

# SME0816 - Planejamento de Experimentos I: Comparações Múltiplas

---

Profa. Cibele Russo

(Referências: Montgomery (2012), Notas de aula de Roseli Leandro; Clarice Demétrio; Marinho Andrade)

## Revisando

```
require(readxl)
```

```
## Loading required package: readxl
datos <- read_xlsx("plasma_pag_62_ed7.xlsx")
str(datos)
```

```
## tibble [20 x 2] (S3: tbl_df/tbl/data.frame)
##  $ Potencia : num [1:20] 160 160 160 160 160 180 180 180 180 180 ...
##  $ Etch.rate: num [1:20] 575 542 530 539 570 565 593 590 579 610 ...
datos$Potencia <- as.factor(datos$Potencia)
str(datos)
```

```
## tibble [20 x 2] (S3: tbl_df/tbl/data.frame)
##  $ Potencia : Factor w/ 4 levels "160","180","200",...: 1 1 1 1 1 2 2 2 2 2 ...
##  $ Etch.rate: num [1:20] 575 542 530 539 570 565 593 590 579 610 ...
```

# Os dados

dados

```
## # A tibble: 20 x 2
##   Potencia Etch.rate
##   <fct>      <dbl>
## 1 160          575
## 2 160          542
## 3 160          530
## 4 160          539
## 5 160          570
## 6 180          565
## 7 180          593
## 8 180          590
## 9 180          579
## 10 180          610
## 11 200          600
## 12 200          651
## 13 200          610
## 14 200          637
## 15 200          629
## 16 220          725
## 17 220          700
## 18 220          715
## 19 220          685
## 20 220          710
```

# comparando as funções lm e função aov

```
names(dados)

## [1] "Potencia" "Etch.rate"
(mod.lm <- lm(Etch.rate ~ Potencia, data=dados))

##
## Call:
## lm(formula = Etch.rate ~ Potencia, data = dados)
##
## Coefficients:
## (Intercept) Potencia180 Potencia200 Potencia220
##          551.2          36.2          74.2          155.8
(mod.aov <- aov(Etch.rate ~ Potencia, data=dados))

## Call:
## aov(formula = Etch.rate ~ Potencia, data = dados)
##
## Terms:
##          Potencia Residuals
## Sum of Squares 66870.55  5339.20
## Deg. of Freedom      3      16
##
## Residual standard error: 18.26746
## Estimated effects may be unbalanced
```

```
names(mod.lm)
```

```
## [1] "coefficients" "residuals" "effects" "rank"  
## [5] "fitted.values" "assign" "qr" "df.residual"  
## [9] "contrasts" "xlevels" "call" "terms"  
## [13] "model"
```

```
names(mod.aov)
```

```
## [1] "coefficients" "residuals" "effects" "rank"  
## [5] "fitted.values" "assign" "qr" "df.residual"  
## [9] "contrasts" "xlevels" "call" "terms"  
## [13] "model"
```

```
class(mod.lm)
```

```
## [1] "lm"
```

```
class(aov)
```

```
## [1] "function"
```

# Quadro da ANOVA

```
anova(mod.lm)
```

```
## Analysis of Variance Table
```

```
##
```

```
## Response: Etch.rate
```

```
##           Df Sum Sq Mean Sq F value    Pr(>F)
```

```
## Potencia   3  66871 22290.2  66.797 2.883e-09 ***
```

```
## Residuals 16   5339   333.7
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
anova(mod.aov)
```

```
## Analysis of Variance Table
```

```
##
```

```
## Response: Etch.rate
```

```
##           Df Sum Sq Mean Sq F value    Pr(>F)
```

```
## Potencia   3  66871 22290.2  66.797 2.883e-09 ***
```

```
## Residuals 16   5339   333.7
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Modelo superparametrizado (restrição default do R:  $\tau_1 = 0$ )

$$y_{ij} = \mu + \tau_i + e_{ij}, \quad e_{ij} \sim N(0, \sigma^2)$$

$$e_{ij} = y_{ij} - \mu - \tau_i$$

**y ajustado:**  $\hat{y}_{ij}$

$$\hat{y}_{ij} = \hat{\mu} + \hat{\tau}_i$$

**$e_{ij}$  ajustado:**  $\hat{e}_{ij}$

$$\hat{e}_{ij} = y_{ij} - \hat{y}_{ij}$$

Estimativa para  $\theta$

$$\hat{\theta} = \begin{bmatrix} \hat{\mu} \\ \hat{\tau}_1 \\ \hat{\tau}_2 \\ \vdots \\ \hat{\tau}_a \\ \hat{\sigma}^2 \end{bmatrix}$$

## Estimativa para $\sigma^2$

```
sigma(mod.lm)^2
```

```
## [1] 333.7
```

```
sigma(mod.aov)^2
```

```
## [1] 333.7
```

```
y.obs <- dados$Etch.rate
```

```
# Número de tratamentos
```

```
(a <- length(unique(dados$Potencia)))
```

```
## [1] 4
```

```
# Número de observações
```

```
(n <- length(y.obs))
```

```
## [1] 20
```

```
sum((y.obs-fitted(mod.lm))^2)/(n-a)
```

```
## [1] 333.7
```

$\hat{\theta}$  do exemplo

$$\hat{\theta} = \begin{bmatrix} \hat{\mu} \\ \hat{\tau}_1 \\ \hat{\tau}_2 \\ \hat{\tau}_3 \\ \hat{\tau}_4 \\ \hat{\sigma}^2 \end{bmatrix} = \begin{bmatrix} 551,2 \\ 0,00 \\ 36,20 \\ 74,20 \\ 155,80 \\ 333,70 \end{bmatrix}$$

$$\hat{\sigma}^2 = QMRes = 333,70 \quad \text{e} \quad \text{g. l. res} = 16 = 20 - 4,$$

- QMRes e g.l. res são quantidades necessárias para o Teste de Tukey.

# Interpretação

```
dummy.coef(mod.lm)

## Full coefficients are
##
## (Intercept):      551.2
## Potencia:         160    180    200    220
##                   0.0   36.2   74.2  155.8

tapply(dados$Etch.rate, dados$Potencia, mean)

##    160    180    200    220
## 551.2 587.4 625.4 707.0

mean(dados$Etch.rate)

## [1] 617.75
```

- $\mu$  é a média do tratamento 1: Potência = 160;
- $\tau_1 = 0$  pela restrição do modelo;
- $\tau_i$ ,  $i = 2, 3, 4$  o efeito do tratamento  $i$  em relação a média do tratamento 1, isto é, quanto a média do tratamento  $i$  difere da média do tratamento 1.
- Observe que com a restrição  $\tau_1 = 0$  a estimativa para  $\mu$  não representa a média geral, e sim, uma constante inerente aos dados, nesse caso,  $\mu = \bar{y}_1$ , a média do tratamento 1.

## As funções abaixo podem auxiliá-lo a descrever o conjunto de dados

```
(d1 <- tapply(dados$Etch.rate, dados$Potencia,summary))
```

```
## $`160`  
##   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.  
##  530.0  539.0  542.0  551.2  570.0  575.0  
##  
## $`180`  
##   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.  
##  565.0  579.0  590.0  587.4  593.0  610.0  
##  
## $`200`  
##   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.  
##  600.0  610.0  629.0  625.4  637.0  651.0  
##  
## $`220`  
##   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.  
##   685    700    710    707    715    725
```


```
d2 <- tapply(dados$Etch.rate, dados$Potencia,length)
d3 <- tapply(dados$Etch.rate, dados$Potencia,sum)
d4 <- tapply(dados$Etch.rate, dados$Potencia,mean)
d5 <- tapply(dados$Etch.rate, dados$Potencia,var)
d6 <- tapply(dados$Etch.rate, dados$Potencia,sd)
```

```
data.frame(n=d2,soma=d3,media=d4,
           variancia=d5,desvio.pad=round(d6,1))
```

```
##      n soma media variancia desvio.pad
## 160 5 2756 551.2      400.7      20.0
## 180 5 2937 587.4      280.3      16.7
## 200 5 3127 625.4      421.3      20.5
## 220 5 3535 707.0      232.5      15.2
```

# Boxplot com valores observados

```
## Loading required package: ggplot2
```




# Análise no R

```
mod1 <- aov(dados$Etch.rate ~ dados$Potencia)
anova(mod1)
## Analysis of Variance Table
##
## Response: dados$Etch.rate
##
##           Df Sum Sq Mean Sq F value    Pr(>F)
## dados$Potencia  3  66871  22290.2  66.797 2.883e-09 ***
## Residuals    16   5339   333.7
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

# Obtenção dos resíduos: ordinário, padronizado, estudentizado

```
res1 <- mod.lm$res # Resíduo ordinário
res2 <- rstandard(mod.lm) # Resíduos padronizado
res3 <- rstudent(mod.lm) # resíduo estudentizado
data.frame(res1,res2,res3)
```

```
##      res1      res2      res3
## 1  23.8  1.4566455  1.5143741
## 2  -9.2 -0.5630730 -0.5506764
## 3 -21.2 -1.2975161 -1.3281303
## 4 -12.2 -0.7466838 -0.7359089
## 5  18.8  1.1506275  1.1632571
## 6 -22.4 -1.3709604 -1.4130125
## 7   5.6  0.3427401  0.3330817
## 8   2.6  0.1591293  0.1541984
## 9  -8.4 -0.5141102 -0.5019482
## 10 22.6  1.3832012  1.4273336
## 11 -25.4 -1.5545712 -1.6336291
## 12 25.6  1.5668119  1.6488129
## 13 -15.4 -0.9425353 -0.9390477
## 14  11.6  0.7099617  0.6985080
## 15   3.6  0.2203329  0.2136608
## 16  18.0  1.1016646  1.1095957
## 17  -7.0 -0.4284251 -0.4172209
## 18   8.0  0.4896287  0.4776731
## 19 -22.0 -1.3464790 -1.3845225
## 20   3.0  0.1836108  0.1779680
```




#

```
## Loading required package: hnp
```

```
## Loading required package: MASS
```



```
## Gaussian model (lm object)
```



## Graficamente


##	Potencia	taxa	fit	res
## 1	160	575	551.2	1.5144
## 2	160	542	551.2	-0.5507
## 3	160	530	551.2	-1.3281
## 4	160	539	551.2	-0.7359
## 5	160	570	551.2	1.1633
## 6	180	565	587.4	-1.4130
## 7	180	593	587.4	0.3331
## 8	180	590	587.4	0.1542
## 9	180	579	587.4	-0.5019
## 10	180	610	587.4	1.4273
## 11	200	600	625.4	-1.6336
## 12	200	651	625.4	1.6488
## 13	200	610	625.4	-0.9390
## 14	200	637	625.4	0.6985
## 15	200	629	625.4	0.2137
## 16	220	725	707.0	1.1096
## 17	220	700	707.0	-0.4172
## 18	220	715	707.0	0.4777
## 19	220	685	707.0	-1.3845
## 20	220	710	707.0	0.1780

## Gráficos



```
#```{r, echo=F, eval=T, fig.asp=0.30}  
require(hnp)  
hnp(mod.lm, resid.type="student", how.many.out=T)
```

```
## Gaussian model (lm object)
```



```
## Total points: 20
```

```
## Points out of envelope: 5 ( 25 %)
```

- Idealmente, todos os pontos devem estar dentro do envelope simulado
- Alguns autores sugerem uma tolerância, por exemplo 10% de um conjunto de dados “pequeno” estiverem fora do envelope simulado ou 5% de um conjunto de dados “grande”. (Clarice G. B. Demétrio em 03/05/2021).

## Verificação dos pressupostos básicos: Homocedasticidade

Teste de Bartlett

```
bartlett.test(Etch.rate ~Potencia, data=dados )
```

```
##
```

```
## Bartlett test of homogeneity of variances
```

```
##
```

```
## data: Etch.rate by Potencia
```

```
## Bartlett's K-squared = 0.43349, df = 3, p-value = 0.9332
```

## Verificação dos pressupostos básicos: normalidade

Teste de Shapiro-Wilk

```
shapiro.test(rstudent(mod.lm))  
  
##  
## Shapiro-Wilk normality test  
##  
## data:  rstudent(mod.lm)  
## W = 0.94514, p-value = 0.2993
```

# Quadro da ANOVA

```
mod = mod_anula1
```

```
anova(mod.lm)
```

```
## Analysis of Variance Table
```

```
##
```

```
## Response: Etch.rate
```

```
##           Df Sum Sq Mean Sq F value    Pr(>F)
```

```
## Potencia   3  66871 22290.2  66.797 2.883e-09 ***
```

```
## Residuals 16   5339   333.7
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Conclusão:

- Rejeita-se  $H_0$  no nível de significância  $\alpha = 5\%$
- Em média as taxas de gravação diferem entre si.
- Existe diferença entre pelo menos um contraste de dois tratamentos.
- Ou ainda, pelo menos duas taxas de gravação diferem entre si.
- Dando prosseguimento à análise.

## Testes de comparações múltiplas

- Ao comparar mais de duas médias, um teste ANOVA informa se as médias são significativamente diferentes uma das outras, mas não informa quais médias diferem umas das outras.
- Quando a hipótese nula,  $H_0$ , é rejeitada. Deve-se dar continuidade à análise estatística dos dados utilizando testes de comparações múltiplas para localizar onde ocorreu a diferença. Os **procedimentos de comparação múltipla (MCPs)**, fornecem informações mais detalhadas sobre as diferenças entre os médias.

## Métodos de comparação múltipla (MCP, ou MCM)

- Uma variedade de métodos de comparação múltipla estão disponíveis
  - Teste t;
  - Teste de Tukey;
  - Teste de Scheffé;
  - Teste de Duncan;
  - Teste de Dunnet;
  - Correção de Bonferroni;

entre outros.

## O que é um contraste de médias?

Um contraste é uma combinação linear dos parâmetros da forma:

$$\Gamma = \sum_{i=1}^a c_i \mu_i$$

em que as constantes  $c_i, i = 1, \dots, a$  satisfazem

$$\sum_{i=1}^a c_i = 0.$$

## Exemplo de contrastes

1.  $H_0 : \mu_3 = \mu_4$  ou equivalentemente,  
 $H_0 : \mu_3 - \mu_4 = 0$

$$c_1 = c_2 = 0, c_3 = 1, c_4 = -1$$

2.  $H_0 : \mu_1 + \mu_2 = \mu_3 + \mu_4$  ou equivalentemente;  
 $H_0 : \mu_1 + \mu_2 - \mu_3 - \mu_4 = 0$

$$c_1 = c_2 = 1, c_3 = c_4 = -1$$

# Teste de Tukey

- é um teste de comparação de contrastes que envolvem duas médias.
- é um teste de comparação de médias duas a duas
- Se o número de tratamentos é igual a “ $a$ ” tem-se

$$m = \frac{a(a - 1)}{2}$$

comparações de médias duas a duas.

O teste de Tukey foi desenvolvido por John Wilder Tukey e apresentado em 1949 no artigo titulado “Comparing Individual Means in the Analysis of Variance” (Biometrics. 5 (2): 99-114. JSTOR 3001913).



- [https://en.wikipedia.org/wiki/John\\_Tukey](https://en.wikipedia.org/wiki/John_Tukey)
- John Wilder Tukey (1915 - 2000) foi um matemático e estatístico americano famoso pelo algoritmo Fast Fourier Transform (FFT) e pelo gráfico boxplot.

## Teste de Tukey (TSD - Tukey Significant Difference)

- O Teste proposto por Tukey (1953) é também conhecido como:
  - teste de Tukey da diferença honestamente significativa (honestly significant difference)(HSD) e,
  - teste de Tukey da diferença totalmente significativa (wholly significant difference)(WSD).
  - As hipóteses a serem testadas são:

$$\begin{cases} H_0 : \mu_i = \mu_j \\ H_1 : \mu_i \neq \mu_j, i > j \end{cases}$$

- Para tamanhos de amostras iguais (dados balanceados), o teste de Tukey declara duas médias significativamente diferentes se o valor absoluto de suas diferenças amostrais ultrapassar a diferença mínima significativa (DMS) ou Diferença significativa de Tukey (DST) (TSD-Tukey Significant Difference)

Ou seja,

- O procedimento de Tukey utiliza a estatística da amplitude studentizada

$$Q = \frac{|\bar{Y}_i - \bar{Y}_j|}{\sqrt{\frac{QMRes}{k}}}$$

e declara duas médias significativamente diferentes se

$$|\bar{y}_i. - \bar{y}_j.| > TSD = DMS$$

em que

$$DMS = TSD = q_{\alpha}(a, na - a) \sqrt{\frac{QMRes}{n}},$$

e  $q(a, na - a)$  é a amplitude studentizada e  $a$  é o número de tratamentos e  $n$  é o número de unidades experimentais, ou ainda,  $na - a$  é o número de graus de liberdade do resíduo.

- Em outras palavras, rejeita-se a igualdade da média de dois níveis de tratamento se

$$|\bar{y}_i. - \bar{y}_j.| > DMS$$

## Intervalo de confiança (dados balanceados)

- Também pode-se rejeitar  $H_0$  quando o intervalo de confiança de  $100(1 - \alpha)$  para a diferença entre o par de médias correspondente não incluir zero, indicando que o valor  $p$  para o teste de igualdade de médias é menor do que 0,05.

$$\begin{aligned} \overline{y}_i - \overline{y}_j - q_\alpha(a, na - a) \sqrt{\frac{QMRes}{n}} &\leq \mu_i - \mu_j \leq \\ &\leq \overline{y}_i - \overline{y}_j + q_\alpha(a, na - a) \sqrt{\frac{QMRes}{n}}, \quad i \neq j. \end{aligned}$$

## Dados desbalanceados

Quando o tamanho das amostras são diferentes (dados não balanceados), o teste de Tukey é modificado e é chamado de Teste de Tukey-Kramer. Esse teste não é exato, mas é minimamente conservativo no sentido em que a FWER real é muitas vezes menor que  $\alpha$ .

O teste de Tukey-Kramer declara duas médias significativamente diferentes se o valor absoluto de suas diferenças amostrais ultrapassar a diferença mínima significativa (DMS)

$$DMS = \frac{q_{\alpha}(a, \sum_{l=1}^a n_l - a)}{\sqrt{2}} \sqrt{QMRes \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}$$

## Intervalo de confiança (dados desbalanceados)

$$\begin{aligned} \bar{y}_i. - \bar{y}_j. - \frac{q_\alpha(a, \sum_{l=1}^a n_l - a)}{\sqrt{2}} \sqrt{QMRes \left( \frac{1}{n_i} + \frac{1}{n_j} \right)} &\leq \mu_i - \mu_j \leq \\ &\leq \bar{y}_i. - \bar{y}_j. + \frac{q_\alpha(a, \sum_{l=1}^a n_l - a)}{\sqrt{2}} \sqrt{QMRes \left( \frac{1}{n_i} + \frac{1}{n_j} \right)} \end{aligned}$$

O teste de Tukey-Kramer também fornece intervalos uniformemente mais curtos que qualquer um dos outros de uma etapa para a família de todas as comparações duas a duas.

- O teste de Tukey tem-se mostrado analiticamente ótimo, no sentido que, entre todos os procedimentos que resultam em intervalos de confiança com mesmo tamanho para todas diferenças duas a duas com coeficiente de confiança da família de pelo menos  $1 - \alpha$ , o teste de Tukey resulta em intervalos menores.
- Isso quer dizer que, se a família consiste em todas comparações duas a duas e o teste de Tukey pode ser usado, ele resultará em intervalos menores que qualquer outro método de comparação múltipla de uma etapa.

## Exemplo: Plasma

- $a = 4$ ,  $trat = Potencia = 160, 180, 200, 220$
- $m = \frac{a(a-1)}{2} = \frac{4(4-1)}{2} = 6$  comparações, a saber:

	$\mu_{160}$	$\mu_{180}$	$\mu_{200}$
$\mu_{180}$	$ \mu_{180} - \mu_{160} $		
$\mu_{200}$	$ \mu_{200} - \mu_{160} $	$ \mu_{200} - \mu_{180} $	
$\mu_{220}$	$ \mu_{220} - \mu_{160} $	$ \mu_{220} - \mu_{180} $	$ \mu_{220} - \mu_{200} $

## Teste Tukey passo a passo (dados balanceados)

```
(mean.trat <- tapply(dados$Etch.rate, dados$Potencia, mean))

##    160    180    200    220
## 551.2 587.4 625.4 707.0

mat.comp <- matrix(c(
  mean.trat[2]-mean.trat[1],
  mean.trat[3]-mean.trat[1],
  mean.trat[4]-mean.trat[1],
  0,
  mean.trat[3]-mean.trat[2],
  mean.trat[4]-mean.trat[2],
  0,
  0,
  mean.trat[4]-mean.trat[3]), 3, 3)
row.names(mat.comp) <- c(180,200,220)
colnames(mat.comp) <- c(160,180,200)
```

## Teste Tukey passo a passo (dados balanceados)

```
mat.comp
```

```
##          160    180    200  
## 180  36.2    0.0    0.0  
## 200  74.2   38.0    0.0  
## 220 155.8 119.6  81.6
```

## O teste de Tukey passo a passo (DMS)

```
a <- 4 # Número de tratamentos
k <- 5 # Número de repetições por tratamento (dados balanceados)
n <- length(dados$Etch.rate) # Número de unidades experimentais

alpha <- 0.05 # Nível de significância do teste

qtukey(1-alpha,a,n-a) # Amplitude studentizada

## [1] 4.046093

(QMRes <- sigma(mod.lm)^2)

## [1] 333.7

(DMS <- qtukey(1-alpha,4,n-4)*sqrt(QMRes/k))

## [1] 33.05438
```

## O teste de Tukey passo a passo

```
mat.comp
```

```
##          160    180    200
## 180  36.2    0.0    0.0
## 200  74.2   38.0    0.0
## 220 155.8 119.6  81.6
```

```
DMS
```

```
## [1] 33.05438
```

## Conclusão

```
abs(mat.comp) > DMS
```

```
##      160   180   200
## 180 TRUE FALSE FALSE
## 200 TRUE  TRUE FALSE
## 220 TRUE  TRUE  TRUE
```

- Conclui-se que existem diferenças entre os pares de médias de potência:

$(\mu_1, \mu_2)$     $(\mu_1, \mu_3)$     $(\mu_1, \mu_4)$   
 $(\mu_2, \mu_3)$     $(\mu_2, \mu_4)$     $(\mu_3, \mu_4)$

ao nível de significância  $\alpha = 5\%$ .

## Resumindo:

```
data.frame(medias=sort(mean.trat,decreasing=T),  
           Letras=c("a","b","c","d"))
```

```
##      medias Letras  
## 220  707.0      a  
## 200  625.4      b  
## 180  587.4      c  
## 160  551.2      d
```

Letras diferentes implicam em tratamentos diferentes.

- No R existem vários pacotes para realizar comparações múltiplas cada um com suas particularidades
  - agricolae
  - DescTools
  - multcomp
  - multcompView
  - ExpDes
  - ExpDes.pt
  - entre outros

# Teste de comparação de médias no R

## Teste de Tukey (Direto)

- sem necessidade de pacotes específicos

```
k <- 5 # Número de repetições
mod.Tukey <- aov(Etch.rate ~ Potencia-1, data=dados )
model.tables(mod.Tukey, type="means")

## Tables of means
##
## Potencia
## Potencia
## 160 180 200 220
## 551.2 587.4 625.4 707.0
mod.Tukey$df

## [1] 16
(q <- qtTukey(0.95, a, mod.Tukey$df))

## [1] 4.046093
(w <- qtTukey(0.95, a, mod.Tukey$df)*sigma(mod.Tukey)/sqrt(k))

## [1] 33.05438
```


## Teste de Tukey

```
TukeyHSD(mod.Tukey, "Potencia", ordered = TRUE)
```

```
## Tukey multiple comparisons of means
## 95% family-wise confidence level
## factor levels have been ordered
##
## Fit: aov(formula = Etch.rate ~ Potencia - 1, data = dados)
##
## $Potencia
##      diff      lwr      upr      p adj
## 180-160  36.2    3.145624  69.25438 0.0294279
## 200-160  74.2    41.145624 107.25438 0.0000455
## 220-160 155.8   122.745624 188.85438 0.0000000
## 200-180  38.0     4.945624   71.05438 0.0215995
## 220-180 119.6    86.545624 152.65438 0.0000001
## 220-200  81.6    48.545624 114.65438 0.0000146
```

# Graficamente,

```
plot(TukeyHSD(mod.Tukey, "Potencia"), col="blue")
```



# Teste de Tukey é muito simples no R

- Observe que é necessário utilizar a função `aov`

```
modelo <- aov(Etch.rate ~ Potencia ,data=dados )
tukey<-TukeyHSD(modelo)
#TukeyHSD() package=base R objeto ajuste aov
tukey


## Tukey multiple comparisons of means
## 95% family-wise confidence level
##
## Fit: aov(formula = Etch.rate ~ Potencia, data = dados)
##
## $Potencia
##      diff      lwr      upr    p adj
## 180-160  36.2   3.145624 69.25438 0.0294279
## 200-160  74.2  41.145624 107.25438 0.0000455
## 220-160 155.8 122.745624 188.85438 0.0000000
## 200-180  38.0   4.945624  71.05438 0.0215995
## 220-180 119.6  86.545624 152.65438 0.0000001
## 220-200  81.6  48.545624 114.65438 0.0000146
mat.comp

##      160  180  200
## 180 36.2  0.0  0.0
## 200 74.2 38.0  0.0
## 220 155.8 119.6 81.6
```

# Gráfico sem necessidade de pacotes especiais

```
plot(tukey, las=1, col="blue")
```

95% family-wise confidence level



## package=agricolae

- Observe as saídas

```
require(agricolae)
```

```
## Loading required package: agricolae
```

```
out <- HSD.test(modelo, "Potencia",console=F)
```

```
names(out)
```

```
## [1] "statistics" "parameters" "means" "comparison" "groups"
```

```
print(out$statistics)
```

```
##      MSerror Df      Mean          CV      MSD  
##      333.7 16 617.75 2.957095 33.05438
```

em que

- $MS_{\text{error}} = QM_{\text{Res}}$
- $Df = gl_{\text{res}}$
- $Mean =$  média geral (média da variável resposta)
- $CV =$  coeficiente de variação
- $MSD = DMS =$  diferença mínima significativa

## Coeficiente de variação

- O coeficiente de variação do modelo (CV) é definido por

$$CV = \frac{\sqrt{QMRes}}{\bar{y}} 100\%$$

No exemplo do plasma:

$$CV = \frac{s}{\bar{y}} = \frac{18,26746}{617,75} \approx 2,96\%$$

```
(CV=sigma(modelo)/mean(dados$Etch.rate))
```

```
## [1] 0.02957095
```

## Interpretação do coeficiente de variação

- O coeficiente de variação mede o quanto da variabilidade dos dados não foi explicada pelo modelo
- a variabilidade residual dos dados como uma porcentagem da média da variável resposta.

## R-squared ( $R^2$ )

$$R^2 = \frac{SQTrat}{SQT}$$

é a proporção da variabilidade dos dados “explicada” pelo tratamento.

Assim no exemplo do plasma etching o fator (tratamento=potência) explica em torno de 93% da variabilidade da variável resposta etch.rate.

- No exemplo do plasma:

$$R^2 = \frac{SQTrat}{SQRes} = \frac{66871}{66871 + 5339} \approx 0,93$$

## Quadro ANOVA para verificação dos valores

```
summary(modelo, intercept = T)
```

```
##              Df  Sum Sq Mean Sq F value    Pr(>F)
## (Intercept)   1 7632301 7632301 22871.7 < 2e-16 ***
## Potencia      3   66871   22290    66.8 2.88e-09 ***
## Residuals    16    5339     334
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

# Parâmetros

```
print(out$parameters)
```

```
##      test   name.t ntr StudentizedRange alpha  
##      Tukey Potencia   4           4.046093 0.05
```

- StudentizedRange = amplitude studentizada tabelada

```
a <- 4  
(n <- length(dados$Etch.rate))
```

```
## [1] 20
```

```
(q.tab <- qtukey(0.95,a,n-a))
```

```
## [1] 4.046093
```

```
glRes <- 16 # n-a
```

- $a = 4$  fatores=tratamento=potência
- $n = 20$  número de unidades amostrais
- $n - a = 16$  graus de liberdade do resíduo (glRes)

```
print(out$means)
```

```
##      Etch.rate      std r      se Min Max Q25 Q50 Q75
## 160      551.2 20.01749 5 8.169455 530 575 539 542 570
## 180      587.4 16.74216 5 8.169455 565 610 579 590 593
## 200      625.4 20.52559 5 8.169455 600 651 610 629 637
## 220      707.0 15.24795 5 8.169455 685 725 700 710 715
```

Tratamentos com mesma letra não diferem entre si

```
print(out$groups)
```

##	Etch.rate	groups
## 220	707.0	a
## 200	625.4	b
## 180	587.4	c
## 160	551.2	d

# Veja a diferença entre group=T e group=F

```
out <- HSD.test(modelo, "Potencia",group=F,console=F)
print(out$comparison)
```

##		difference	pvalue	signif.	LCL	UCL
##	160 - 180	-36.2	0.0294	*	-69.25438	-3.145624
##	160 - 200	-74.2	0.0000	***	-107.25438	-41.145624
##	160 - 220	-155.8	0.0000	***	-188.85438	-122.745624
##	180 - 200	-38.0	0.0216	*	-71.05438	-4.945624
##	180 - 220	-119.6	0.0000	***	-152.65438	-86.545624
##	200 - 220	-81.6	0.0000	***	-114.65438	-48.545624

```
out1 <- HSD.test(modelo, "Potencia",group=F,console=F)
print(out1$comparison)
```

##		difference	pvalue	signif.	LCL	UCL
##	160 - 180	-36.2	0.0294	*	-69.25438	-3.145624
##	160 - 200	-74.2	0.0000	***	-107.25438	-41.145624
##	160 - 220	-155.8	0.0000	***	-188.85438	-122.745624
##	180 - 200	-38.0	0.0216	*	-71.05438	-4.945624
##	180 - 220	-119.6	0.0000	***	-152.65438	-86.545624
##	200 - 220	-81.6	0.0000	***	-114.65438	-48.545624

## Comparação saída das funções

1. `out1$comparison`
2. `TukeyHSD`

# Saída out1\$comparison

```
out1$comparison
```

##		difference	pvalue	signif.	LCL	UCL
##	160 - 180	-36.2	0.0294	*	-69.25438	-3.145624
##	160 - 200	-74.2	0.0000	***	-107.25438	-41.145624
##	160 - 220	-155.8	0.0000	***	-188.85438	-122.745624
##	180 - 200	-38.0	0.0216	*	-71.05438	-4.945624
##	180 - 220	-119.6	0.0000	***	-152.65438	-86.545624
##	200 - 220	-81.6	0.0000	***	-114.65438	-48.545624

# Saída TukeyHSD

```
modelo <- aov(Etch.rate ~ Potencia ,data=dados )
TukeyHSD(modelo)


## Tukey multiple comparisons of means
## 95% family-wise confidence level
##
## Fit: aov(formula = Etch.rate ~ Potencia, data = dados)
##
## $Potencia
##          diff          lwr          upr          p adj
## 180-160  36.2    3.145624  69.25438  0.0294279
## 200-160  74.2   41.145624 107.25438  0.0000455
## 220-160 155.8 122.745624 188.85438  0.0000000
## 200-180  38.0    4.945624  71.05438  0.0215995
## 220-180 119.6   86.545624 152.65438  0.0000001
## 220-200  81.6   48.545624 114.65438  0.0000146
```

# Diferenças?

- Você observa diferenças entre utilizar
  - TukeyHSD
  - agricolae: HSD.test
  - Quais?
  - Por quê isso ocorre?

## Gráfico com package=base


```
plot(TukeyHSD(modelo), las=1, col="blue")
```




## Gráficos com package=Agricolae

```
out <- HSD.test(modelo, "Potencia",group=T,console=F)
oldpar<-par(mfrow=c(2,2),mar=c(3,3,2,1),cex=0.7)
c1<-colors()[480]; c2=colors()[65]
bar.err(out$means, variation="range",ylim=c(0,800),col=c1,las=1)
bar.err(out$means, variation="IQR",horiz=TRUE, xlim=c(0,800),col=c2,las=1)
plot(out, variation="range",las=1)
plot(out, horiz=TRUE, variation="SD",las=1)
par(oldpar)
```



# Gráficos com package=Agricolae





Groups and Range



Groups and Standard deviation




## Gráficos com package=Agricolae




# Gráficos com package=Agricolae

## Groups and Range



## Groups and Standard deviat



## Para ajudar a interpretar os gráficos

```
tapply(dados$Etch.rate, dados$Potencia, mean)
```

```
##    160    180    200    220
```

```
## 551.2 587.4 625.4 707.0
```

```
tapply(dados$Etch.rate, dados$Potencia, sd)
```

```
##      160      180      200      220
```

```
## 20.01749 16.74216 20.52559 15.24795
```

## Para ajudar a interpretar os gráficos

```
tapply(dados$Etch.rate, dados$Potencia, range)
```

```
## $`160`
```

```
## [1] 530 575
```

```
##
```

```
## $`180`
```

```
## [1] 565 610
```

```
##
```

```
## $`200`
```

```
## [1] 600 651
```

```
##
```

```
## $`220`
```

```
## [1] 685 725
```

# Obtenção dos intervalos de confiança

## Diferenças de média

```
coeff1 <- c(-1,1,0,0)
coeff2 <- c(-1,0,1,0)
coeff3 <- c(-1,0,0,1)
coeff4 <- c(0,-1,1,0)
coeff5 <- c(0,-1,0,1)
coeff6 <- c(0,0,-1,1)
```

```
dif21 <- sum(coeff1*mean.trat)
dif31 <- sum(coeff2*mean.trat)
dif41 <- sum(coeff3*mean.trat)
dif32 <- sum(coeff4*mean.trat)
dif42 <- sum(coeff5*mean.trat)
dif43 <- sum(coeff6*mean.trat)
```

```
(dif.media <- c(dif21,dif31,dif41,dif32,dif42,dif43))
```

```
## [1] 36.2 74.2 155.8 38.0 119.6 81.6
```

```
int.conf <- cbind(dif.media - DMS, dif.media+DMS)
```

```
resp <- data.frame(tukey.teste=
```

```
  round(tukey$Potencia[,2:3],2),
```

```
  int.conf=round(int.conf,2))
```

```
colnames(resp) <- c("tukey.inf", "tukey.sup", "inf", "sup")
```

```
resp
```

##	tukey.inf	tukey.sup	inf	sup
## 180-160	3.15	69.25	3.15	69.25
## 200-160	41.15	107.25	41.15	107.25
## 220-160	122.75	188.85	122.75	188.85
## 200-180	4.95	71.05	4.95	71.05
## 220-180	86.55	152.65	86.55	152.65
## 220-200	48.55	114.65	48.55	114.65

# Obtenção do valor p ajustado

```
valor.p.ajust <- ptukey(dif.media/sqrt(QMRes/k),a,glRes,  
                      nranges=1,lower.tail=F)
```

```
valor.p.ajust.r <- tukey$Potencia[,4]
```

```
data.frame(valor.p.ajust = round(valor.p.ajust,4) ,  
          valor.p.ajust.r = round(valor.p.ajust.r,4) )
```

```
##          valor.p.ajust valor.p.ajust.r  
## 180-160      0.0294      0.0294  
## 200-160      0.0000      0.0000  
## 220-160      0.0000      0.0000  
## 200-180      0.0216      0.0216  
## 220-180      0.0000      0.0000  
## 220-200      0.0000      0.0000
```

## Exercício

**3.27.** Four catalysts that may affect the concentration of one component in a three-component liquid mixture are being investigated. The following concentrations are obtained from a completely randomized experiment:

Catalyst			
1	2	3	4
58.2	56.3	50.1	52.9
57.2	54.5	54.2	49.9
58.4	57.0	55.4	50.0
55.8	55.3		51.7
54.9			

- Do the four catalysts have the same effect on the concentration?
- Analyze the residuals from this experiment.
- Construct a 99 percent confidence interval estimate of the mean response for catalyst 1.

- Considerando-se do exercício 3.27, pag. pdf. 135, do livro do Montgomery referente a catalisadores.
  1. Os catalisadores têm o mesmo efeito sobre a concentração?
  2. Se houver diferença de efeito aplique o Teste de Tukey para fazer comparação entre os pares de médias das concentrações.
  3. Quais suas conclusões?
- OBS: Para as comparações múltiplas interprete o valor-p, os intervalos de confiança, resuma os resultados graficamente e utilizando letras.

As hipóteses nula e alternativa podem ser expressas como:

$$H_0 : \Gamma_u = \sum_{i=1}^a c_i \mu_i = 0, u = 1, \dots, m$$

$$H_1 : \Gamma_u \neq 0, u = 1, \dots, m$$

Para calcular os contrastes, podemos usar uma combinação linear das médias amostrais:

$$C = c_1 \bar{Y}_1 + c_2 \bar{Y}_2 + \dots + c_a \bar{Y}_a$$

Onde  $\bar{Y}_i$  é a média da amostra  $i$  e  $c_1, c_2, \dots, c_a$  são coeficientes que somam zero.

### **Cálculo da estatística de teste de Scheffé:**

A estatística de teste F de Scheffé é calculada como:

$$F = \frac{C^2}{MSE}$$

Onde  $C^2$  é a soma dos quadrados dos contrastes e MSE é a média dos quadrados dos erros.

### Decisão

O valor crítico é selecionado a partir da distribuição F com  $df_1 = k - 1$  e  $df_2 = df_{\text{error}}$ , onde  $k$  é o número de grupos e  $df_{\text{error}}$  são os graus de liberdade do erro.

Se  $F$  for maior que o valor crítico, rejeitamos  $H_0$ , indicando diferenças significativas entre as médias dos grupos.

## **Comparações múltiplas**

Se a hipótese nula for rejeitada, o teste de Scheffé pode ser usado para realizar comparações múltiplas entre as médias dos grupos, controlando o erro tipo I.

## **Interpretação dos resultados:**

As diferenças significativas entre os grupos podem ser identificadas e interpretadas com base nos intervalos de confiança para as diferenças entre médias ajustados pelo teste de Scheffé.

- <https://eaulas.usp.br/portal/video.action?idItem=17687>
- <https://eaulas.usp.br/portal/video?idItem=30424>
- [https://www.uel.br/projetos/experimental/pages/arquivos/Dic\\_patol.html](https://www.uel.br/projetos/experimental/pages/arquivos/Dic_patol.html)
- <https://www.statology.org/scheffe-test-in-r/>

- Comparações múltiplas com um controle
- Vídeo recomendado:  
<https://eaulas.usp.br/portal/video?idItem=18543> Prof. César Gonçalves de Lima (FZEA/USP).
- Dunnett C. W. (1955) A multiple comparison procedure for comparing several treatments with a control, *Journal of the American Statistical Association*, 50:1096-1121.

```
library(DescTools)
```

```
## Hollander & Wolfe (1973), 116.
```

```
## Mucociliary efficiency from the rate of removal of dust in no
```

```
## subjects, subjects with obstructive airway disease, and subj
```

```
## with asbestosis.
```

```
x <- c(2.9, 3.0, 2.5, 2.6, 3.2) # normal subjects
```

```
y <- c(3.8, 2.7, 4.0, 2.4)      # with obstructive airway diseas
```

```
z <- c(2.8, 3.4, 3.7, 2.2, 2.0) # with asbestosis
```

## Controle x

```
DunnettTest(list(x, y, z))
```

```
##
```

```
## Dunnett's test for comparing several treatments with a cont
```

```
## 95% family-wise confidence level
```

```
##
```

```
## $`1`
```

```
##      diff      lwr.ci      upr.ci      pval
```

```
## 2-1  0.385 -0.6901497 1.4601497 0.5832
```

```
## 3-1 -0.020 -1.0336608 0.9936608 0.9982
```

```
##
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Controle y

```
DunnettTest(list(y,x, z))
```

```
##
```

```
## Dunnett's test for comparing several treatments with a cont
```

```
## 95% family-wise confidence level
```

```
##
```

```
## $`1`
```

```
##      diff      lwr.ci      upr.ci      pval
```

```
## 2-1 -0.385 -1.453557 0.6835572 0.5717
```

```
## 3-1 -0.405 -1.473557 0.6635572 0.5421
```

```
##
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Controle z

```
DunnettTest(list(z,x,y))
```

```
##
```

```
## Dunnett's test for comparing several treatments with a cont
```

```
## 95% family-wise confidence level
```

```
##
```

```
## $`1`
```

```
##      diff      lwr.ci   upr.ci   pval
```

```
## 2-1 0.020 -0.9936608 1.033661 0.9982
```

```
## 3-1 0.405 -0.6701497 1.480150 0.5535
```

```
##
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## De forma equivalente,

```
x <- c(x, y, z)
```

```
g <- factor(rep(1:3, c(5, 4, 5)),  
            labels = c("Normal subjects",  
                        "Subjects with obstructive airway disease",  
                        "Subjects with asbestosis"))
```

```
DunnettTest(x, g)
```

```
##
## Dunnett's test for comparing several treatments with a control :
## 95% family-wise confidence level
##
## $`Normal subjects`
##
## diff      lwr.ci
## Subjects with obstructive airway disease-Normal subjects 0.385 -0.6901497
## Subjects with asbestosis-Normal subjects -0.020 -1.0336608
##
## upr.ci  pval
## Subjects with obstructive airway disease-Normal subjects 1.4601497 0.5832
## Subjects with asbestosis-Normal subjects 0.9936608 0.9982
##
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

## Equivalentemente,

```
## Formula interface
```

```
layout(1)
```

```
str(airquality)
```

```
## 'data.frame': 153 obs. of 6 variables:
```

```
## $ Ozone : int 41 36 12 18 NA 28 23 19 8 NA ...
```

```
## $ Solar.R: int 190 118 149 313 NA NA 299 99 19 194 ...
```


```
## $ Wind : num 7.4 8 12.6 11.5 14.3 14.9 8.6 13.8 20.1 ...
```

```
## $ Temp : int 67 72 74 62 56 66 65 59 61 69 ...
```

```
## $ Month : int 5 5 5 5 5 5 5 5 5 5 ...
```

```
## $ Day : int 1 2 3 4 5 6 7 8 9 10 ...
```

```
boxplot(Ozone ~ Month, data = airquality)
```



```
DunnettTest(Ozone ~ Month, data = airquality)
```

```
##
```

```
## Dunnett's test for comparing several treatments with a cont
```

```
## 95% family-wise confidence level
```

```
##
```

```
## $`5`
```

```
##          diff      lwr.ci   upr.ci    pval
```

```
## 6-5  5.829060 -22.43792  34.09604  0.96467
```

```
## 7-5 35.500000  15.22870  55.77130  0.00011 ***
```

```
## 8-5 36.346154  16.07486  56.61745  8.7e-05 ***
```

```
## 9-5  7.832891 -11.90719  27.57297  0.73509
```

```
##
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```

DunnettTest(Ozone ~ Month, data = airquality, control="8", conf.

##
##   Dunnett's test for comparing several treatments with a cont
##     90% family-wise confidence level
##
## $`8`
##           diff      lwr.ci      upr.ci      pval
## 5-8 -36.3461538 -54.26925 -18.423062 6.4e-05 ***
## 6-8 -30.5170940 -55.50965  -5.524537 0.0300 *
## 7-8  -0.8461538 -18.76925  17.076938 0.9999
## 9-8 -28.5132626 -45.96667 -11.059853 0.0019 **
##
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' '

```

- Dunnett, C. W. (1955). A multiple comparisons procedure for comparing several treatments with a control. *Journal of the American Statistical Association*. 50 (272): 1096–1121. doi:10.1080/01621459.1955.10501294
- Dunnett, C. W. (1964). New tables for multiple comparisons with a control. *Biometrics*. 20 (3): 482–491. JSTOR 2528490. doi:10.2307/2528490

- <https://soniavieira.blogspot.com/2016/09/teste-de-amplitudes-multiplas-de-duncan.html>

- Entrada de dados

```
y <- c(25,17,27,21,15,  
      10,-2,12, 4,16,  
      18, 8, 4,14, 6,  
      23,29,25,35,33,  
      11,23, 5,17, 9,  
      8,-6, 6, 0, 2)
```

```
trat <- as.factor(rep(1:6,each=5))
```

```
(dados <- data.frame(y=y, trat=trat))
```

## Normalidade

```
mod <- aov(y ~ trat, data=dados )  
shapiro.test(rstudent(mod))
```

```
##
```

```
## Shapiro-Wilk normality test
```

```
##
```

```
## data:  rstudent(mod)
```

```
## W = 0.96257, p-value = 0.3598
```

### Homogeneidade de variâncias

```
bartlett.test(y ~ trat, data=dados )
```

```
##
```

```
## Bartlett test of homogeneity of variances
```

```
##
```

```
## data:  y by trat
```

```
## Bartlett's K-squared = 0.85057, df = 5, p-value = 0.9737
```

## Interpretação Quadro ANOVA

`anova(mod)`

```
## Analysis of Variance Table
```

```
##
```

```
## Response: y
```

```
##           Df Sum Sq Mean Sq F value    Pr(>F)
```

```
## trat         5 2354.2   470.83  13.079 3.318e-06 ***
```

```
## Residuals  24   864.0    36.00
```

```
## ---
```

```
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1
```

- Como o valor de F é significativo ao nível de 5%, existe pelo menos uma média diferente das demais.

# Pairwise t.test

```
attach(airquality)
Month <- factor(Month, labels = month.abb[5:9])
pairwise.t.test(Ozone, Month)

##
## Pairwise comparisons using t tests with pooled SD
##
## data: Ozone and Month
##
##      May      Jun      Jul      Aug
## Jun 1.00000 -          -          -
## Jul 0.00026 0.05113 -          -
## Aug 0.00019 0.04987 1.00000 -
## Sep 1.00000 1.00000 0.00488 0.00388
##
## P value adjustment method: holm
```

# Pairwise t.test

```
pairwise.t.test(Ozone, Month, p.adjust.method = "bonf")
```

```
##  
## Pairwise comparisons using t tests with pooled SD  
##  
## data: Ozone and Month  
##  
##      May      Jun      Jul      Aug  
## Jun 1.00000 -        -        -  
## Jul 0.00029 0.10225 -        -  
## Aug 0.00019 0.08312 1.00000 -  
## Sep 1.00000 1.00000 0.00697 0.00485  
##  
## P value adjustment method: bonferroni  
pairwise.t.test(Ozone, Month, pool.sd = FALSE)
```

```
##  
## Pairwise comparisons using t tests with non-pooled SD  
##  
## data: Ozone and Month  
##  
##      May      Jun      Jul      Aug  
## Jun 1.00000 -        -        -  
## Jul 0.00026 0.01527 -        -  
## Aug 0.00195 0.02135 1.00000 -  
## Sep 0.86321 1.00000 0.00589 0.01721  
##  
## P value adjustment method: holm  
detach()
```

## Biblioteca ExpDes

### Obtendo os resultados com o pacote ExpDes

```
require(ExpDes)
```

```
require(doBy)
```

```
with(dados , crd(treat=trat, resp=y, mcomp="tukey")) # Tukey
with(dados , crd(treat=trat, resp=y, mcomp="duncan")) # Duncan
with(dados , crd(treat=trat, resp=y, mcomp="snk")) # Student-Newman-Keuls
with(dados , crd(treat=trat, resp=y, mcomp="lsd")) # t-Student (LSD)
with(dados , crd(treat=trat, resp=y, mcomp="lsdb")) # t-Student / Bonferroni
with(dados , crd(treat=trat, resp=y, mcomp="sk")) # Scott-Knott - sob balanceam
```

## **Biblioteca DescTools**

<https://www.statology.org/scheffe-test-in-r/>

## **Biblioteca Agricola**

- [https://www.uel.br/projetos/experimental/pages/arquivos/Dic\\_patol.html](https://www.uel.br/projetos/experimental/pages/arquivos/Dic_patol.html)

## Um teste único

Situação	Decisão	
	Rejeito $H_0$	Não rejeito $H_0$
$H_0$ é V	Erro Tipo I	Ok
$H_0$ é F	Ok	Erro Tipo II

- $\alpha$  é a probabilidade de cometer o erro tipo I

$$Prob[\text{Rejeitar } H_0 | H_0 \text{ é verdadeira}]$$

## Tabela (Múltiplos testes)

Situação	Decisão		Total
	Rejeito $H_0$	Não rejeito $H_0$	
$H_0$ é V	V	U	$m_0$
$H_0$ é F	S	T	$m - m_0$
	R	m-R	m

- Rejeito  $H_0$  se o teste for declarado significativo,
- Não rejeito  $H_0$  se o teste for declarado não significativo.
- $\alpha = Prob[\text{Rejeitar } H_0 | H_0 \text{ é verdadeira}]$
- $1 - \alpha = Prob[\text{Não Rejeitar } H_0 | H_0 \text{ é verdadeira}]$

- A probabilidade global (Familywise Error),  $FWER$ , é a probabilidade de cometer pelo menos um erro do Tipo I na família de testes, ou seja,

$$FWER = P[V \geq 1] = 1 - P[V = 0] \leq 1 - (1 - \alpha)^m$$

Visto que,  $P[A|B] + P[A^C|B] = 1$  e os testes não são independentes.

## Múltiplos testes

### Classificação de testes de hipóteses múltiplas

- Testando várias hipóteses nulas: Suponha que temos um número  $m$  de hipóteses nulas, denotado por:  $H_1, H_2, \dots, H_m$ .
- Usando um teste estatístico, rejeitamos a hipótese nula se o teste for declarado significativo.
- Não rejeitamos a hipótese nula se o teste não for significativo.
- A soma de cada tipo de resultado sobre todas as  $H_i$  produz as seguintes variáveis aleatórias:

- $m$  é o número total de hipóteses testadas (conhecido)
- $m_0$  é o número de hipóteses nulas verdadeiras, um parâmetro desconhecido
- $m - m_0$  é o número de hipóteses alternativas verdadeiras, um parâmetro desconhecido
- $V$  é o número de falsos positivos (Erro Tipo I) (também chamado de “falsas descobertas”)
- $S$  é o número de verdadeiros positivos (também chamados de “descobertas verdadeiras”)
- $T$  é o número de falsos negativos (Erro Tipo II)
- $U$  é o número de verdadeiros negativos
- $R = V + S$  é o número de hipóteses nulas rejeitadas (também chamadas de “descobertas”, verdadeiras ou falsas)

Em  $m$  testes de hipóteses dos quais  $m_0$  são hipóteses nulas verdadeiras,  $R$  é uma variável aleatória observável e  $S$ ,  $T$ ,  $U$  e  $V$  são variáveis aleatórias não observáveis.

- [https://en.wikipedia.org/wiki/Multiple\\_comparisons\\_problem](https://en.wikipedia.org/wiki/Multiple_comparisons_problem)

## Familywise error rate (Taxa de erro familiar)

Portanto, precisamos de uma abordagem diferente, que comece por definir exatamente o que queremos controlar. Este não é um problema novo e, durante décadas, os estatísticos usaram a Familywise error rate (FWER), que garante que a probabilidade de cometer uma única rejeição falsa é limitada por  $\alpha$ .

- Alguns testes que controlam FWER
  - Teste de Tukey
  - Teste de Scheffé
  - Teste de Duncan
  - Teste de Dunnett
  - Correção de Bonferroni

$$\begin{cases} H_0 : \mu_i - \mu_j = 0 \\ H_1 : \mu_i - \mu_j \neq 0, \text{ para } i < j \end{cases}$$

## Teste Tukey (p.adj???)

- controla a taxa de erro individual?
- ou a taxa de erro experimental (ou de família)?

### **O teste Tukey controla a taxa de erro experimental ou familiar**

- O Teste de Tukey controla o erro da família, ou family-wise error (FWE) considerando-se o valor  $p$  ajustado ( $p$  adj).
- O valor  $p$  adj deve ser comparado com o valor  $\alpha$ , em geral,  $\alpha = 0,05$ .

- com testes de hipóteses: quanto mais testes simultâneos você executar, maior será a probabilidade de obter um resultado “significativo”. Digamos que você esteja executando testes de 50 simultaneamente com um nível alpha de 0,05. A probabilidade de observar pelo menos um evento significativo devido apenas ao acaso é:

$$P(\text{significant event}) = 1 - P(\text{no significant event}) \leq 1 - (1 - 0.05)^{50} = 0.92.$$

É quase certo (92%) que há pelo menos um resultado significativo.

- A correção de múltiplos testes refere-se a tornar os testes estatísticos mais rigorosos, a fim de neutralizar o problema dos testes múltiplos. O ajuste mais conhecido é a correção de Bonferroni, mas outros métodos foram desenvolvidos. Esses métodos são normalmente projetados para controlar a taxa de erro familiar ou a taxa de falsas descobertas.
- Brillinger, D. "The Collected Works of John W. Tukey". 1984.


## Como calcular a correção de Bonferroni

- O cálculo para este teste post-hoc é na verdade muito simples, é apenas o nível alfa ( $\alpha$ ) dividido pelo número de testes que você está executando.
- Exemplo de pergunta: Um pesquisador está testando 25 hipóteses diferentes ao mesmo tempo, usando um valor crítico de 0,05. Qual é a correção de Bonferroni?

Responder: A correção de Bonferroni é  $\frac{\alpha}{n} = \frac{0,05}{25} = 0,002$

Para este conjunto de testes de 25, você rejeitaria o nulo apenas se seu valor p fosse menor que 0,002.

Probability of At Least 1 False Positive



- <https://stat.ethz.ch/R-manual/R-devel/library/stats/html/p.adjust.html>

?p.adjust.methods

- <https://multithreaded.stitchfix.com/blog/2015/10/15/multiple-hypothesis-testing/>

- <https://home.uchicago.edu/~amshaikh/webfiles/palgrave.pdf>


## **Correção de Bonferroni**

- [https://pt.wikipedia.org/wiki/Corre%C3%A7%C3%A3o\\_de\\_Bonferroni](https://pt.wikipedia.org/wiki/Corre%C3%A7%C3%A3o_de_Bonferroni)

## **Qual teste utilizar?**

- <https://www.statology.org/tukey-vs-bonferroni-vs-scheffe/>

## Testes que controlam o False discovery rate



- [https://www.wikiwand.com/pt/Testes\\_de\\_hip%C3%B3teses](https://www.wikiwand.com/pt/Testes_de_hip%C3%B3teses)
- [https://en0.wikipedia.org/wiki/Multiple\\_comparisons\\_problem#Classification\\_of\\_multiple\\_hypothesis\\_tests](https://en0.wikipedia.org/wiki/Multiple_comparisons_problem#Classification_of_multiple_hypothesis_tests)

## Correção de Bonferroni

- <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6099145/> Leia!
- [https://www.wikiwand.com/pt/Corre%C3%A7%C3%A3o\\_de\\_Bonferroni](https://www.wikiwand.com/pt/Corre%C3%A7%C3%A3o_de_Bonferroni)
- <https://www.graphpad.com/support/faq/adjusted-p-values-as-part-of-multiple-comparisons/>
- Shaffer, J. P. (1995). Multiple Hypothesis Testing. *Annual Review of Psychology*. 46: 561–584. doi:10.1146/annurev.ps.46.020195.003021
- Strassburger, K.; Bretz, Frank (2008). Compatible simultaneous lower confidence bounds for the Holm procedure and other Bonferroni-based closed tests. *Statistics in Medicine*. 27 (24): 4914–4927. PMID 18618415. doi:10.1002/sim.3338
- Sidák, Z. (1967). Rectangular confidence regions for the means of multivariate normal distributions. *Journal of the American Statistical Association*. 62 (318): 626–633. doi:10.1080/01621459.1967.10482935

```
require(multcomp)
```

```
?glht
```

## Teste de Dunnet

- <https://pt.stackoverflow.com/questions/309395/como-fazer-o-teste-de-dunnett-no-r>

## Teste de Duncan

- <https://search.r-project.org/CRAN/refmans/agricolae/html/duncan.test.html>