

CAPÍTULO 2

Análise descritiva e testes de pressuposições para análise de variância

Tatiane Caroline Grella, José Bruno Malaquias, Jéssica Karina da Silva Pachú

<https://doi.org/10.4322/mp.2020-12.c2>

Resumen

Neste capítulo, descrevemos de forma simples e objetiva elementos essenciais para análise descritiva no R por meio de boxplot e também exploramos algumas linhas de comando que são essenciais para testes de normalidade e homogeneidade de variâncias, para posterior análise de variância e testes de comparação de duas médias, no caso teste t, e comparação múltipla de médias – teste de Tukey. Todas as linhas de comando são apresentadas com um passo a passo de forma comentada e detalhada. Utilizaremos os seguintes pacotes: **readxl** e **ExpDes.pt**. Os comandos a serem executados no R estão sendo apresentados com a cor azul.

Palabras clave: boxplot; normalidade; homocedasticidade; variáveis contínuas; testes de comparação; ANOVA.

1. Leitura de arquivos no R

Para acessar o banco de dados e o script utilizados como exemplo neste capítulo [clique aqui](#).

Para iniciar a análise é necessário fazer o download do banco de dados e script (disponibilizados a cima) e em seguida verificar em qual local do computador (diretório) o arquivo que será analisado se encontra.

Para isso, vamos usar o comando **getwd**, que irá verificar em qual diretório você está trabalhando: **getwd()**

Caso seja necessário alterar o diretório, basta seguir os passos:

Session -> Set working Directory -> Choose Directory

Após escolher um diretório é possível ver quais os arquivos existem no mesmo, para isso, usamos a função: **list.files()** que mostrará a lista de arquivos dentro do seu diretório.

Após a escolha do diretório, vamos ler o arquivo que será analisado.

Para ler o arquivo em excel, nós iremos precisar do pacote: **readxl** [1].

Uma forma elegante de carregar o pacote é utilizar a seguinte linha de comando (essa linha também funciona caso o pacote não esteja instalado, pois automaticamente a instalação será realizada):

```
if(!require("readxl")) install.packages("readxl"); require(readxl)
```

O sinal de exclamação indica negação, então a linha de comando acima é traduzida como: “*caso o pacote necessário (readxl) não esteja instalado, instale o pacote, e em seguida carregue-o*”.

2. Análise descritiva com box plot

Depois de carregar o pacote, precisamos ler o arquivo, para isso usaremos a linha de comando:

```
df<-read_excel("BD1.xls ", sheet = 1)
```

- df é o nome dado ao dataframe (você pode colocar o nome que desejar);
- read_excel é o comando para ler o arquivo do Excel
- **BD1** é o nome do seu arquivo dentro da pasta selecionada
- xls é a extensão do arquivo com o qual você está trabalhando
- sheet = 1 faz referência a qual aba do seu arquivo do Excel quer analisar

Vamos ler o Arquivo: **BD1.xls**.

Nesse exemplo didático foi analisado o efeito de dois tratamentos no peso dos insetos (Tabela 1). O delineamento experimental foi inteiramente casualizado e com apenas 3 repetições.

Tabela 1 – Peso (g) de uma espécie hipotética de inseto submetida a dois tratamentos

TRATAMENTO	REPETIÇÃO	PESO
A	1	0,0750
A	2	0,0810
A	3	0,0820
B	1	0,0780
B	2	0,0790
B	3	0,0800

Para ver o cabeçalho usamos a função: **head(df)**

Para ver o banco de dados, usamos a função: **View(df)**

Para expressar os dados em um boxplot e construí-lo, usamos a função:

```
boxplot(PESO~TRATAMENTO, data=df)
```

Após a construção é possível alterar diversos itens, como:

- nome nos eixos, usando o comando:

```
boxplot(PESO~TRATAMENTO, data=df,
        xlab = "Tratamentos",
        ylab = "Matéria seca (kg)")
```

Neste exemplo os nomes do eixos são "Tratamentos" "Matéria seca (kg)"

- nome nos eixos e com limite inferior e superior.

```
boxplot(PESO~TRATAMENTO, data=df,
        xlab = "Tratamentos",
        ylab = "Matéria seca (kg)"
        , ylim = c(0.07,0.085))
```

- nome nos eixos e com limite inferior e superior e adicionando a média dentro do Boxplot.

```
boxplot(PESO~TRATAMENTO, data=df, col= "white",
        xlab= "Variedades", ylab= "Matéria Seca (Kg)", ylim = c(0.07,0.085))
points(1:nlevels(TRATAMENTO), tapply(PESO, TRATAMENTO, mean), data=df)
abline(mean(TRATAMENTO), data=df)
```

Para exportar a figura no formato desejado (uma sugestão é o formato tiff com 300 dpi, que geralmente é o formato solicitado pelos periódicos).

Para alterar os tamanhos, utilize: `cex.main` (título), `cex.lab` (rótulos) e `cex.axis` (tamanho dos eixos).

```
tiff("Figura_BoxPlot_.tiff", width=12, height=8, units="in", res=300)
boxplot(PESO~TRATAMENTO, data=df, col= "white",
        xlab= "Variedades", ylab= "Matéria Seca (Kg)",
        ylim = c(0.07,0.085),
        cex.main=1.5, cex.lab=1.5, cex.axis=1.5)
dev.off()
```

OBS: observe o seu diretório, pois a figura será diretamente exportada para essa pasta.

Para escolher o diretório utilize **Control + Shift + H** ou simplesmente use `getwd()`

A Figura 1 é o boxplot exportado. Cada seta expressa um parâmetro da análise descritiva, ou seja, os valores mínimo, máximo e quantis (1º, 2º e 3º).

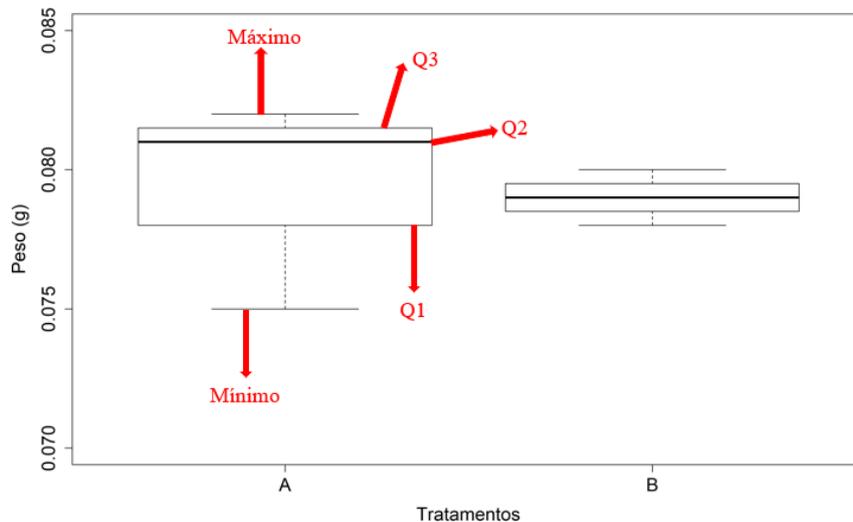


Figura 1 – Boxplot representando o efeito de dois tratamentos no peso (g) de uma espécie hipotética de inseto. **Q1**: primeiro quantil. **Q2**: segundo quantil ou mediana. **Q3**: terceiro quantil.

Com a utilização da linha de comando abaixo, será possível visualizar os mesmos valores expressos no boxplot, ou seja, valor mínimo (Min), primeiro quantil (1st Qu.), mediana (Median), média (Mean), terceiro quantil (3rd Qu.) e máximo (Max), portanto, será demonstrado um resumo da análise descritiva do peso (g) de uma espécie hipotética de inseto submetida a cada um dos dois tratamentos.

`tapply(df$PESO, df$TRATAMENTO, summary)`

\$A

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.07500	0.07800	0.08100	0.07933	0.08150	0.08200

\$B

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
0.0780	0.0785	0.0790	0.0790	0.0795	0.0800

3. Testando as pressuposições do modelo da ANOVA

Vamos utilizar o mesmo banco de dados que foi utilizado anteriormente, então leia o arquivo: **BD1.xls** (Tabela 1) utilizando o script que está disponível ao [clique aqui](#). Conforme exposto na Tabela 1 e comentado anteriormente, nesse exemplo didático foi analisado o efeito de dois tratamentos no peso dos insetos. O delineamento experimental foi inteiramente casualizado e com apenas 3 repetições.

Carregue o pacote **readxl**, para ler o arquivo do Excel:

require(readxl) caso tenha dúvidas em relação ao carregamento do pacote e instalação, veja o tópico “Leitura de arquivos no R”.

Leia o banco de dados: `df<- read_excel("BD1.xlsx", sheet = 1)`

Ver o cabeçalho: `head(df)`

Ver o banco de dados: `View(df)`

Antes de realizar a análise **ANOVA**, é necessário testar a normalidade e a homogeneidade das variâncias.

Para testar a normalidade, utilizamos o teste de Shapiro Wilk, usando:

`shapiro.test(df$PESO)`

Teste de Shapiro: Se o *p-value* for superior a 0,05 (5%), há normalidade dos dados.

Para testar a homogeneidade, em um estudo conduzido em DIC – com apenas um fator, utilizamos o teste de Bartlett, usando:

`bartlett.test(df$PESO, df$TRATAMENTO)`

Teste de Bartlett: Se o *p-value* for superior a 0.05, as variâncias são homogêneas.

OBS: caso seus dados sejam variáveis contínuas e não atendam à normalidade e/ou homogeneidade serão necessárias transformações.

4. Teste T

Vamos continuar utilizando o mesmo banco de dados que foi utilizado anteriormente, mas com alteração do script que podem ser acessados [clique aqui](#), então leia o Arquivo: **BD1.xls** (Tabela 1). Como são apenas dois tratamentos, iremos aplicar um teste t. Mas antes disso, precisaremos testar as pressuposições de normalidade e homogeneidade de variâncias, para maiores detalhes veja o tópico: “Testando as Pressuposições do Modelo da Anova”.

Carregue o pacote **readxl**, para ler o arquivo do Excel:

require(readxl) caso tenha dúvidas em relação ao carregamento do pacote e instalação, veja o tópico “Leitura de arquivos no R”.

Leia o banco de dados: **df<- read_excel("BD1.xlsx", sheet = 1)**

Ver o cabeçalho: **head(df)**

Ver o banco de dados: **View(df)**

Teste de Shapiro Wilk: **shapiro.test(df\$PESO)**

Teste de Bartlett para um estudo conduzido em DIC – – com apenas um fator: **bartlett.test(df\$PESO, df\$TRATAMENTO)**

Para aplicar o teste t, utilize a função **t.test**.

- Peso é a variável resposta;
- Tratamento é a variável independente.

Pode-se utilizar as opções: "**two.sided**", "**less**" ou "**greater**".

t.test(PESO ~ TRATAMENTO, data = df, alternative = "two.sided")

5. Teste de Tukey

Vamos utilizar o banco de dados presente no Arquivo: **Anova1.0.xlsx** (Tabela 2). O delineamento experimental foi inteiramente casualizado e com 4 repetições. Como são mais de dois tratamentos, iremos aplicar um teste de comparações múltiplas, nesse caso o teste de Tukey. Lembre-se, de testar as pressuposições de normalidade e homogeneidade de variâncias, para maiores detalhes veja o tópico: Testando as Pressuposições do Modelo da Anova.

Tabela 2 – Diâmetro (mm) do *prnotum* de uma espécie hipotética de inseto submetida a três tratamentos

TRATAMENTO	REPETIÇÃO	DIÂMETRO
X	1	30
X	2	40
X	3	20
X	4	67
Y	1	20
Y	2	20
Y	3	35
Y	4	45
Z	1	60
Z	2	40
Z	3	50
Z	4	30

Carregue o pacote **readxl**, para ler o arquivo do Excel:

require(readxl) caso tenha dúvidas em relação ao carregamento do pacote e instalação, veja o tópico “Leitura de arquivos no R”.

Leia o banco de dados: `df<- read_excel("BD1.xlsx", sheet = 1)`

Ver o cabeçalho: `head(df)`

Ver o banco de dados: `View(df)`

Teste de Shapiro Wilk: `shapiro.test(df$Diámetro)`

Teste de Bartlett para um estudo conduzido em DIC – com apenas um fator: `bartlett.test(df$Diámetro, df$Tratamento)`

Para essa análise vamos utilizar o pacote ExpDes.pt [2]: `require(ExpDes.pt)`

Para enviar os comandos digitados (data frame) para memória: `attach(df)`

O ensaio foi conduzido no delineamento “dic”, por isso vamos utilizar a função `dic`

#em `mcomp`, escolha o método: `"tukey"`

`dic(Tratamento, Diámetro, quali = TRUE, mcomp = "tukey", nl=FALSE, sigT = 0.05, sigF = 0.05)`

Esse é o resultado da análise:

De acordo com o teste F, as medias nao podem ser consideradas diferentes.

```
-----  
  Niveis Medias  
1      x  39.25  
2      y  30.00  
3      z  45.00  
-----
```

A partir da análise, percebe-se que não existem evidências de diferenças entre os tratamentos. Caso queira apresentar os resultados usando letras, basta atribuir a mesma letra para as 3 médias – embora isto seja considerado redundante.

6. Referências dos pacotes utilizados

[1] WICKHAM H., BRYAN J. readxl: Read Excel Files. R package version 1.3.1. 2019. <https://CRAN.R-project.org/package=readxl>

[2] FERREIRA E.B., CAVALCANTI P.P., NOGUEIRA D.A. ExpDes.pt: Pacote Experimental Designs (Portuguese). R package version 1.2.0. 2018. <https://CRAN.R-project.org/package=ExpDes.pt>

7. Referências recomendadas

CRAWLEY, Michael J. The R book. John Wiley & Sons, 2012.

MATLOFF, Norman. The art of R programming: A tour of statistical software design. No Starch Press, 2011.

PETERNELLI, Luiz Alexandre; MELLO, MP de. Conhecendo o R: uma visão estatística. Viçosa: UFV, v. 1, 2011.

VENABLES W.N., RIPLEY B. D. Modern Applied Statistics with S. Fourth Edition. Springer, New York. 2002.

Autores

Tatiane Caroline Grella* - Biologia Celular e Molecular na Universidade Estadual Paulista "Júlio de Mesquita Filho" – Laboratório de Ecotoxicologia e Conservação de Abelhas (LECA) - Avenida 24 A,1515 - Bela Vista - CEP 13506-900 – Rio Claro/SP, Brasil

José Bruno Malaquias, Instituto de Biociências - Câmpus de Botucatu. R. Prof. Dr. Antônio Celso Wagner Zanin, 250 - Distrito de Rubião Junior - Botucatu/SP, Brasil - CEP 18618-689

Jéssica Karina da Silva Pachú, Departamento de Entomologia e Acarologia - LEA Avenida Pádua Dias, 11 - CEP 13418-900 - Piracicaba/SP, Brasil

* Autor para correspondência: tati_cg04@hotmail.com