0,70), ylim=c(0,3200)))
with(subset(new, sistema=="A"), lines(dia, fit))
with(subset(new, sistema=="B"), lines(dia, fit, col=2))
#-----#
#
.

```

---

## 4.8 Ajuste de modelos não lineares com a library{nlme}

```

#-----#
# dados de número de nematóides ecloditos em função dos dias e dose de nematicida
nema <- expand.grid(dia=seq(2,16,2), dose=c(0,1,5,10))
nema$eclod <- c(13, 56.5, 97.5, 168, 246.5, 323, 374, 389, 7, 26, 64.5, 126, 207.5,
                282, 334, 343, 5, 21.5, 45.5, 79, 118.5, 146, 167.5, 174.5, 3.25,
                9.25, 12.5, 20.5, 32.25, 39.25, 40.25, 42.25)
xyplot(eclod~dia, groups=dose, data=nema, type="b", auto.key=TRUE)
#-----#
# carrega o pacote nlme (do grupo dos recomendados)
require(nlme)
#-----#
# ajuste das curvas em uma única função (usando função selfstart)
gn0 <- gnls(eclod~SSlogis(dia, Asym, xmid, scal),
             data=nema,
             params=Asym+xmid+scal~factor(dose),
             start=c(500,-100,-200,-400, 4.4,0,0,0, 1.13,0,0,0))
summary(gn0)
anova(gn0, type="marginal")
#-----#
# novos valores de dia para a predição de ecloid
new <- expand.grid(dia=seq(0,20,0.2), dose=c(0,1,5,10))
new$eclod <- predict(gn0, newdata=new)
xyplot(eclod~dia, groups=dose, data=new)
#-----#
# incluir todos os resultados em um único gráfico

```

```

tudo <- rbind(nema, new)
tudo$tipo <- rep(c("obs", "fit"), c(nrow(nema), nrow(new)))
xyplot(eclod-dia|factor(dose), groups=tipo, data=tudo,
       distribute.type=TRUE, type=c("l", "p", "g"),
       main="O revisor que pede gráficos no Excel deve que ir preso!",
       sub="Os gráficos do R são infinitamente melhores!",
       xlab="Período após a aplicação dos nematicídias (dias)",
       ylab="Nematóides eclodidos",
       key=list(x=0.8, y=0.9,
                lines=list(lty=c(NULL,1), col=c("#0080ff", "#ff00ff")),
                text=list(c("ajustado", "observado"))),
       layout=c(4,1)##, scales=list(y="free")
)
#
#-----#

```

---

## 5 Análise de experimento com um fator em DIC

### 5.1 Importando dados

```

.
#
Lines <-
  "gen  diam
ATF06B 0.713
ATF06B 0.635
ATF06B 0.757
ATF40B 0.621
ATF40B 0.527
ATF40B 0.640
ATF54B 0.559
ATF54B 0.446
ATF54B 0.616
BR001B 0.734
BR001B 0.635
BR001B 0.763
BR005B 0.597
BR005B 0.415
BR005B 0.460
BR007B 0.601
BR007B 0.506
BR007B 0.623
BR008B 0.724
BR008B 0.574
BR008B 0.663
P9401 0.686
P9401 0.440
P9401 0.588
SC283 0.632
SC283 0.610
SC283 0.650"
diam <- read.table(textConnection(Lines), header=TRUE); closeAllConnections()
str(diam)
#
#-----#
# instalação de pacotes para o teste de Tukey e Scott-Knott
# install.packages("agricolae", dep=TRUE)
# install.packages("ScottKnott", dep=TRUE)
# install.packages("contrast", dep=TRUE)
# install.packages("multcomp", dep=TRUE)
# http://cran.r-project.org/

```

```

#-----#
# conferir se temos fatores para fazer a análise de variância
is.factor(diam$gen)
is.numeric(diam$gen)
is.character(diam$gen)
class(diam$gen)                                #
#-----#
.
```

---

## 5.2 Análise de variância

---

```

.                                           #
#-----#
# fazendo a análise de variância
a0 <- aov(diam~gen, data=diam)
anova(a0)                                     #

#-----#
# análise gráfica dos resíduos
par(mfrow=c(2,2))
plot(a0)
layout(1)                                     #

#-----#
# teste das pressuposições da análise de variância
shapiro.test(residuals(a0))
bartlett.test(residuals(a0)~diam$gen)        #
#-----#
.
```

---

## 5.3 Aplicando teste de Tukey para comparar médias

---

```

.                                           #
#-----#
# teste de médias (Tukey), ingredientes: QMR e GLR
df.residual(a0)
# grau de liberdade residual (GLR)
deviance(a0)
# soma de quadrado dos resíduos
deviance(a0)/df.residual(a0) # quadrado médio do resíduo (QMR)
#-----#
# carregando a biblioteca necessária
require(agricolae)                           #

#-----#
# aplicando o teste de Tukey
with(diam,
      HSD.test(diam, gen,
                DFerror=df.residual(a0),
                MSerror=deviance(a0)/df.residual(a0), alpha=0.05)
    )                                         #
#-----#
.
```

---

## 5.4 Aplicando teste de Scott-Knott para agrupar médias

---

```
.  
#-----  
# ScottKnott  
require(ScottKnott) #  
#-----  
# aplicando o teste de ScottKnott  
sk <- SK(x=diam, y=diam$diam, model="y~gen", which="gen", sig.level=0.05)  
summary(sk) #  
#-----  
.

---


```

## 5.5 Aplicando contrastes

---

```
.  
#-----  
# biblioteca para fazer contrastes; o modelo precisa ser classe "lm" e não "aov"  
require(contrast)  
a0 <- lm(diam~gen, data=diam)  
class(a0) #  
#-----  
# um nível contra o outro  
c0 <- contrast(a0, list(gen="ATF06B"), list(gen="ATF40B"))  
c0  
levels(diam$gen)  
coef(a0)  
c0$X  
summary(a0) #  
#-----  
# um grupo de níveis contra outro  
c1 <- contrast(a0, type="average", list(gen=c("BR001B", "ATF06B", "BR008B", "SC283")))  
c2 <- contrast(a0, type="average", list(gen=c("ATF40B", "BR007B", "P9401", "ATF54B", "BR005B")))  
c1  
c2  
c1$X-c2$X  
(c1$X-c2$X)%*%coef(a0) #  
#-----  
# biblioteca para coduzir comparações multiplas de hipóteses  
require(multcomp)  
summary(glht(a0, linfct=(c1$X-c2$X))) #  
#-----  
.

---


```

## 5.6 Estudo das taxas de erro tipo I dos testes

---

```
.  
#-----  
# função que gera experimentos em DIC sob H0  
trat <- gl(6,4)  
geraov <- function(...){  
  y <- rnorm(length(trat))
```

```

m0 <- lm(y~trat)
s0 <- summary(m0)
t1 <- abs(coef(m0)[2]*sqrt(2))/s0$sigma
t2 <- diff(range(0, coef(m0)[-1]))*sqrt(2)/s0$sigma
return(c(t1,t2))
}
gerao()
#
#-----#
# gerando 1000 experimentos aleatórios
exper <- abs(replicate(2000, geraov()))
#
#-----#
# quantil da distribuição t para 95% de área com df graus de liberdade no resíduo
qt(0.975, df=length(trat)-length(levels(trat)))
#
#-----#
# número de experimentos sob  $H_0$  que rejeitaram  $H_0$ , ocorrência do erro tipo I
apply(exper, 1, function(x) sum(x>2.01))/2000
apply(exper, 1, function(x) sum(x>3.17))/2000
#
#-----#
# qual deveria ser a dms para assegurar o nível nominal de significância?
quantile(exper[2,], prob=0.95)
qtukey(0.95, length(levels(trat)), length(trat)-length(levels(trat)))/sqrt(2)
#
#-----#
# gráfico
layout(1)
plot(density(exper[1,]), lty=1)
lines(density(exper[2,]), lty=2)
abline(v=c(2.1,3.17), lty=1:2)
#
#-----#
.

```

---

## 6 Análise de experimentos de um fator em DBC

### 6.1 Entrada de dados

```

#-----#
# produção de madeira (m3/ha) em função de procedência de E. grandis e blocos
dbc <- expand.grid(proced=c("P1","P2","P3","P4","P5","P6","P7"),
                    bloco=c("I","II","III","IV"))
dbc
dbc$prod <- c(358,284,273,284,258,249,318,
              380,249,222,242,263,217,312,
              353,259,236,266,242,267,327,
              360,242,226,252,231,220,319)
str(dbc)
#
#-----#
# gráficos
require(lattice)
xyplot(prod~proced, groups=bloco, data=dbc, type="b")
#
#-----#
.
```

---

## 6.2 Análise de variância

---

```
#-----  
m0 <- aov(prod~bloco+proced, data=dbc)  
class(m0)  
anova(m0)  
summary(m0)  
summary.lm(m0) #  
#-----  
# checagem gráfica  
par(mfrow=c(2,2))  
plot(m0)  
layout(1) #  
#-----  
# teste das pressuposições de normalidade de homocedasticidade  
shapiro.test(residuals(m0))  
bartlett.test(residuals(m0)~dbc$proced)  
bartlett.test(residuals(m0)~dbc$bloco) #  
#-----  
#-----  
.
```

---

## 6.3 Teste de médias

---

```
#-----  
# teste de Tukey  
with(dbc, HSD.test(prod, proced,  
                    DFerror=df.residual(m0),  
                    MSerror=deviance(m0)/df.residual(m0))) #  
#-----  
# teste de Scott-Knott  
sk <- SK(x=dbc, y=dbc$prod, model="prod~bloco+proced", which="proced")  
summary(sk) #  
#-----  
.
```

---

## 6.4 Observações perdidas

---

```
#-----  
# simulando observações perdidas aleatoriamente no conjunto dados  
id <- sample(1:nrow(dbc), 3)  
id  
dbc$prod[id] <- NA  
dbc #  
#-----  
m1 <- aov(prod~bloco+proced, data=dbc)  
summary(m1) #  
#-----  
# o que acontece com os estimadores amostrais das médias?  
dbc$ajus <- predict(m1, newdata=dbc)
```

---

```

with(dbc, tapply(prod, proced, mean, na.rm=TRUE))
#
#-----#
# o que acontece com os estimadores de mínimos quadrados das médias?
with(dbc, tapply(ajus, proced, mean))
#
#-----#
# como comparar médias? Tukey usando a média harmônica do número de repetições (danger)
dbc.cc <- dbc[complete.cases(dbc),]
with(dbc.cc,
      HSD.test(prod, proced,
                DFerror=df.residual(m1),
                MSerror=deviance(m1)/df.residual(m1)
      ))
#
#-----#
# procedimentos diretos que precisam melhor descrição metodológica (usar com cuidado!)
TukeyHSD(m1)
layout(1)
plot(TukeyHSD(m1))
abline(v=0)
summary(glht(m1, linfct=mcp(proced="Tukey")))
#
#-----#
# contraste de médias populacionais marginais, montando os vetores de comparações
comp <- outer(levels(dbc$proced), levels(dbc$proced),
               function(x, y) paste(x, y, sep="-"))
comp
comp <- comp[upper.tri(comp)]
comp <- do.call(rbind, strsplit(comp, "-"))
comp
#
#-----#
# montando a matriz de contrastes
cX <- sapply(1:nrow(comp),
             function(i){
               c.contr <- contrast(m1, type="average",
                                     list(proced=comp[i,1], bloco=levels(dbc$bloco)),
                                     list(proced=comp[i,2], bloco=levels(dbc$bloco)))
               c.contr$X
             })
cX
#
#-----#
# fornecendo a matriz para a glht para manutenção do erro tipo I
comP <- glht(m1, linfct=t(cX))
summary(comP)
#
#-----#
# as médias marginais populacionais
do.call(c, sapply(levels(dbc$proced),
                  function(i){
                    contrast(m1, type="average", list(proced=i, bloco=levels(dbc$bloco)))[1]
                  }))
#
#-----#
.

```

---

## 7 Análise de experimento fatorial duplo em DIC

### 7.1 Análise de variância

```

#-----#
vol <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/volume.txt", header=TRUE)
str(vol)
unique(vol$dose)                                     #
#-----#
# análise gráfica
require(lattice)
xyplot(volu~dose, groups=gen, data=vol, type=c("p","smooth"))
xyplot(volu~gen|dose, data=vol)                      #
#-----#
# análise de variância
m0 <- aov(volu~gen+dose+gen:dose, data=vol)
m0 <- aov(volu~gen*dose, data=vol)
summary(m0)                                         #
#-----#
# verificando tipo das variáveis
class(vol$gen)
class(vol$dose)
vol$dose <- factor(vol$dose)
class(vol$dose)                                     #
#-----#
# análise de variância com a especificação correta
m0 <- aov(volu~gen*dose, data=vol)
summary(m0)                                         #
#-----#
# checagem
par(mfrow=c(2,2))
plot(m0)
layout(1)                                           #
#-----#
# testes
shapiro.test(residuals(m0))
bartlett.test(residuals(m0)~vol$dose)               #
#-----#
# precisa-se de transformação para normalidade e homocedasticidade
require(MASS)
boxcox(m0)                                         #
#-----#
# usando a transformação indicada
m1 <- aov(volu^0.33~gen*dose, data=vol)
par(mfrow=c(2,2))
plot(m1)
layout(1)
shapiro.test(residuals(m1))
bartlett.test(residuals(m1)~vol$dose)
bartlett.test(residuals(m1)~vol$gen)
summary(m1)                                         #
#-----#
.

```

---

## 7.2 Testes de médias

---

```
#-----#
```

```

# teste de Tukey para gen (com dados transformados)
Tu <- with(vol, HSD.test(volu^0.33, gen,
                         DFn=df.residual(m1),
                         MSn=deviance(m1)/df.residual(m1)
                         ))
Tu
#
#-----#
# aplicando a transformação inversa
Tu$means <- Tu$means^(1/0.33)
Tu
#
#-----#
# médias na escala original
with(vol, tapply(volu, gen, mean))
#
#-----#
# cuidados ao combinar funções estatísticas com funções não lineares
mean(sqrt(1:3))
sqrt(mean(1:3))
#
#-----#
# teste de SkottKnott (com dados transformados)
sk <- SK(x=vol, y=vol$volu^0.33, model="y~gen*dose", which="gen")
sk <- summary(sk)
sk$Means <- sk$Means^(1/0.33)
sk
#
#-----#
.

```

---

## 8 Análise de fatorial duplo em DBC

### 8.1 Entrando com os dados

```

#-----#
rend <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/rendimento.txt", header=TRUE)
str(rend)
rend <- transform(rend, K=factor(K), A=factor(A), bloc=factor(bloc))
str(rend)
#
#-----#
# análise gráfica
xyplot(rg~K|A, groups=bloc, data=rend, type="b", auto.key=TRUE)
#
#-----#
.
```

---

### 8.2 Análise de variância e desdobramento das somas de quadrados

```

#-----#
m0 <- aov(rg~bloc+A*K, data=rend)
summary(m0)
#
#-----#
# checagem
par(mfrow=c(2,2))

```

```

plot(m0)
layout(1)

#-----#
# desdobrando somas de quadrados para a variação de K dentro de A
m1 <- aov(rg~bloc+A/K, data=rend)
summary(m1)
coef(m1)
summary(m1, split=list("A:K"=list(
    "A-37.5"=c(1,4,7,10),
    "A-50.0"=c(2,5,8,11),
    "A-62.5"=c(3,6,9,12)
)))
#-----#
# para facilitar encontrar as posições pode-se fazer a busca por expressões regulares
words <- c("0","R","é","um","programa","livre")
grep("r", words)
names(coef(m1))
names(coef(m1))[8:19]
grep("A37.5", names(coef(m1))[8:19])
grep("A50", names(coef(m1))[8:19])
grep("A62.5", names(coef(m1))[8:19])
#-----#
# usando as expressões regulares vamos desdobrar A dentro de K
m2 <- aov(rg~bloc+K/A, data=rend)
summary(m2)
names(coef(m2))
#-----#
# buscando pela expressão regular
grep("K0", names(coef(m2))[10:19])
grep("K30", names(coef(m2))[10:19])
grep("K60", names(coef(m2))[10:19])
grep("K120", names(coef(m2))[10:19])
grep("K180", names(coef(m2))[10:19])
#-----#
# decomposição das somas de quadrados
summary(m2, split=list("K:A"=list(
    "K-0"=c(1,6),
    "K-30"=c(2,7),
    "K-60"=c(3,8),
    "K-120"=c(4,9),
    "K-180"=c(5,10)
)))
#-----#

```

---

### 8.3 Desdobramento da interação com testes de médias

```

#-----#
# desdobrando a interação em testes de médias para níveis de K fixando os níveis de A
with(subset(rend, A=="37.5"),
      HSD.test(rg, K, DFerror=df.residual(m0), MSerror=deviance(m0)/df.residual(m0)))
with(subset(rend, A=="50"),
      HSD.test(rg, K, DFerror=df.residual(m0), MSerror=deviance(m0)/df.residual(m0)))
with(subset(rend, A=="62.5"),
      HSD.test(rg, K, DFerror=df.residual(m0), MSerror=deviance(m0)/df.residual(m0)))
#-----#

```

```

#-----#
# usando funções para fazer o desdobramento (lapply)
levels(rend$A)
lapply(levels(rend$A),
       function(a){
         with(subset(rend, A==a),
              HSD.test(rg, K,
                        DFerror=df.residual(m0),
                        MSerror=deviance(m0)/df.residual(m0)))
       })
#-----#
# fazendo o mesmo para o teste ScottKnott (a ordem A*K e K*A é importante!)
sk <- SK.nest(x=rend, y=rend$rg, model="y~bloc+A*K", which="A:K", fl2=1)
summary(sk)
sk <- SK.nest(x=rend, y=rend$rg, model="y~bloc+K*A", which="K:A", fl2=1)
summary(sk)
#-----#
# fazer o teste de ScottKnott com um comando apenas (lapply)
length(levels(rend$A))
lapply(1:3,
       function(a){
         sk <- SK.nest(x=rend, y=rend$rg, model="y~bloc+K*A", which="K:A", fl2=a)
         summary(sk)
       })
#-----#
lapply(1:5,
       function(a){
         sk <- SK.nest(x=rend, y=rend$rg, model="y~bloc+A*K", which="A:K", fl2=a)
         summary(sk)
       })
#-----#
#
.

```

---

## 9 Análise de experimento fatorial com um tratamento adicional

---

```

#-----#
# dados (segredo está em como montar a planilha, para provocar o confundimento correto)
fa <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/fat-adi.txt", header=TRUE)
str(fa)
fa <- transform(fa, concentração=factor(concentração), bloc=factor(bloc))
str(fa)
fa
#-----#
# análise de variância para os tratamentos (despreza estrutura fatorial-adicional)
m0 <- lm(media~bloc+trat, fa)
anova(m0)
#-----#
# checagem
par(mfrow=c(2,2))
plot(m0)
layout(1)
shapiro.test(residuals(m0))
bartlett.test(residuals(m0)~fa$trat)
#-----#

```

```

#-----#
# as matrizes de contrastes envolvidas
contrasts(fa$trat)
contrasts(fa$origem)
contrasts(fa$concentração)                                #
#-----#
# para definir os contrastes a testemunha deve ser o último nível
levels(fa$origem)
levels(fa$concentração)
fa$concentração <- factor(fa$concentração, levels=c("25","50","75","0"))
contrasts(fa$concentração)
levels(fa$concentração)                                #
#-----#
# usar contrastes em que a testemunha contraste com os tratamentos (helmert)
contrasts(C(fa$origem, treatment))
contrasts(C(fa$origem, SAS))
contrasts(C(fa$origem, sum))
contrasts(C(fa$origem, poly))
contrasts(C(fa$origem, helmert))                         #
#-----#
# anova só da parte fatorial
anova(m0)
m1 <- aov(media~bloc+origem*concentração, data=subset(fa, trat!="TEST"))
summary(m1)                                              #
#-----#
# anova com fornecimento dos contrates e "arrancando" a SQ do contraste com o adicional
# da SQ do fator origem
m2 <- aov(media~bloc+origem*concentração, data=fa,
           contrast=list(origem=contr.helmert, concentração=contr.helmert))
summary(m2)
summary(m2, expand.split=FALSE,
        split=list("origem"=list("fatorial"=c(1:2), "adicional"=3)))   #
#-----#
# teste de média da testemunha contra as origens na menor concentração
with(subset(fa, concentração %in% c("0","25")),
     HSD.test(media, origem,
              DFerror=df.residual(m2),
              MSerror=deviance(m2)/df.residual(m2)))                      #
#-----#
.

```

---

## 10 Análise de covariância

### 10.1 Análise de variância

```

.
#-----#
# dados
ac <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/ancova.txt", header=TRUE)
str(ac)                                                 #
#-----#
# análise de variância (em experimentos não ortogonais a ordem dos termos é importante!)
m0 <- aov(peso28~sexo*energia, data=ac)
summary(m0)
m1 <- aov(peso28~pi+id+sexo*energia, data=ac)
```

```

summary(m1)
m1 <- aov(peso28~id+pi+sexo*energia, data=ac)
summary(m1)
anova(m0, m1) #  

#-----  

m2 <- aov(peso28~energia*sexo+pi+id, data=ac)
summary(m2)
m2 <- aov(peso28~sexo*energia+pi+id, data=ac)
summary(m2) #  

#-----  

# dado que há efeito de sexo após correção da variação para pi e id, fazer teste de médias  

# deve-se escolher o valor das covariáveis a ser fixado para comparar tratamentos  

mean(ac$pi)  

mean(ac$id) #  

#-----  

# para fazer os contrastes (objeto deve ser da classe lm)
require(contrast)
levels(ac$sexo)
levels(ac$energia)
m0 <- lm(peso28~pi+id+sexo*energia, data=ac)
anova(m0)
par(mfrow=c(2,2))
plot(m0)
layout(1) #  

#-----  

#
.
```

---

## 10.2 Constrainedo entre níveis dos fatores

---

```

#-----  

# femea vs macho castrado
contrast(m0, type="average",
         list(sexo="F", energia=c("baixo","medio","alto"), pi=92, id=138),
         list(sexo="MC", energia=levels(ac$energia), pi=92, id=138)) #  

#-----  

# femêa vs macho imunocastrado
contrast(m0, type="average",
         list(sexo="F", energia=levels(ac$energia), pi=92, id=138),
         list(sexo="MI", energia=levels(ac$energia), pi=92, id=138)) #  

#-----  

# macho castrado vs macho imunocastrado
contrast(m0, type="average",
         list(sexo="MI", energia=levels(ac$energia), pi=92, id=138),
         list(sexo="MC", energia=levels(ac$energia), pi=92, id=138)) #  

#-----  

# as médias marginais populacionais
med <- sapply(levels(ac$sexo),
               function(s){
                 contrast(m0, type="average",
                           list(sexo=s, energia=levels(ac$energia), pi=92, id=138))[1:7]
               })
str(med)
med #  

#-----  

# gráfico de barras com IC para a média
```

```

require(gplots)
barplot2(unlist(med[1,]), ylim=c(120, 130), xpd=FALSE, plot.ci=TRUE,
        ci.l=unlist(med[3,]), ci.u=unlist(med[4,]),
        ylab="Peso aos 28 dias")
box() #  

#-----  

# gráfico de barras com as médias e resultado da comparação  

bp <- barplot(unlist(med[1,]), ylim=c(120, 130), xpd=FALSE, ylab="Peso aos 28 dias")  

text(bp, unlist(med[1,]),  

     label=paste(round(unlist(med[1,]), 2), c("b", "b", "a")), pos=3)  

box() #  

#-----  

.

```

---

## 11 Experimento factorial com fatores qualitativos e quantitativos

---

```

.  

#-----  

# dados  

sorgo <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/anovareg.txt", header=TRUE)  

sorgo <- transform(sorgo, bloco=factor(bloco), cultivar=factor(cultivar))  

str(sorgo) #  

#-----  

# gráficos exploratórios  

require(lattice)  

xyplot(indice~dose|cultivar, groups=bloco, data=sorgo,  

       jitter.x=TRUE, type=c("p", "l"), layout=c(3,1))  

xyplot(indice~dose, groups=cultivar, data=sorgo, jitter.x=TRUE, type=c("p", "a")) #  

#-----  

# análise de variância do modelo de fatores  

m0 <- aov(indice~bloco+cultivar*ordered(dose), data=sorgo)  

summary(m0) #  

#-----  

# checagem  

par(mfrow=c(2,2))  

plot(m0)  

layout(1) #  

#-----  

.
```

---

### 11.1 Desdobramento da interação

---

```

.  

#-----  

# desdobrando as somas de quadrados de doses dentro de cultivar  

# dicas: forneça para 'by' o número de níveis de cultivar (3)  

# forneça para 'length.out' os graus de liberdade de dose (6-1)  

m1 <- aov(indice~bloco+cultivar/ordered(dose), data=sorgo)  

summary(m1)  

coef(m1)  

summary(m1, split=list("cultivar:ordered(dose)"=list(

```

```

    "Ag-1002"=seq(1, by=3, length.out=5),
    "BR-300"=seq(2, by=3, length.out=5),
    "Pioneer-B815"=seq(3, by=3, length.out=5)
  )))
  #
#-----#
# desdobrando somas de quadrados de cultivar dentro das doses
# dicas: forneça para 'by' o número de níveis de dose (6)
# forneça para 'length.out' os graus de liberdade de cultivar (3-1)
m2 <- aov(indice~bloco+ordered(dose)/cultivar, data=sorgo)
coef(m2)
summary(m2, split=list("ordered(dose)":cultivar=list(
  "N.0"=seq(1, by=6, length.out=2),
  "N.60"=seq(2, by=6, length.out=2),
  "N.120"=seq(3, by=6, length.out=2),
  "N.180"=seq(4, by=6, length.out=2),
  "N.240"=seq(5, by=6, length.out=2),
  "N.300"=seq(6, by=6, length.out=2)
)))
#
#-----#
# desdobrando efeitos dos graus polinômio dentro de dose dentro de cultivar
# lof é falta de ajuste (lack of fit)
summary(m1, split=list("cultivar:ordered(dose)"=list(
  "Ag-1002.L"=1,
  "Ag-1002.Q"=4,
  "Ag-1002.C"=7,
  "Ag-1002.lof"=c(10,13),
  "BR-300.L"=2,
  "BR-300.Q"=5,
  "BR-300.C"=8,
  "BR-300.lof"=c(11,14),
  "Pioneer-B815.L"=3,
  "Pioneer-B815.Q"=6,
  "Pioneer-B815.C"=9,
  "Pioneer-B815.lof"=c(12,15)
)))
#
#-----#
.

```

---

## 11.2 Obtenção das equações de regressão e R<sup>2</sup>

```

.
#-----#
# obter as equações de regressão e R^2 para os modelos linear, quadrático e cúbico
# dica: usar contraste tipo soma zero para blocos para se anularem na fórmula
# e remover o intercepto especificando o '1', trocar a ordem dos termos no modelo
# linear (estimativas corretas mas erros padrões e p-valores precisam de correção)
m3 <- aov(indice~-1+cultivar/dose+bloco, data=sorgo,
           contrast=list(bloco=contr.sum))
summary.lm(m3)
#
#-----#
# quadrático (estimativas corretas mas erros padrões e p-valores precisam de correção)
m4 <- aov(indice~-1+cultivar/(dose+I(dose^2))+bloco, data=sorgo,
           contrast=list(bloco=contr.sum))
summary.lm(m4)
#
#-----#
# cúbico (estimativas corretas mas erros padrões e p-valores precisam de correção)
m5 <- aov(indice~-1+cultivar/(dose+I(dose^2)+I(dose^3))+bloco, data=sorgo,
           contrast=list(bloco=contr.sum))

```

```

summary.lm(m5)
#
#-----#
# calcular os R^2
sapply(c(linear=1, quadrático=2, cúbico=3),
       function(degree){
         sapply(levels(sorgo$cultivar),
               function(i){
                 da <- with(subset(sorgo, cultivar==i),
                             aggregate(indice, list(dose=dose), mean))
                 summary(lm(x~poly(dose, degree, raw=TRUE), da)$r.squared
               })))
#
#-----#
.

```

---

## 12 Fatorial com fatores quantitativos - superfície de resposta

### 12.1 Análise de variância e obtenção do modelo empírico

```

.
#-----#
# vamos usar os dados de rendimento de grãos de soja em função de K e A
rend <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/rendimento.txt", header=TRUE)
rend <- transform(rend, bloc=factor(bloc))
str(rend)
#
#-----#
# ajustar um modelo quadrático completo
m0 <- lm(ts~bloc+poly(A, 2, raw=TRUE)*poly(K, 4, raw=TRUE), data=rend) # modelo saturado
m1 <- lm(ts~bloc+poly(A, 2, raw=TRUE)*poly(K, 2, raw=TRUE), data=rend) # modelo desejado
#
#-----#
# testar a falta de ajuste e checagem dos resíduos
anova(m1, m0)
par(mfrow=c(2,2))
plot(m1)
layout(1)
#
#-----#
# ajustando o modelo de segundo grau (dica, usar contr.sum para blocos)
levels(rend$bloc)
contrasts(rend$bloc) <- contr.sum(5)
contrasts(rend$bloc)
m2 <- lm(ts~bloc+(A+I(A^2))*(K+I(K^2)), data=rend)
anova(m2)
#
#-----#
.

```

---

### 12.2 Gráfico do modelo final

```

.
#-----#
# ajustar modelo menor e testar a falta de ajuste
m3 <- lm(ts~bloc+A+K+A:I(A^2)+I(K^2), data=rend)
anova(m2, m3)
anova(m3, m0)
```

```

summary(m3)                                     #
#-----#
# fazer o gráfico tridimensional dos valores preditos (dica, ajustar um modelo sem blocos
# apenas para fazer a predição, certificar-se de que as estimativas são as mesmas)
m4 <- lm(ts~A+K+A:K+I(A^2)+I(K^2), data=rend)
summary(m4)
p0 <- expand.grid(A=seq(35,65,l=80), K=seq(0,200, l=80))
p0$ts <- predict(m4, newdata=p0)               #
#-----#
# usar a wireframe() da lattice (ver persp(), contour(), contourplot())
require(lattice)
wireframe(ts~A*K, data=p0, scales=list(arrows=FALSE))
levelplot(ts~A*K, data=p0, scales=list(arrows=FALSE), col.regions=heat.colors)      #
#-----#
# outros gráficos
A <- seq(35,65,l=20); K <- seq(0,200, l=20)
p0 <- expand.grid(A=A, K=K)
p0$ts <- predict(m4, newdata=p0)
filled.contour(A, K, matrix(p0$ts,20,20))
contour(A, K, matrix(p0$ts,20,20))           #
#-----#
.

```

---

## 13 Análise de experimentos em parcela subdividida

### 13.1 Análise de variância

```

#-----#
# dados
ps <- expand.grid(BL=c("I","II","III","IV"),
                   ES=c("e1","e2"),
                   AD=c("a1","a2","a3"))
ps$alt <- c(58,77,38,52,44,59,30,34,
          85,90,73,77,59,68,45,55,
          66,93,67,64,54,75,53,48)
str(ps)                                         #
#-----#
# análise de variância (erro A = BL x AD)
m0 <- aov(alt~BL+AD+Error(BL:AD)+ES+AD:ES, data=ps)
m0 <- aov(alt~BL+AD*ES+Error(BL:AD), data=ps)
summary(m0)                                     #
#-----#
# checagem
class(m0)
m1 <- lm(alt~BL+AD*ES, data=ps)
par(mfrow=c(2,2))
plot(m1)
shapiro.test(residuals(m1))                  #
#-----#
.

```

---

## 13.2 Teste de médias

---

```

#-----#
# dedobrar ES em cada nível de AD
require(agricolae)
df.residual(m0)
deviance(m0) #-----#
# temos que retirar os valores de GL e QM da anova
str(summary(m0))
str(summary(m0)[[1]])
str(summary(m0)[[1]][[1]])
summary(m0)[[1]][[1]]
summary(m0)[[2]][[1]]
glP <- summary(m0)[[1]][[1]][3,1]
qmP <- summary(m0)[[1]][[1]][3,3]
gls <- summary(m0)[[2]][[1]][3,1]
qmS <- summary(m0)[[2]][[1]][3,3]
qmS #-----#
# teste de Tukey
lapply(levels(ps$AD),
      function(a){
        with(subset(ps, AD==a),
             HSD.test(alt, ES, DFerror=glS, MSerror=qmS))
      }) #-----#
# teste de ScottKnott
lapply(1:3,
      function(a){
        sk <- SK.nest(x=ps, y=ps$alt, model="y~BL+ES*AD+Error(BL:AD)",
                      which="ES:AD", fl2=a, error="Within")
        summary(sk)
      }) #-----#
# desdobrar AD dentro de ES (requer variância complexa, expressão de Satterthwaite)
# função criada para calcular o QM e GL aproximados baseados na função linear de QMs
satter <- function(A, B, C=c(0,1,1)){
  ## cada termo é um vetor cujos elementos são QM, GL e número de níveis de cada estrato/fator
  ## o vetor em C só precisa ser fornecido em casos de parcela subdividida
  qmr <- (A[1]+(B[3]-1)*B[1]+B[3]*(C[3]-1)*C[1])/(B[3]*C[3])
  ngl <- (A[1]+(B[3]-1)*B[1]+B[3]*(C[3]-1)*C[1])/2/
    ((A[1]^2/A[2])+((B[3]-1)*B[1])^2/B[2]+(B[3]*(C[3]-1)*C[1])^2/C[2])
  return(c(qmr=qmr, ngl=ngl))
} #-----#
# obtendo o QM e GL (QM do resíduo, GL do resíduo e número de níveis do fator do estrato)
satter=A=c(qmP, glP, 3), B=c(qmS, glS, 2))
lapply(levels(ps$ES),
      function(a){
        with(subset(ps, ES==a),
             HSD.test(alt, AD, DFerror=7.43, MSerror=29.83))
      }) #-----#
# desdobrar com o teste de ScottKnott
lapply(1:2,
      function(a){
        sk <- SK.nest(x=ps, y=ps$alt, model="y~BL+AD*ES+Error(BL:AD)",
                      which="AD:ES", fl2=a, error="BL:AD")
      })

```

```

        summary(sk)
})
#
#-----#

```

---

## 14 Experimentos em parcelas subsubdivididas

### 14.1 Análise de variância

```

#
#-----#
# dados
pss <- read.table("http://www.leg.ufpr.br/~walmes/cursoR/pss.txt", header=TRUE)
str(pss)
pss <- transform(pss, dorg=factor(dorg), dnpk=factor(dnpk), bloco=factor(bloco))
str(pss)
#
#-----#
# análise de variância, ErroA=bloco:parcela, ErroB=bloco:parcela:subparcela
m0 <- aov(AF~bloco+fonte*dorg*dnpk+Error(bloco:fonte/dorg), data=pss)
summary(m0)
#
#-----#
# checagem não é possível por padrão
class(m0)
m1 <- aov(AF~bloco+fonte*dorg*dnpk, data=pss)
par(mfrow=c(2,2))
plot(m1)
layout(1)
#
require(MASS)
boxcox(m1)
m2 <- aov(log(AF)~bloco+fonte*dorg*dnpk, data=pss)
par(mfrow=c(2,2))
plot(m2)
#
#-----#
# análise de variância com dados transformados
m0 <- aov(log(AF)~bloco+fonte*dorg*dnpk+Error(bloco:fonte/dorg), data=pss)
summary(m0)
#
#-----#
.
```

---

### 14.2 Testes de médias

```

#
#-----#
# desdobrar níveis da subsub dentro de níveis da sub com parcela (usa erro C)
require(agricolae)
gl3 <- summary(m0)[[3]][[1]][5,1]
qm3 <- summary(m0)[[3]][[1]][5,3]
#
lapply(levels(pss$fonte),
      function(f){
        lapply(levels(pss$dorg),

```

```

        function(o){
          tes <- with(subset(pss, fonte==f & dorg==o),
                      HSD.test(log(AF), dnpk,
                                DFerror=gl3, MSerror=qm3))
          tes$means <- exp(tes$means)
          tes
        })
      }

#-----#
# desdobrar níveis de dorg em níveis de fonte com dnpk (usa variância combinada)
gl1 <- summary(m0)[[1]][[1]][3,1]
qm1 <- summary(m0)[[1]][[1]][3,3]
gl2 <- summary(m0)[[2]][[1]][3,1]
qm2 <- summary(m0)[[2]][[1]][3,3]
vcBemCA <- satter(c(qm2, gl2, 4),
                    c(qm3, gl3, 5))
vcBemCA

#-----#
lapply(levels(pss$fonte),
       function(f){
         lapply(levels(pss$dnpk),
               function(npk){
                 tes <- with(subset(pss, fonte==f & dnpk==npk),
                             HSD.test(log(AF), dorg,
                                       DFerror=vcBemCA["ngl"], MSerror=vcBemCA["qmr"]))
                 tes$means <- exp(tes$means)
                 tes
               })
         })

#-----#
# desdobrar níveis de fonte dentro de níveis de dorg com dnpk
vcAemBC <- satter(c(qm1, gl1, 3),
                    c(qm2, gl2, 4),
                    c(qm3, gl3, 5))
vcAemBC

#-----#
lapply(levels(pss$dorg),
       function(o){
         lapply(levels(pss$dnpk),
               function(npk){
                 tes <- with(subset(pss, dorg==o & dnpk==npk),
                             HSD.test(log(AF), fonte,
                                       DFerror=vcAemBC["ngl"], MSerror=vcAemBC["qmr"]))
                 tes$means <- exp(tes$means)
                 tes
               })
         })

#-----#
# usando o teste de ScottKnott para dnpk em fonte com dorg
require(ScottKnott)
tes <- SK.nest(x=pss, y=log(pss$AF), model="y~bloco+dnpk*fonte*dorg+Error(bloco:fonte/dorg)",
               which="dnpk:fonte:dorg", error="Within", fl2=1, fl3=1)
summary(tes)

#-----#
lapply(1:3,
       function(f){
         lapply(1:4,
               function(o){
                 tes <- SK.nest(x=pss, y=log(pss$AF),
                               model="y~bloco+dnpk*fonte*dorg+Error(bloco:fonte/dorg)",
                               which="dnpk:fonte:dorg", error="Within",

```

```

        fl2=f, fl3=o)
    tes <- summary(tes)
    tes$Means <- exp(tes$Means)
    tes
  })
}

#-----#
# desdobrar dorg em fonte com dnpk
tes <- SK.nest(x=pss, y=log(pss$AF),
               model="y~bloco+dorg*fonte*dnpk+Error(bloco:fonte/dorg)",
               which="dorg:fonte:dnpk", error="bloco:fonte:dorg", fl2=1, fl3=1)
summary(tes) #-----#
lapply(1:3,
       function(f){
         lapply(1:5,
                function(npk){
                  tes <- SK.nest(x=pss, y=log(pss$AF),
                                 model="y~bloco+dorg*fonte*dnpk+Error(bloco:fonte/dorg)",
                                 which="dorg:fonte:dnpk", error="bloco:fonte:dorg",
                                 fl2=f, fl3=npk)
                  tes <- summary(tes)
                  tes$Means <- exp(tes$Means)
                  tes
                })
      })
}

#-----#
# desdobrar fonte em dorg com dnpk
tes <- SK.nest(x=pss, y=log(pss$AF),
               model="y~bloco+fonte*dorg*dnpk+Error(bloco:fonte/dorg)",
               which="fonte:dorg:dnpk", error="bloco:fonte", fl2=1, fl3=1)
summary(tes) #-----#
lapply(1:4,
       function(o){
         lapply(1:5,
                function(npk){
                  tes <- SK.nest(x=pss, y=log(pss$AF),
                                 model="y~bloco+fonte*dorg*dnpk+Error(bloco:fonte/dorg)",
                                 which="fonte:dorg:dnpk", error="bloco:fonte",
                                 fl2=o, fl3=npk)
                  tes <- summary(tes)
                  tes$Means <- exp(tes$Means)
                  tes
                })
      })
}

#-----#

```

---

## 15 Recursos gráficos

### 15.1 Gráficos do pacote *graphics*

---

```

#-----#
# conhecendo os recursos gráficos
layout(1)

```

```

demo(graphics)                                     #
#-----#
# carregando dados disponível no R
data(anscombe)
str(anscombe)                                     #
#-----#
# gráficos de dispersão e identificação de pontos
plot(y1~x1, data=anscombe,
      col="red", pch=3, type="p", cex=1.2)
with(anscombe, identify(x1, y1))                 #
#-----#
# gráficos de funções e inserção de legenda
curve((2*pi*1)^-0.5*exp(-0.5*(x-0)^2/1), from=-3, to=3)
curve(dnorm(x, 0.5, 1.1), col="green", lty=2, add=TRUE)
legend(x=-3, y=0.4, legend=c("N(0,1)", "N(0.5,1.1)"),
       col=c(1,3), lty=c(1,2))                      #
#-----#
# visualizando a distribuição dos dados
hist(anscombe$y1)
with(anscombe, plot(density(y1)))
qqnorm(anscombe$y1); qqline(anscombe$y1)
with(anscombe, plot(ecdf(y1)))                   #
#-----#
# boxplot e adição de retas
x <- matrix(rep(1:10, 10), ncol=10)
x[10,] <- 10:19
boxplot(x)
fivenum(1:10)
abline(h=fivenum(1:10), col="orange", lty=5)
abline(h=8+(8-3)*1.5, col="cyan", lty=4)
abline(v=6.5)
abline(a=9, b=1, col="red")                      #
#-----#
# combinando recursos gráficos (1)
hist(anscombe$y1, freq=FALSE)
lines(density(anscombe$y1))
mean(anscombe); sd(anscombe)
curve(dnorm(x, 7.5, 2.03), col="green", lty=2, add=TRUE)   #
#-----#
# combinando recursos gráficos (2)
plot(y1~x1, data=anscombe)
m0 <- lm(y1~x1, data=anscombe)
abline(m0, col="red")
with(anscombe, segments(x1, y1, x1, fitted(m0)))
with(anscombe, points(x1, fitted(m0), pch=3))             #
#-----#
# combinando recursos gráficos (3)
plot(y1~x1, data=anscombe,
      xlab="Valores de x", ylab="Valores de y")
new.x1 <- seq(4, 14, length=20)
p0 <- predict(m0, newdata=data.frame(x1=new.x1),
              interval="confidence")
str(p0)
lines(new.x1, p0[, "fit"], lwd=2)
lines(new.x1, p0[, "lwr"], lty=2)
lines(new.x1, p0[, "upr"], lty=2)
coef(m0)
legend("topleft", legend="y=3+0.5*x",
       col=1, lwd=2, bty="n")

```

```

#-----#
# gráficos de barras com texto
mads <- apply(anscombe[,5:8], 2, mad)
tt <- barplot(mads, ylim=c(0,2.5))
text(tt, mads, label=mads, pos=3)
title("Desvios absolutos da mediana") #
#-----#
# gráficos de setores (pizza)
str(HairEyeColor)
x <- apply(HairEyeColor, 2, sum)
x <- apply(HairEyeColor, 1, sum)
pie(x)
pie(mads, main="DAM") #
#-----#
# interpretando o qqplot
n <- 1000
x <- rnorm(n, 2, 1.2) #x <- rbeta(n, 2, 1.2) #x <- rgamma(n, 2, 1.2)
qnorm(x); qqline(x, col="red")
op <- par(fig=c(.02,.5,.5,.98), new=TRUE)
hist(x, freq=FALSE, axes=FALSE, main="", xlab="", ylab="")
lines(density(x), col="red", lwd=2)
box()
par(op) #
#-----#
# gráficos de contornos de níveis
str(volcano)
x <- 10*(1:nrow(volcano))
y <- 10*(1:ncol(volcano))
image(x, y, volcano)
contour(x, y, volcano, add=TRUE)
image(matrix(rnorm(100),10,10))
contour(matrix(rnorm(100),10,10)) #
#-----#
# funções paramétricas de representação 3D
x <- seq(-10, 10, length=50)
y <- x
z <- outer(x, y, function(x,y) 0.5*sin(x)+0.8*sin(y))
filled.contour(x, y, z)
persp(x, y, z, theta=30, phi=30, expand=0.5, col="lightgreen") #
#-----#
# matriz de gráficos de dispersão
pairs(~mpg+disp+drat+wt,
      data=mtcars,
      main="Matriz gráfica de dispersão") #
#-----#
.
```

---

## 15.2 Gráficos do pacote *lattice*

```

#-----#
# carregando a biblioteca gráfica (vem com o R por padrão)
require(lattice) #
#-----#
# distribuição
histogram(~height|voice.part, data=singer)
```

```

densityplot(~height|voice.part, data=singer)
qqmath(~height|voice.part, data=singer)                                            #
#-----#
# dispersão
xyplot(Petal.Length~Sepal.Length|Species, data=iris,
type=c("p","smooth"))                                                       #
#-----#
# box and whiskers (caixa e bigode)
bwplot(depth~factor(mag)|cut(stations,2), data=quakes, pch="|")                #
#-----#
# representação 3D
wireframe(volcano, shade=TRUE)
g <- expand.grid(x=1:10, y=5:15, gr=1:2)
g$z <- log((g$x^g$g+g$y^2)*g$gr)
wireframe(z~x*y, data=g, groups=gr)
cloud(Sepal.Length~Petal.Length*Petal.Width|Species, data=iris)                 #
#-----#
# matriz de gráficos de dispersão
splom(~iris[1:4], groups=Species, data=iris)                                     #
#-----#
.

```

---