

Lição 10: Teste-t

Na Lição 9, vimos testes estatísticos univariados para variáveis nominais. Nesta lição, veremos um teste que se aplica a variáveis numéricas: o teste-t.

Antes de mais nada, carregue o pacote tidyverse.

```
library(tidyverse)
```

Vamos trabalhar com os dados das vogais pretônicas. Rode as linhas de comando para deixá-lo disponível, definindo como diretório de trabalho a pasta que contém o arquivo Pretonicas.csv.

```
# Definir diretório de trabalho

#setwd()

pretonicas <- read_csv("Pretonicas.csv",
  col_types = cols(
    AMOSTRA = col_factor(levels = c("PBSP", "SP2010")),
    VOGAL = col_factor(levels = c("i", "e", "a", "o", "u"
  )))
)
```

Cheque a estrutura desse dataframe.

```
str(pretonicas)

## spec_tbl_df [2,415 × 27] (S3: spec_tbl_df/tbl_df/tbl/data.frame)
## $ PALAVRA      : chr [1:2415] "fazer" "quatorze" "casou" "casado"
## ...
## $ Transc.Fon  : chr [1:2415] "f<a>- 'zer" "k<a>- 'tor-ze" "k<a>- 'zo
w" "k<a>- 'za-do" ...
## $ VOGAL       : Factor w/ 5 levels "i","e","a","o",...: 3 3 3 3 3
3 4 3 3 3 ...
## $ F1          : num [1:2415] 487 686 731 621 845 ...
## $ F2          : num [1:2415] 1666 1414 1168 1275 1574 ...
## $ F1.NORM     : num [1:2415] 397 476 494 450 540 ...
## $ F2.NORM     : num [1:2415] 1517 1386 1258 1314 1469 ...
## $ CONT.PREC   : chr [1:2415] "f" "k" "k" "k" ...
## $ CONT.SEG    : chr [1:2415] "z" "t" "z" "z" ...
## $ VOGAL.SIL.SEG: chr [1:2415] "e" "o" "ow" "a" ...
## $ F1.SIL.SEG  : num [1:2415] 498 462 529 842 509 ...
## $ F2.SIL.SEG  : num [1:2415] 2001 1126 1009 1239 2351 ...
## $ F1.SEG.NORM : num [1:2415] 328 317 338 433 331 ...
## $ F2.SEG.NORM : num [1:2415] 1518 1095 1038 1149 1687 ...
## $ VOGAL.TONICA : chr [1:2415] "e" "o" "ow" "a" ...
## $ DIST.TONICA : num [1:2415] 1 1 1 1 1 1 1 1 1 1 ...
```

```

## $ ESTR.SIL.PRET: chr [1:2415] "CV" "CV" "CV" "CV" ...
## $ Begin.Time.s : num [1:2415] 20.4 20.6 33.6 36.5 40.3 ...
## $ End.Time.s   : num [1:2415] 20.4 20.6 33.6 36.5 40.4 ...
## $ Duration.ms  : num [1:2415] 19.1 20.2 40.7 25.2 34.7 ...
## $ AMOSTRA      : Factor w/ 2 levels "PBSP","SP2010": 1 1 1 1 1 1 1
1 1 1 ...
## $ PARTICIPANTE : chr [1:2415] "MartaS" "MartaS" "MartaS" "MartaS"
...
## $ SEXO         : chr [1:2415] "feminino" "feminino" "feminino" "fe
minino" ...
## $ IDADE        : num [1:2415] 32 32 32 32 32 32 32 32 32 32 ...
## $ IDADE.CHEGADA: num [1:2415] 18 18 18 18 18 18 18 18 18 18 ...
## $ ANOS.SP      : num [1:2415] 14 14 14 14 14 14 14 14 14 14 ...
## $ CONTEXTO     : chr [1:2415] "ai aqui j\u0087 tem treze ano vai f
azer quatorze" "ai aqui j\u0087 tem treze ano vai fazer quatorze" "a\u
0092 depois ele voltou a gente casou e viemos" "que l\u0087 voc\u0090
s\u0097 podia sair se fosse casado n\u008e se fosse pra" ...
## - attr(*, "spec")=
## .. cols(
## ..   PALAVRA = col_character(),
## ..   Transc.Fon = col_character(),
## ..   VOGAL = col_factor(levels = c("i", "e", "a", "o", "u"), orde
red = FALSE, include_na = FALSE),
## ..   F1 = col_double(),
## ..   F2 = col_double(),
## ..   F1.NORM = col_double(),
## ..   F2.NORM = col_double(),
## ..   CONT.PREC = col_character(),
## ..   CONT.SEG = col_character(),
## ..   VOGAL.SIL.SEG = col_character(),
## ..   F1.SIL.SEG = col_double(),
## ..   F2.SIL.SEG = col_double(),
## ..   F1.SEG.NORM = col_double(),
## ..   F2.SEG.NORM = col_double(),
## ..   VOGAL.TONICA = col_character(),
## ..   DIST.TONICA = col_double(),
## ..   ESTR.SIL.PRET = col_character(),
## ..   Begin.Time.s = col_double(),
## ..   End.Time.s = col_double(),
## ..   Duration.ms = col_double(),
## ..   AMOSTRA = col_factor(levels = c("PBSP", "SP2010"), ordered =
FALSE, include_na = FALSE),
## ..   PARTICIPANTE = col_character(),
## ..   SEXO = col_character(),
## ..   IDADE = col_double(),
## ..   IDADE.CHEGADA = col_double(),
## ..   ANOS.SP = col_double(),
## ..   CONTEXTO = col_character()
## .. )
## - attr(*, "problems")=<externalptr>

```

Nesta lição, vamos trabalhar apenas com os dados da vogal /e/ pretônica. Por vezes será nos dados apenas de paraibanos ou de paulistanos, por vezes será para ambos

os grupos. Crie então um subconjunto de dados chamado `PBSP_e`, com os dados da VOGAL /e/ na AMOSTRA PBSP.

```
PBSP_e <- filter(pretonicas, VOGAL == "e" & AMOSTRA == "PBSP")
```

Crie também um subconjunto de dados chamado `SP2010_e`, com os dados da VOGAL /e/ na AMOSTRA SP2010.

```
SP2010_e <- filter(pretonicas, VOGAL == "e" & AMOSTRA == "SP2010")
```

E crie um subconjunto de dados da vogal /e/ (com dados de PBSP e SP2010), chamado `VOGAL_e`, que vamos usar mais adiante.

```
VOGAL_e <- filter(pretonicas, VOGAL == "e")
```

Vamos agora fazer dois histogramas das medidas de `F1.NORM` (=altura das vogais) em uma mesma figura para compará-los. Complete a linha de comando neste ponto do *script*, substituindo, com calma, os valores `df`, `VAR` e `VAR`.

O dataframe é `VOGAL_e` – que contém dados de ambas as amostras –, o valor da variável em `x` é `F1.NORM` e da variável em `facet_grid()` é `AMOSTRA`, para que cada faceta contenha os dados de um dos grupos. A variável `AMOSTRA` vem antes de `~` para ordenar os gráficos um em cima do outro, e não lado a lado. O resultado se encontra na Figura 10.1.

```
ggplot(VOGAL_e, aes(x = F1.NORM)) +
  geom_histogram() +
  facet_grid(AMOSTRA ~ .)
```

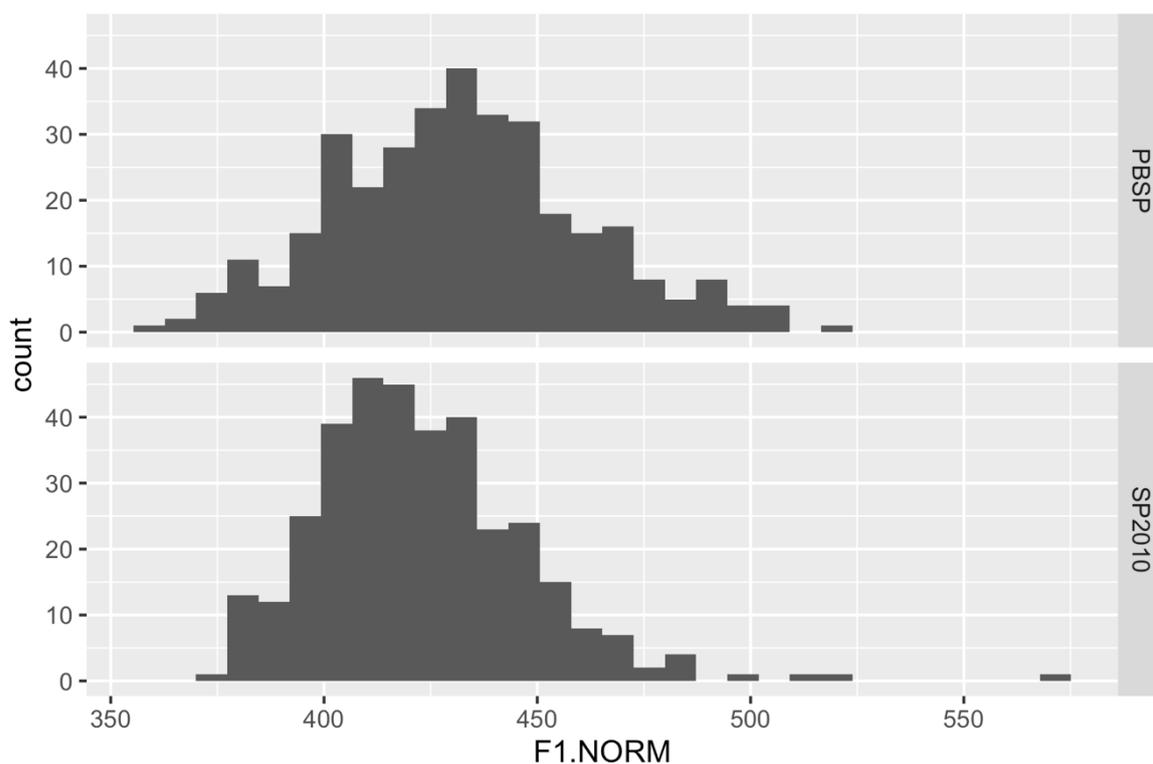


Figura 10.1: Distribuição das medidas de F1 normalizado da vogal /e/ nas amostras PBSP e SP2010. Fonte: própria.

Na figura, as medidas de F1.NORM para os paraibanos parecem ser, em geral, mais altas e mais dispersas do que para os paulistanos. Calcule a média e o desvio padrão de F1.NORM para PBSP e SP2010, e guarde os resultados num novo dataframe chamado `estatisticas`.

```
estatisticas <- VOGAL_e %>%
  group_by(AMOSTRA) %>%
  summarize(media_F1 = mean(F1.NORM),
            desvio_F1 = sd(F1.NORM)) %>%
  print()

## # A tibble: 2 × 3
##   AMOSTRA media_F1 desvio_F1
##   <fct>    <dbl>    <dbl>
## 1 PBSP      432.      29.5
## 2 SP2010    423.      24.9
```

Compare as médias de F1.NORM entre paraibanos e paulistanos: qual é maior?

- a média de F1.NORM de paraibanos
- a média de F1.NORM de paulistanos

Compare os valores de desvio padrão de F1.NORM entre paraibanos e paulistanos: qual é maior?

- o desvio padrão de F1.NORM de paraibanos
- o desvio padrão de F1.NORM de paulistanos

Como vimos na Lição 7, outro modo de visualizar a dispersão dos dados é por meio de boxplots. Faça um boxplot das medidas de F1.NORM por AMOSTRA no subconjunto de dados da VOGAL /e/ (Figura 10.2).

```
VOGAL_e %>%
  ggplot(., aes(x = AMOSTRA, y = F1.NORM)) +
  geom_boxplot(notch = TRUE) +
  scale_y_reverse()
```

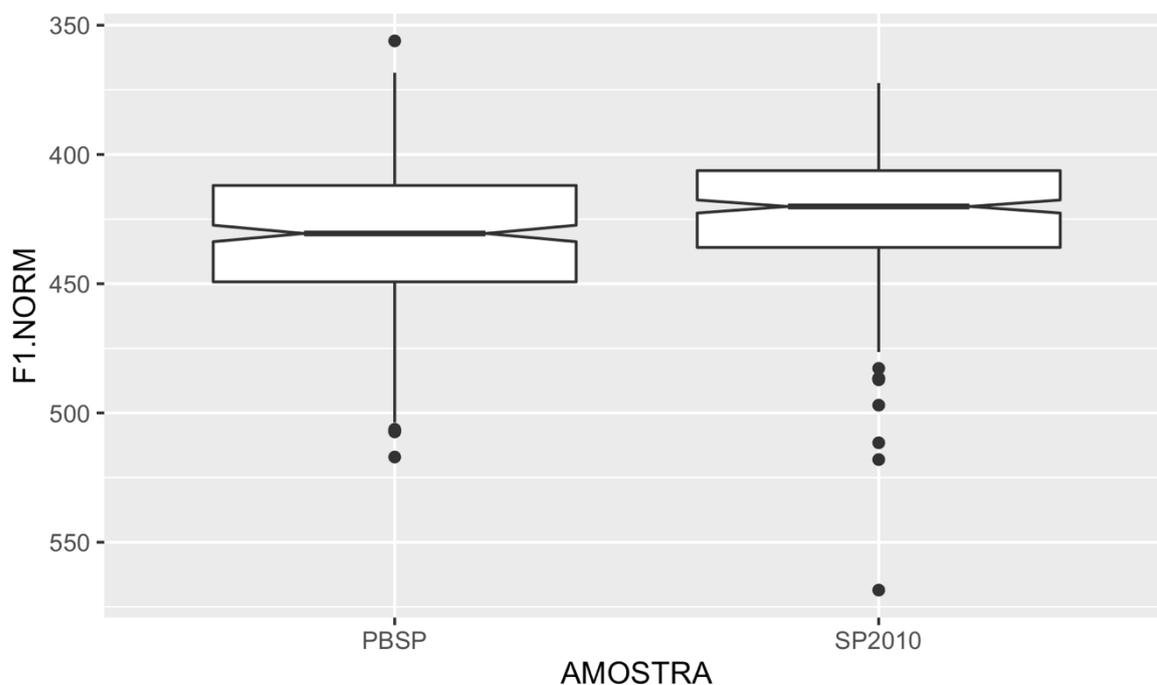


Figura 10.2: Boxplots das medidas de F1 normalizado da vogal /e/ nas amostras PBSP e SP2010. Fonte: própria.

Até aqui, refizemos os passos da Lição 7, pois esta teria sido sua trajetória de análise: começar com cálculos de medidas estatísticas básicas e visualização dos dados para estabelecer hipóteses. A partir dos histogramas e do boxplot, das medidas de média e desvio padrão, podemos querer verificar se as vogais médias pretônicas /e/ para paraibanos são significativamente mais baixas do que as dos paulistanos. Pelos entalhes

nos boxplots, temos uma boa evidência de que as médias são significativamente diferentes; cabe agora um teste estatístico para reforçar essa evidência.

O teste-t – no R, `t.test()` – compara médias e variâncias de uma distribuição com uma distribuição esperada ou com a distribuição de outro grupo. Ele tem, contudo, um requisito: a distribuição dos dados deve seguir a distribuição normal (o formato da curva de sino), ou deve ser aplicada a uma amostra com grande número de dados. Caso a distribuição não seja normal ou a amostra seja pequena, aplica-se uma variante do teste-t, chamada Teste de Wilcoxon – no R, `wilcox.test()`. Aqui, vamos seguir a primeira condição – seguir a distribuição normal ou não. O teste-t é um teste paramétrico e o teste de Wilcoxon é um teste não paramétrico.

Olhando para os histogramas (volte a eles com as flechinhas azuis), você acha que a distribuição das medidas de F1.NORM da vogal /e/ para paraibanos segue a distribuição normal?

- sim
- não
- não sei!

E para os paulistanos?

- sim
- não
- não sei!

A inspeção gráfica é um bom primeiro passo, mas deixa margem para muita dúvida. O teste de Shapiro permite obter uma medida mais acurada do quanto a distribuição se aproxima da distribuição normal. No R, ele é feito com a função `shapiro.test()`, que se aplica a um vetor de dados numéricos. Aplique a função aos dados de F1.NORM do subconjunto PBSP_e.

```
shapiro.test(PBSP_e$F1.NORM)
```

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

```
## data: PBSP_e$F1.NORM
## W = 0.99263, p-value = 0.09217
```

E aplique-a também aos de F1.NORM do subconjunto SP2010_e.

```
shapiro.test(SP2010_e$F1.NORM)

##
## Shapiro-Wilk normality test
##
## data: SP2010_e$F1.NORM
## W = 0.94706, p-value = 8.416e-10
```

Para aplicação do teste de Shapiro, usamos a função da instalação base do R. Só por curiosidade, também seria possível fazer isso por meio do `dplyr`; no entanto, como o resultado do teste de Shapiro é uma lista, também seria necessário guardar o resultado em uma lista (não um dataframe). A linha de comando neste ponto do *script*, já pronta, mostra como isso poderia ser feito, aplicando-se a função `list()` sobre o teste de Shapiro. Rode-a para ver o resultado.

```
shapiro <- pretonicas %>%
  filter(VOGAL == "e") %>%
  group_by(AMOSTRA) %>%
  summarize(res = list(shapiro.test(F1.NORM)))
```

O resultado pode ser acessado por `shapiro$res`, em que `shapiro` é o objeto criado pelo comando acima e `res` é onde guardamos o resultado do teste de Shapiro. Rode essa linha de comando.

```
shapiro$res

## [[1]]
##
## Shapiro-Wilk normality test
##
## data: F1.NORM
## W = 0.99263, p-value = 0.09217
##
##
## [[2]]
##
## Shapiro-Wilk normality test
##
## data: F1.NORM
## W = 0.94706, p-value = 8.416e-10
```

O teste de Shapiro testa a hipótese *nula* que os dados vêm de uma distribuição normal. Isso significa que um $p < 0,05$ indica que a distribuição provavelmente *não* é

normal. Veja o resultado do teste de Shapiro nos dados de PBSP_e. A que conclusão o pesquisador pode chegar?

- a distribuição é normal
- a distribuição não é normal

Qual teste então pode ser aplicado aos dados de PBSP_e?

- `t.test()`
- `wilcox.test()`

E sobre o resultado do teste de Shapiro nos dados de SP2010_e?

- a distribuição é normal
- a distribuição não é normal

Qual teste então pode ser aplicado aos dados de SP2010_e?

- `t.test()`
- `wilcox.test()`

Façamos isso. Vamos aplicar o teste-t à distribuição de F1.NORM dos dados de PBSP_e. Em sua forma mais simples, assim como no teste de proporções (Lição 9), pode-se verificar se a média dos dados observados é igual a uma média esperada. Neste caso, a função `t.test()` tem dois argumentos: (i) o vetor de dados numéricos com os dados observados; e (ii) o argumento `mu`, que especifica o valor esperado. Suponhamos que um estudo prévio sobre vogais médias pretônicas na fala de paraibanos tenha indicado uma média de 440 Hz para a vogal /e/; vamos usar esse valor para comparação.

```
t.test(PBSP_e$F1.NORM, mu = 440)

##
## One Sample t-test
##
## data: PBSP_e$F1.NORM
## t = -5.1475, df = 339, p-value = 4.482e-07
## alternative hypothesis: true mean is not equal to 440
## 95 percent confidence interval:
##  428.6064 434.9065
## sample estimates:
## mean of x
## 431.7564
```

Vejamos o resultado de um teste-t. Primeiro o R informa o teste que foi realizado (teste-t de uma amostra) e, logo em seguida, o conjunto de dados (PBSP_e\$F1.NORM). A terceira linha informa a medida t, os graus de liberdade e o valor de significância. Isso é paralelo ao teste de qui-quadrado, visto na Lição 9, com a diferença que, em vez de uma tabela de distribuição de qui-quadrado, consulta-se uma tabela de distribuição t. Como variáveis numéricas podem ter um número muito maior de graus de liberdade, ela não é mostrada aqui (como na última lição), mas você pode facilmente encontrá-la na Internet.

Logo em seguida o R enuncia a hipótese alternativa e o intervalo de confiança da distribuição (*default* = 95%). Se quisesse mudar o intervalo de confiança, bastaria especificar o argumento *conf.level*. Veja que o intervalo de confiança do teste acima (428,6 Hz a 434,9 Hz) não contém a média esperada ($\mu = 440$), de modo que a hipótese nula (= a média é igual a 440) pode ser rejeitada e a hipótese alternativa (= a média não é igual a 440) pode ser acatada. Por último, o R mostra a média da amostra (431,7 Hz), que é justamente o que havíamos calculado acima para as medidas de F1.NORM da vogal /e/ entre os paraibanos.

Assim como o teste de qui-quadrado, a aplicação do teste-t é extremamente simples. Mas não importa apenas saber como aplicá-lo, mas também *quando* aplicá-lo (a uma variável numérica) e *de onde saíram* as medidas estatísticas.

Para sua curiosidade, o valor-t é calculado de acordo com a fórmula na sequência. \bar{X} é o valor da média da amostra (para nós, `estatisticas$media_F1[1]`) e μ é a média esperada (aqui, 440); S é o valor de desvio padrão da amostra (`estatisticas$desvio_F1[1]`) e n é o número de observações.

$$t = \frac{\bar{X} - \mu}{\frac{S}{\sqrt{n}}}$$

No R, como seria escrita a fórmula da figura de acordo com nossos dados?

- `(estatisticas$media_F1[1] - 440) / (estatisticas$desvio_F1[1] / sqrt(length(PBSP_e$F1.NORM)))`
- `(estatisticas$media_F1[1] - 440) / (estatisticas$desvio_F1[1] / sqrt(PBSP))`

- $(440 - \text{estatisticas\$media_F1}[1]) / (\text{estatisticas\$desvio_F1}[1] / \text{length}(\text{PBSP_e\$F1.NORM}))$
- $\text{estatisticas\$media_F1}[1] - 440 / \text{estatisticas\$desvio_F1}[1] / \sqrt{\text{length}(\text{PBSP_e\$F1.NORM})}$

Execute a linha de comando $(\text{estatisticas\$media_F1}[1] - 440) / (\text{estatisticas\$desvio_F1}[1] / \sqrt{\text{length}(\text{PBSP_e\$F1.NORM})})$ para calcular o valor-*t*.

```
(estatisticas$media_F1[1] - 440) / (estatisticas$desvio_F1[1] / sqrt(length(PBSP_e$F1.NORM)))
```

```
## [1] -5.147498
```

Compare este valor com o valor-*t* calculado no teste-*t* acima. É o mesmo, certo? Quanto aos graus de liberdade, ele é o número de observações - 1. Como há 340 dados de F1.NORM da vogal /e/ para paraibanos, $df = 339$. (Para outros tipos de teste-*t* que veremos adiante, o cálculo do valor-*t* e dos graus de liberdade é um pouco diferente. Para mais informações, veja <http://www.statisticshowto.com/t-test/>.)

Assim como no teste de proporções, é possível estabelecer hipóteses bi ou unidirecionais. Para as vogais médias pretônicas /e/ na fala de migrantes paraibanos, a expectativa é que esses valores se aproximem mais das medidas de F1 dos paulistanos – vogais relativamente mais altas, ou F1 mais baixo. Neste caso, o pesquisador poderia estabelecer uma hipótese unidirecional: a média de F1.NORM para paraibanos em São Paulo é mais baixa do que a média de F1.NORM para paraibanos não migrantes. No R, como esta hipótese seria colocada da função `t.test()`?

- `t.test(PBSP_e$F1.NORM, mu = 440, alternative = "less")`
- `t.test(PBSP_e$F1.NORM, mu = 440, alternative = "greater")`
- `t.test(PBSP_e$F1.NORM, mu = 440, alternative = "two.sided")`

Faça agora o teste unidirecional, com `alternative = "less"`.

```
t.test(PBSP_e$F1.NORM, mu = 440, alternative = "less")
```

```
##
## One Sample t-test
##
## data: PBSP_e$F1.NORM
## t = -5.1475, df = 339, p-value = 2.241e-07
```

```
## alternative hypothesis: true mean is less than 440
## 95 percent confidence interval:
##      -Inf 434.3978
## sample estimates:
## mean of x
## 431.7564
```

Evidentemente, a escolha de um teste uni ou bidirecional depende de suas questões de pesquisa, hipóteses e expectativas. O conhecimento necessário aí é a sua formação em Linguística!

Vamos agora aplicar o teste para as vogais dos paulistanos. Lembre-se que, neste caso, como a distribuição não é normal, devemos aplicar o teste de Wilcoxon, cuja função no R é `wilcox.test()` – atenção para o nome da função, que é diferente do nome do teste! Como primeiro argumento, use o vetor de dados de `F1.NORM` de `SP2010_e`, e como segundo argumento uma média hipotética $\mu = 410$.

```
wilcox.test(SP2010_e$F1.NORM, mu = 410)

##
## Wilcoxon signed rank test with continuity correction
##
## data:  SP2010_e$F1.NORM
## V = 46146, p-value < 2.2e-16
## alternative hypothesis: true location is not equal to 410
```

O resultado da função `wilcox.test()` é mais resumido, mas a interpretação é semelhante. O teste nos informa que as médias não são iguais, com probabilidade de se ter observado tal distribuição em caso de a hipótese nula ser verdadeira abaixo de 0,001. Para esta função, o *default* é não exibir os valores do intervalo de confiança e a média da amostra; caso queira vê-los, é necessário especificar o argumento `conf.int = T`. Faça isso agora a partir da linha de comando acima.

```
wilcox.test(SP2010_e$F1.NORM, mu = 410, conf.int = T)

##
## Wilcoxon signed rank test with continuity correction
##
## data:  SP2010_e$F1.NORM
## V = 46146, p-value < 2.2e-16
## alternative hypothesis: true location is not equal to 410
## 95 percent confidence interval:
## 418.9230 424.0106
## sample estimates:
```

```
## (pseudo)median
##      421.4194
```

Note, contudo, que como se trata de uma distribuição não normal, as estimativas são menos precisas. Assim como na função `t.test()`, você também poderia estabelecer uma hipótese unidirecional com o argumento `alternative`, e mudar o intervalo de confiança com o argumento `conf.level`.

Nos exemplos acima, empregamos uma média esperada μ hipoteticamente vinda de algum estudo prévio, e analisamos os dados de `PBSP_e` e `SP2010_e` separadamente. Mas as funções `t.test()` e `wilcox.test()` também podem comparar a média e a variância/desvio padrão de dois grupos, como é justamente o nosso caso. Quando se quer comparar dois grupos, o primeiro argumento de ambas as funções é uma fórmula no formato `y ~ x`, em que `y` é a variável dependente e `x` é a variável independente. Memorize essa notação, pois ela será vista novamente mais adiante no curso. Aqui, queremos comparar `F1.NORM ~ AMOSTRA`. O segundo argumento é o conjunto de dados – para nós, `VOGAL_e`.

Para decidir qual dos testes aplicar (teste-t ou teste de Wilcoxon), fazemos um teste de Shapiro sobre os dados de `F1.NORM` do subconjunto `VOGAL_e`.

```
shapiro.test(VOGAL_e$F1.NORM)

##
## Shapiro-Wilk normality test
##
## data:  VOGAL_e$F1.NORM
## W = 0.97831, p-value = 1.505e-08
```

O teste nos informa que a distribuição dos dados não é normal e, portanto, é mais recomendado aplicar o teste de Wilcoxon. Essa decisão também poderia ter sido tomada pelo simples fato de que sabemos que a distribuição de uma das amostras (a dos paulistanos) não tem distribuição normal.

Digite então `wilcox.test(F1.NORM ~ AMOSTRA, data = VOGAL_e, conf.int = T)`.

```
wilcox.test(F1.NORM ~ AMOSTRA, data = VOGAL_e, conf.int = T)

##
## Wilcoxon rank sum test with continuity correction
```

```
##
## data: F1.NORM by AMOSTRA
## W = 70330, p-value = 9.2e-06
## alternative hypothesis: true location shift is not equal to 0
## 95 percent confidence interval:
## 5.181038 13.209983
## sample estimates:
## difference in location
## 9.148978
```

O resultado de um teste de Wilcoxon de duas amostras (= dois grupos) segue a mesma estrutura que já vimos acima; no entanto, uma diferença é que a estatística gerada é um valor W . Outra é o fato que a medida da comparação não são as médias em si, mas sim se a diferença entre elas é igual ou não a zero. É nesse sentido que se deve entender a hipótese alternativa (true location shift is not equal to 0) e os valores do intervalo de confiança. No teste feito acima, o intervalo de confiança, de 5,18 a 13,21, não contém zero, o que nos leva à rejeição da hipótese nula, com $p < 0,001$. A medida de estimativa ao final (9,15) é o valor da diferença estimada entre os grupos.

Veja que a estimativa da diferença entre as médias é um pouco diferente da diferença entre a média de PBSP e de SP2010. Digite `estatisticas$media_F1[1] - estatisticas$media_F1[2]` para comparar.

```
estatisticas$media_F1[1] - estatisticas$media_F1[2]
## [1] 8.790398
```

A diferença observada entre as médias é um pouco menor. Como os dados advêm de uma distribuição não normal, o teste de Wilcoxon ajustou a estimativa da diferença.

Por curiosidade, vamos aplicar a função `t.test()` ao mesmo conjunto de dados, para familiarização com o resultado fornecido pelo R. Digite `t.test(F1.NORM ~ AMOSTRA, data = VOGAL_e)`.

```
t.test(F1.NORM ~ AMOSTRA, data = VOGAL_e)
##
## Welch Two Sample t-test
##
## data: F1.NORM by AMOSTRA
## t = 4.2125, df = 660.96, p-value = 2.877e-05
## alternative hypothesis: true difference in means between group PBSP
and group SP2010 is not equal to 0
## 95 percent confidence interval:
```

```
## 4.692926 12.887869
## sample estimates:
## mean in group PBSP mean in group SP2010
## 431.7564 422.9660
```

O teste-t de duas amostras também mede a diferença entre as médias e testa a hipótese nula que a diferença é igual a zero. Os valores do intervalo de confiança estimam que a diferença entre as medidas de F1.NORM para paraibanos e paulistanos está entre 4,7 Hz e 12,9 Hz, intervalo que não inclui zero – daí a diferença entre as médias ser significativa. Ao final, o R apresenta as médias do grupo 1 e do grupo 2.

Assim como fizemos no teste de uma amostra, podemos estabelecer uma hipótese unidirecional. Para as vogais pretônicas /e/ de paraibanos e de paulistanos, pode-se esperar que a média de F1.NORM de paraibanos seja maior que a de paulistanos, ou que a média de F1.NORM de paulistanos seja menor que a de paraibanos. Como você acha que o R determina a direção da comparação?

- pela ordem alfabética dos níveis
- pela ordem dos níveis no dataframe
- é uma ordem aleatória, que muda a cada teste

Exato! Pela ordem dos níveis, que pode ter sido definida pelo usuário ao importar os dados com `read_csv()`, ou, caso não tenham sido feitas modificações, a ordem em que os níveis aparecem no dataframe. É importante, portanto, checar a ordem dos níveis de AMOSTRA para bem interpretar o resultado do teste-t. Aplique a função `levels()` a esse vetor para termos certeza da ordem dos níveis de AMOSTRA.

```
levels(VOGAL_e$AMOSTRA)
## [1] "PBSP" "SP2010"
```

Pela ordem no dataframe, o R vai comparar PBSP com SP2010, e não o contrário. Como esperamos que a média de F1.NORM seja maior para PBSP do que para SP2010, devemos estabelecer `alternative = "greater"` nas funções `wilcox.test()` ou `t.test()`. Copie a última linha de comando em que usamos a função `wilcox.test()`, cole-a no script e acrescente o argumento `alternative = "greater"`.

```
wilcox.test(F1.NORM ~ AMOSTRA, data = VOGAL_e, conf.int = T, alternative = "greater")

##
## Wilcoxon rank sum test with continuity correction
##
## data:  F1.NORM by AMOSTRA
## W = 70330, p-value = 4.6e-06
## alternative hypothesis: true location shift is greater than 0
## 95 percent confidence interval:
##  5.834992      Inf
## sample estimates:
## difference in location
##                9.148978
```

Fizemos isso apenas para que você tenha em conta que sempre pode realizar testes bi ou unidirecionais. Na verdade, o resultado significativo do teste unidirecional era previsível. Lembra-se do exemplo da moeda (Lição 8)? Lá vimos que o teste bidirecional (como era o caso do juiz imparcial) é mais rigoroso para rejeição da hipótese nula do que o teste unidirecional (como era o seu caso). Se a hipótese nula foi rejeitada num teste bidirecional, ela também será no teste unidirecional que prevê a direção dos dados observados.

Um terceiro tipo de teste-t/teste de Wilcoxon é de amostras pareadas. Aqui, permita-me usar um novo conjunto de dados, pois os dados de vogais pretônicas de paraibanos e paulistanos não são adequados para um teste pareado. Vamos usar um exemplo retirado do curso Statistical Inference, do swirl – outro curso que recomendo fazer –, mas que não tem nada a ver com Linguística, infelizmente.

Um exemplo linguístico em que se poderia aplicar um teste-t pareado seria testar a eficácia de determinado método de ensino. Digamos que um grupo de 10 alunos de um curso de inglês fizesse uma prova, depois passasse por uma aula, e em seguida fizesse nova prova sobre o mesmo assunto. O pesquisador quer comparar se o desempenho do aluno – medido pelas provas – melhorou depois da aula. O pesquisador tem em mãos 20 notas de provas, mas cada uma dessas notas não é uma observação independente vinda da população. É mais provável que alunos que já tinham tido uma nota boa na primeira prova continuem com uma boa nota na segunda prova. Cada nota da prova 1 está

associada a uma nota da prova 2. É aí que cabe fazer uma comparação de médias em que os dados são pareados.

No conjunto de dados não linguísticos com que vamos trabalhar, tem-se os resultados de um estudo médico sobre o sono, que testa o efeito de duas drogas que foram ministradas a 10 pacientes. Para mais informações, visite <https://stat.ethz.ch/R-manual/R-devel/library/datasets/html/sleep.html>. Este conjunto de dados está disponível no dataframe `sleep`, que faz parte da instalação base do R. Digite `sleep` para vê-lo no Console.

```
sleep
##      extra group ID
## 1      0.7      1  1
## 2     -1.6      1  2
## 3     -0.2      1  3
## 4     -1.2      1  4
## 5     -0.1      1  5
## 6      3.4      1  6
## 7      3.7      1  7
## 8      0.8      1  8
## 9      0.0      1  9
## 10     2.0      1 10
## 11     1.9      2  1
## 12     0.8      2  2
## 13     1.1      2  3
## 14     0.1      2  4
## 15    -0.1      2  5
## 16     4.4      2  6
## 17     5.5      2  7
## 18     1.6      2  8
## 19     4.6      2  9
## 20     3.4      2 10
```

A primeira coluna mostra o resultado obtido após a aplicação das drogas; a segunda coluna indica qual foi a droga (grupo 1 ou grupo 2); e a terceira coluna identifica o paciente (de 1 a 10). Se fizermos simplesmente a média das medições da droga 1 e da droga 2, não podemos saber efetivamente se cada paciente melhorou ou não.

Para fazer um teste-t pareado, precisamos de dois vetores de mesma extensão e mesma ordem, para que os pares estejam devidamente ordenados. Crie primeiro um vetor chamado `g1`, com as medições da primeira coluna, das linhas 1 a 10.

```
g1 <- sleep[1:10, 1]
```

Crie agora um vetor chamado `g2`, com as medições da primeira coluna, das linhas 11 a 20.

```
g2 <- sleep[11:20, 1]
```

Aplique o teste de Shapiro a `g1` para verificar se a distribuição é normal.

```
shapiro.test(g1)

##
## Shapiro-Wilk normality test
##
## data:  g1
## W = 0.92581, p-value = 0.4079
```

Aplique o teste de Shapiro a `g2` para verificar se a distribuição é normal.

```
shapiro.test(g2)

##
## Shapiro-Wilk normality test
##
## data:  g2
## W = 0.9193, p-value = 0.3511
```

Como ambas as amostras têm distribuição normal, podemos aplicar `t.test()`. O teste-t pareado toma como argumentos os dois vetores e mais o argumento `paired = T`. Digite então `t.test(g1, g2, paired = T)` para ver o resultado.

```
t.test(g1, g2, paired = T)

##
## Paired t-test
##
## data:  g1 and g2
## t = -4.0621, df = 9, p-value = 0.002833
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -2.4598858 -0.7001142
## sample estimates:
## mean of the differences
## -1.58
```

O R indica que a diferença é significativa ($p = 0,0028$), e que a diferença `g1 - g2` é em média -1,58. Para comparar, veja o resultado de um teste-t caso não se especificasse que as amostras são pareadas. Digite `t.test(g1, g2)` – o que seria o mesmo que `t.test(extra ~ group, data = sleep)`.

```
t.test(g1, g2)
```

```
##
## Welch Two Sample t-test
##
## data: g1 and g2
## t = -1.8608, df = 17.776, p-value = 0.07939
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -3.3654832 0.2054832
## sample estimates:
## mean of x mean of y
## 0.75 2.33
```

Neste caso, o intervalo de confiança vai de -3,37 a 0,21, um intervalo que inclui o zero, de modo que a diferença entre as amostras poderia ter sido nula. A significância reflete isso: o valor- p calculado está acima de 0,05. Veja que deixar de especificar o fato de que os dados são pareados pode mudar o resultado do teste: no primeiro caso, o teste indicou que houve diferença, e no segundo caso não.

Ao reportar os resultados de um teste-t ou teste de Wilcoxon, é importante indicar qual medida estatística foi gerada (t ou W), os graus de liberdade, o valor- p , o tipo de teste (uma amostra, duas amostras, duas amostras pareadas), se o teste foi uni ou bicaudal, junto com os valores de médias e de erro padrão de cada distribuição. Não há uma função específica na instalação base do R para calcular o erro padrão, mas ele é facilmente calculável. Como vimos na Lição 6, essa medida é o valor do desvio padrão dividido pela raiz quadrada do número de observações – no R: $sd(x)/\sqrt{\text{length}(x)}$. O resultado do teste de Wilcoxon sobre a diferença entre a média de F1.NORM entre as amostras pode ser assim reportado: “Um teste de Wilcoxon bicaudal foi feito para comparar as médias de F1 normalizadas da vogal pretônica /e/ nas amostras de paraibanos e de paulistanos. Em média, a vogal /e/ de paraibanos é significativamente mais baixa (média = 431,7Hz, erro padrão = 1,60) do que a de paulistanos (média = 423Hz, erro padrão = 1,33), $W = 70,330, p < 0,001$.”

Vamos fazer uma pequena revisão antes de concluir esta lição. Quando se aplica um teste-t ou teste de Wilcoxon?

- quando se tem uma variável fatorial e se quer comparar as médias de dois grupos

- quando se tem uma variável nominal e se quer comparar as médias de dois grupos
- quando se tem uma variável numérica e se quer comparar as médias de dois grupos

Quando se aplica um teste-t (e não um teste de Wilcoxon)?

- quando a distribuição dos dados segue a distribuição normal
- quando a distribuição dos dados não segue a distribuição normal
- quando a distribuição dos dados segue a distribuição binomial
- quando a distribuição dos dados segue a distribuição de qui-quadrado

Além da inspeção de histogramas, como se pode determinar se uma distribuição é normal?

- por meio do teste-t, com a função `t.test()`
- por meio do teste de Shapiro, com a função `shapiro.test()`
- por meio do teste de Wilcoxon, com a função `wilcox.test()`

Quando se aplica um teste-t/teste de Wilcoxon de uma amostra?

- quando se quer comparar uma distribuição com uma média conhecida
- quando se quer comparar as distribuições entre dois grupos diferentes de nossos dados
- quando se quer comparar as distribuições entre dois grupos pareados de nossos dados

Quando se aplica um teste-t/teste de Wilcoxon de duas amostras?

- quando se quer comparar uma distribuição com uma média conhecida
- quando se quer comparar as distribuições entre dois grupos diferentes de nossos dados
- quando se quer comparar as distribuições entre dois grupos pareados de nossos dados

Quando se aplica um teste-t/teste de Wilcoxon pareado?

- quando se quer comparar uma distribuição com uma média conhecida
- quando se quer comparar as distribuições entre dois grupos diferentes de nossos dados
- quando se quer comparar as distribuições entre dois grupos pareados de nossos dados

Para saber mais

Recomendo a leitura do capítulo 5 de Dalgaard (2008) e do capítulo 5 de Levshina (2015) para reforçar os conceitos aqui aprendidos.

Exercícios

Para estes exercícios, você vai precisar do arquivo DadosRT-percepcao.csv. Os dados dessa planilha foram adaptados de um experimento de percepções sociolinguísticas sobre a pronúncia variável de /r/ em coda silábica como tepe ou como retroflexo. Todos os participantes eram habitantes da cidade de São Paulo (nativos e não nativos). A eles foram tocados quatro pequenos excertos de áudio, em que ouviam uma pessoa falando; sua tarefa era a de imaginar quem era o falante e responder um questionário sobre as características que imaginaram. Sete dessas características deveriam ser assinaladas dentro de uma escala de dez pontos, em que um extremo significa “pouco” e o outro extremo significa “muito”: extrovertido; escolarizado; inteligente; formal; amigável; paulistano; ter sotaque. Havia também outra escala, em que um extremo significava morar num bairro mais periférico e o outro significava morar num bairro mais central. Os participantes foram divididos em dois grupos. Metade dos participantes ouviram os falantes Antonio e Luisa usando o retroflexo, e Daniela e Paulo usando o tepe. A outra metade ouviu os falantes Antonio e Luisa usando o tepe, e Daniela e Paulo usando o retroflexo. O interesse geral da pesquisa foi o de verificar se as percepções sobre um mesmo falante seriam alteradas ao serem ouvidos com o tepe ou com o retroflexo. Para mais detalhes, ver Oushiro (2015, 2019).

1. Carregue os dados de `DadosRT-percepcao.csv` em um dataframe chamado `dados`. Defina as colunas `VARIANTE.OUVIDA` e `FALANTE` como `factor`.
2. Cheque a estrutura dos dados para ver se foram carregados corretamente.
3. Aplique a função `View()` para visualizar a planilha de dados e se familiarizar com ela. Note, em especial, as colunas de variáveis numéricas: `EXTROVERSAO`, `ESCOLARIZACAO`, `INTELIGENCIA` etc. A planilha também contém variáveis que identificam a variante que foi ouvida, quem era o falante, e características sociais dos ouvintes/participantes.
4. Carregue o pacote `tidyverse`.
5. Faça um subconjunto de dados chamado `dados_R` para quando se ouviu a variante retroflexa. Veja o resultado de `str()` e de `View()` para saber como foram nomeadas a variável e a variante.
6. Faça um subconjunto de dados chamado `dados_T` para quando se ouviu a variante tepe. Veja o resultado de `str()` e de `View()` para saber como foram nomeadas a variável e a variante.
7. Faça um gráfico com dois histogramas da distribuição de “graus de paulistanidade” (`PAULISTANIDADE`) atribuídos aos falantes quando se ouviu o retroflexo e quando se ouviu o tepe. Para tanto, a partir do dataframe `dados`, (i) defina o parâmetro estético para `x`; (ii) use a geometria para histogramas com `binwidth = 1`, `alpha = 0.7` e cor das bordas das barras “gray”; e (iii) use `facet_grid()`, de modo que um histograma fique em cima do outro.
8. Examine os histogramas plotados. Em média, foram atribuídas maiores notas de `PAULISTANIDADE` quando se ouviu qual variante? Justifique sua resposta.
 - a. tepe
 - b. retroflexo
9. Os dados de `PAULISTANIDADE` quando se ouviu o retroflexo parecem seguir uma distribuição normal? Aplique o teste de Shapiro sobre esses dados.

10. De acordo com o teste acima, a distribuição das notas de PAULISTANIDADE quando se ouviu o retroflexo seguem uma distribuição normal? Justifique sua resposta.
11. Aplique o teste de Shapiro aos dados de PAULISTANIDADE quando se ouviu o tepe.
12. De acordo com o teste acima, a distribuição das notas de PAULISTANIDADE quando se ouviu o tepe seguem uma distribuição normal? Justifique sua resposta.
13. Com `ggplot()`, faça boxplots simples da distribuição dos dados de PAULISTANIDADE por VARIANTE.OUVIDA. Use o conjunto geral de dados e `notch = T`.
14. Calcule a média de notas atribuídas na escala de PAULISTANIDADE por VARIANTE.OUVIDA. Nomeie a coluna da medida como `media`.
15. Faça um teste estatístico para testar a hipótese nula de que a média da nota atribuída na escala de PAULISTANIDADE quando se ouviu o retroflexo é 5. Escolha o teste apropriado, segundo o resultado do teste de Shapiro, bem como o conjunto de dados. Estabeleça `conf.int = T`.
16. De acordo com o teste acima, qual deve ser a decisão do pesquisador?
 - a. Rejeitar a hipótese alternativa e acatar a hipótese nula.
 - b. Rejeitar a hipótese nula e acatar a hipótese alternativa.
 - c. Refazer o teste.
17. Faça um teste estatístico para testar a hipótese nula de que média da nota atribuída na escala de PAULISTANIDADE é a mesma para quando se ouviu o tepe ou o retroflexo. Escolha o teste apropriado, segundo o resultado do teste de Shapiro, bem como o conjunto de dados. Estabeleça `conf.int = T`.
18. De acordo com o teste acima, a diferença entre as médias de PAULISTANIDADE para quando se ouviu tepe ou retroflexo é zero? Justifique sua resposta.
19. Qual é a diferença estimada entre as médias?
 - a. 9.664e-15

- b. 0
 - c. 1,199951
 - d. 1,599976
 - e. 1,900033
20. Com `ggplot()`, faça boxplots da distribuição das notas atribuídas ao grau de SOTAQUE por `VARIANTE.OUVIDA` e `FALANTE`. Para tanto, (i) escolha o dataframe apropriado; (ii) defina os parâmetros gráficos `x` e `y`; (iii) use a geometria de boxplots com `notch = T`; e (iv) use `facet_grid()` de modo que os falantes apareçam em facetas lado a lado no gráfico.
21. A figura permite comparar as notas atribuídas ao grau de SOTAQUE quando se ouviu o tepe ou o retroflexo para cada um dos quatro falantes. Para qual dos quatro falantes parece realmente não haver uma diferença significativa entre a nota atribuída a SOTAQUE para retroflexo ou tepe?
- a. Antonio
 - b. Daniela
 - c. Luisa
 - d. Paulo
22. Na sequência, faremos quatro testes para analisar se a diferença entre as notas atribuídas ao grau de SOTAQUE é significativa a depender da `VARIANTE.OUVIDA`, para cada um dos quatro falantes. Como o teste se repetirá quatro vezes, é importante antes tomar uma importante medida. Qual é ela?
- a. fazer a correção de Bonferroni, ajustando o valor- p para $0,05/4$
 - b. fazer o teste-t para verificar se os dados seguem a distribuição normal
 - c. fazer o teste de qui-quadrado para determinar os graus de liberdade
23. Calcule qual deve ser o valor- p para repetir o teste quatro vezes.
24. De acordo o valor- p determinado acima, qual deve ser o nível de confiança?
25. Faça um teste de Wilcoxon para testar a diferença entre as notas atribuídas ao grau de SOTAQUE a depender da `VARIANTE.OUVIDA`, apenas para o falante Antonio. Para tanto, com auxílio do pipe e a partir do dataframe `dados`, (i)

crie um subconjunto apenas dos dados do falante Antonio; e (ii) aplique o teste de Wilcoxon com a fórmula $SOTAQUE \sim VARIANTE.OUVIDA$ e $data = .$ (o ponto final, que indica o conjunto de dados criado à esquerda do pipe). Estabeleça o nível de confiança igual ao valor que você calculou na questão acima.

26. Faça o mesmo teste acima para a falante Daniela.
27. Faça o mesmo teste acima para o falante Paulo.
28. Faça o mesmo teste acima para a falante Luisa.
29. De acordo com os quatro testes acima, para qual ou quais falantes não há diferença significativa para o grau de SOTAQUE atribuído a depender da VARIANTE.OUVIDA?

Se quiser praticar mais, use os dados *pretonicas* ou os dados desta aula para elaborar novos testes. Para as pretônicas, por exemplo, você pode fazer e interpretar os testes para a vogal /o/. Para os dados do teste de percepções sociolinguísticas, você pode testar os efeitos de *tepe/retroflexo* sobre outras variáveis (*ESCOLARIZACAO*, *CENTRALIDADE.BAIRRO* etc.).