

Pesquisa Quantitativa

Lupércio França Bessegato
Mestrado em Administração/UFJF

Comparações de Médias

Roteiro Geral

1. Introdução
2. Coleta de dados
3. Modelos probabilísticos
4. Distribuições amostrais e estimação
5. Testes de significância
- 6. Comparações de médias**
7. Tabelas de contagem
8. Análise de regressão
9. Referências



Roteiro do Módulo

5. Comparações de médias:
 - a) Amostras emparelhadas
 - b) Testes não paramétricos
 - c) Duas amostras independentes
 - d) Mais de duas amostras



Amostras Emparelhadas

Amostras Emparelhadas



- As amostras são dependentes
 - √ Observações combinam-se em pares
 - Observação na amostra 1 de equipara com observação na amostra 2
 - Membros dos pares estão relacionados de alguma maneira
 - √ Dados de pares emparelhados
 - √ Dependência ocorre geralmente quando cada amostra tem os mesmos sujeitos

Pesquisa Quantitativa - 2016

6

Exemplos



- Estudos observacionais longitudinais
 - √ Mesmos sujeitos fazem parte dos dois grupos (antes e após um período)
 - √ Exemplo:
 - Condicionamento físico antes e 4 semanas após início de treinamento de ciclismo

Pesquisa Quantitativa - 2016

7

- Estudos experimentais com medidas repetidas

- √ Sujeitos fazem parte dos dois grupos (antes e após um "tratamento")
- √ Exemplo:
 - Teste de desempenho de veículos com dois tipos diferentes de combustível

Pesquisa Quantitativa - 2016

8

Importante



- Sempre deve-se examinar cuidadosamente como os dados foram produzidos para ver se há duas amostras independentes ou duas amostras emparelhadas (pareadas)

Pesquisa Quantitativa - 2016

9

Análise de Amostras Emparelhadas



- Analisam-se as diferenças entre as medidas observadas por sujeito
 - √ Transforma-se em problema de uma amostra
 - √ Representam-se graficamente as diferenças
 - √ Compara-se a diferença da média dos dois grupos, aplicando teste t no conjunto de diferenças

Pesquisa Quantitativa - 2016

10

Exemplo



- Uso de telefone celular e tempo de reação
 - √ Amostras com 32 estudantes universitários
 - √ Simulação de situações de direção (com e sem celular), em que alvo brilhava na cor verde ou vermelha, em períodos irregulares
 - Pisar no freio o mais rápido possível com luz verde
 - √ Resposta:
 - Tempo médio de reação em várias tentativas
- Investigar se o uso do telefone celular prejudica a reação dos motoristas

Pesquisa Quantitativa - 2016

11

- Tempos de reação (em ms)



Usou Celular?			Estudante	Usou Celular?		
Sim	Não	Diferença		Sim	Não	Diferença
636	604	32	17	626	525	101
623	556	67	18	501	508	-7
615	540	75	19	574	529	45
672	522	150	20	468	470	-2
601	459	142	21	578	512	66
600	544	56	22	560	487	73
542	513	29	23	525	515	10
554	470	84	24	647	499	148
543	556	-13	25	456	448	8
520	531	-11	26	688	558	130
609	599	10	27	679	589	90
559	537	22	28	960	814	146
595	619	-24	29	558	519	39
565	536	29	30	482	462	20
573	554	19	31	527	521	6
554	467	87	32	536	543	-7

Pesquisa Quantitativa - 2016

12

• Estatísticas Descritivas - Saída R

```
> library(pastecs)# fornece resumo de estatísticas descritivas
> aggregate(tempo ~ uso, data = celular, stat.desc, basic = F)
```

uso	tempo.median	tempo.mean	tempo.SE.mean	tempo.CI.mean.0.95	tempo.var
1	N 527.0000000	534.5625000	11.7463908	23.9569220 4415.2862903	
2	S 569.0000000	585.1875000	15.8473335	32.3208497 8036.4153226	

	tempo.std.dev	tempo.coef.var
1	66.4476207	0.1243028
2	89.6460558	0.1531920

• Estatísticas descritivas – Quadro resumo

Desvio = Tempo de reação com celular – tempo sem celular

Grupos	\bar{x}	s_x
Com celular	585,2	66,45
Sem celular	534,6	89,65
Diferença	50,6	52,49

$$ep(\bar{x}_D) = \frac{52,48579}{\sqrt{32}} = 9,278$$

Pesquisa Quantitativa - 2016

• Box-plot

√ O estudante 28 é um valor atípico

Pesquisa Quantitativa - 2016

• Plot dos tempos por sujeito

Desvio = Tempo com celular – tempo sem celular

Tempo *o* celular maior que *o* celular

Desvios > 0

√ Estudante 28 é claramente atípico

√ Há diferenças negativas!

- Tempo médio de reação com celular é menor que sem celular!

Pesquisa Quantitativa - 2016

• Distribuição das diferenças:

√ O estudante 28 não tem uma diferença atípica

√ Pequena anomalia na densidade

- Há um grupo com maior diferença de reação

Pesquisa Quantitativa - 2016

• Verificação normalidade das diferenças

```

> shapiro.test(dif)

Shapiro-Wilk normality test

data: dif
W = 0.92194, p-value = 0.02348
    
```

- √ Dados apresentam desvios (extremidades)
- √ Forte evidência de dados não serem normais

Pesquisa Quantitativa - 2016

• Parâmetro de interesse:

$$\sqrt{\mu_D = \mu_C - \mu_S}$$

√ μ_C : tempo médio de reação da população de motorista com uso de celular

√ μ_S : tempo médio de reação da população de motorista sem uso de celular

• Hipóteses:

$$\sqrt{H_0: \mu_D = 0}$$

$$\sqrt{H_1: \mu_D \neq 0}$$

Pesquisa Quantitativa - 2016

• Considerações para uso do teste t:

- √ É robusto no presente caso, pois:
 - Hipótese é bilateral
 - Sem presença de valores atípicos
 - Amostra de tamanho moderado sem assimetria pronunciada

Pesquisa Quantitativa - 2016

• Execução do teste – comando:

```

# Criação do objeto com os resultados do teste t emparelhado
celular$uso <- relevel(celular$uso, "S") # Dá precedência ao nível "S"
dif.t <- with(celular, t.test(tempo ~ uso, alternative = "two.sided",
                             mu = 0, paired = TRUE, conf.level = 0.95))
    
```

• Resultado - saída:

```

> dif.t

Paired t-test

data: tempo by uso
t = 5.4563, df = 31, p-value = 5.803e-06
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 31.70186 69.54814
sample estimates:
mean of the differences
 50.625
    
```

Pesquisa Quantitativa - 2016

```

> dif.t

Paired t-test

data: tempo by uso
t = 5.4563, df = 31, p-value = 5.803e-06
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 31.70186 69.54814
sample estimates:
mean of the differences
      50.625
    
```

• Conclusão:

- ✓ Existe forte evidência de que o tempo médio de reação é maior quando o motorista usa o celular
- ✓ Tempo médio de reação da população usando celular está entre 32 e 70 ms acima do que aquele sem o uso do celular

21

• Teste t sem o estudante 28:

```

>> with(subset(ceular, estudante != 28), t.test(tempo[uso == "S"], tempo[uso ==
"N"], mu = 0,
+ alternative = "two.sided", paired = TRUE))

data: tempo[uso == "S"] and tempo[uso == "N"]
t = 5.2595, df = 30, p-value = 1.119e-05
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
29.08544 66.01133
sample estimates:
mean of the differences
      47.54839
    
```

Estadísticas amostrais	Diferenças (completo)	Diferenças (sem est. 28)
\bar{x}_D	50,63	47,55
t_0	5,456	5,260
p-valor	5,8e-6	1,1e-5
IC com 95%	[37,7; 69,5]	[29,1; 66,0]

Conclusão não é afetada pelo estudante 28

22

Importante

- Sujeitos no experimento provavelmente eram de uma amostra voluntária
 - ✓ Conclusões inferenciais são aproximadas

23

Exemplo

- Examinando pares de medidas de cabeças
 - ✓ Medição das cabeças de 18 pilotos de caça para compra de capacetes
 - ✓ Interesse:
 - Determinar a adequação de uso de calibrador de cartolina (barato) em vez de calibrador metálico (caro e desconfortável)
- Há diferença sistemática nas medidas produzidas pelos dois tipos de calibradores?

24

• Estatísticas Descritivas - Saída R

```
> apply(cabecas[-1], 2, stat.desc, basic = F)
```

	cartolina	metal
median	153.5000000	152.5000000
mean	154.5555556	152.9444444
SE.mean	1.3725179	1.3047730
CI.mean.0.95	2.8957596	2.7528306
var	33.9084967	30.6437908
std.dev	5.8231002	5.5356834
coef.var	0.0376764	0.0361940

• Estatísticas descritivas – Quadro resumo

Desvio = Cartolina – Metal

Grupos	\bar{x}	s_x
Cartolina	154,56	5,82
Metal	152,94	5,54
Diferença	1,611	2,146

$$ep(\bar{x}_D) = \frac{2.145827}{\sqrt{18}} = 0,506$$

Pesquisa Quantitativa - 2016

• Gráfico de pontos

√ Há pontos empilhados no gráfico
 – Dados arredondados até mm mais próximo

√ Centro dos dados está à direita do 0

√ Gráfico não dá motivo para duvidar da aplicabilidade de procedimentos t

Pesquisa Quantitativa - 2016

• Verificação normalidade das diferenças

Gráfico de Normalidade

```
> shapiro.test(dif)
```

Shapiro-Wilk normality test

data: dif
 W = 0.95735, p-value = 0.5515

√ Amostra pequena com empates
 √ Teste e gráfico não revelam qualquer evidência contra suposição de normalidade

Pesquisa Quantitativa - 2016

• Parâmetro de interesse:

√ $\mu_D = \mu_C - \mu_M$
 √ μ_C : medidas com calibrador de cartolina (mm)
 √ μ_M : medidas com calibrador metálico (mm)

• Hipóteses:

√ $H_0: \mu_D = 0$
 √ $H_1: \mu_C \neq 0$

Pesquisa Quantitativa - 2016



- Execução do teste – comando:

```
# Criação do objeto com os resultados do teste t emparelhado
dif.t <- with(cabecas, t.test(cartolina, metal, alternative = "two.sided",
                             mu = 0, paired = TRUE, conf.level = 0.95))
```

- Resultado - saída:

```
> dif.t
Paired t-test

data: cartolina and metal
t = 3.1854, df = 17, p-value = 0.005415
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.5440163 2.6782060
sample estimates:
mean of the differences
 1.611111
```

29



```
> dif.t
Paired t-test

data: cartolina and metal
t = 3.1854, df = 17, p-value = 0.005415
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.5440163 2.6782060
sample estimates:
mean of the differences
 1.611111
```

- Conclusão:

- ✓ Evidência muito forte de que o tipo de calibrador faz diferença
- ✓ Com 95% de confiança, os calibradores de cartolina fornecem medidas maiores em média que as dos calibradores metálicos, por entre 0,5 mm e 2,7 mm.

30

Testes Não Paramétricos



Testes Não Paramétricos

- Não fazem qualquer suposição a respeito da distribuição que produz os dados
 - ✓ Tendem a não ser sensíveis à presença de *outliers*
- Testes paramétricos:
 - ✓ Dependem da distribuição subjacente dos dados
 - ✓ O teste t é um teste paramétrico
 - Considera que a distribuição subjacente é normal

32

Testes Não Paramétricos – Classes



- Há várias classes de testes não paramétricos
- Testes não paramétricos baseados na ordem
 - √ Não consideram distâncias das observações entre si
 - √ Mediana usada como medida padrão de locação

- Alguns testes não paramétricos:
 - √ Teste do sinal
 - √ Teste de Wilcoxon de postos sinalizados
 - √ Teste de Wilcoxon-Mann-Whitney
 - √ Teste de Kruskal-Wallis
 - √ Teste de Levene
- Intervalos de confiança fornecidos pelos pacotes computacionais
 - √ Em geral por meio de inversão do teste



Testes Não Paramétricos – Uso




- Por que não são usados sempre?
 - √ Os testes paramétricos são superiores quando suas suposições são válidas
 - Superiores no sentido de, mais provavelmente, perceber afastamentos de H_0 (testes mais poderosos)
 - √ Devem ser usados quando os dados parecem não normais que há sérios receios no uso de testes paramétricos

Teste do Sinal



- Mediana populacional ($\tilde{\mu}$):
 - √ Valor do meio da distribuição
 - Mesma probabilidade de obter valor acima da mediana $\tilde{\mu}$, como abaixo dela.



Teste de Significância para a Mediana

- Testar que a mediana é 0
 - √ $H_0: \tilde{\mu} = 0$
- Se H_0 for verdadeira
 - √ Observação teria mesma probabilidade de ser positiva ou negativa
 - $P(+) = P(-) = 0,5 = p$
 - Ou seja, testar H_0 seria testar se $p = 1/2$
 - √ Evidência contra H_0 :
 - Grande desequilíbrio de sinais + e -
 - Teste usa teoria binomial na distribuição dos dados

37

Estrutura do Teste

- Equivalência das hipóteses:

$H_0: \tilde{\mu} = 0$ vs. $\tilde{\mu} \neq 0$	⇒	$H_0: p = \frac{1}{2}$ vs. $p \neq \frac{1}{2}$
$H_0: \tilde{\mu} = 0$ vs. $\tilde{\mu} > 0$		$H_0: p = \frac{1}{2}$ vs. $p > \frac{1}{2}$
$H_0: \tilde{\mu} = 0$ vs. $\tilde{\mu} < 0$		$H_0: p = \frac{1}{2}$ vs. $p < \frac{1}{2}$
- Empates:
 - √ Observações iguais à mediana hipotética
 - √ Diferenças emparelhadas iguais a zero
- Empates são ignorados
 - √ Ignorar empates é considerado uma aproximação

38

- Intervalos de confiança não paramétrico:
 - √ Em geral, usa-se o procedimento de inversão do teste
 - √ Construído reunindo todos os valores hipotético do parâmetro que não são rejeitados no nível de significância especificado

39

Exemplo

- Examinando pares de medidas de cabeças
 - √ Interesse:
 - Determinar a adequação de uso de calibrador de cartolina (barato) em vez de calibrador metálico (caro e desconfortável)
 - √ Hipótese nula:
 - Mediana das medidas dos 2 tipos de calibradores é 0

Diferença = Cartolina - Metal

40



- Empate:
 - √ Há um sujeito para o qual as medidas são iguais (diferença = 0)
 - √ Ignora-se este sujeito
 - São utilizados as 17 observações restantes
 - √ Sinais
 - Calibradores de cartolina (+)
 - Medida superior em 14 casos
 - Calibrador de metal (-)
 - Medida superior em 3 casos
 - √ Seria como lançar uma moeda 17 vezes e obter 14 caras.

41

Pesquisa Quantitativa - 2016



- Se H_0 for verdadeira:
 - √ $p = 1/2$
 - √ $P\{14 \text{ ou mais caras em } 17 \text{ lançamentos}\}$
 - $P\{Y \geq 14\}$, com $Y \sim \text{binomial}(n = 17; p = 0,5)$
 - $P\{Y \geq 14\} = 0,00636$.
- p-valor (H_1 é bilateral)
 - √ $p = 2 \times 0,00636 = 0,0127$
 - √ p-valor (teste t) = 0,005415
- Conclusão:
 - √ Forte evidência para rejeitar H_0
 - √ Mesma conclusão do teste t

42

Pesquisa Quantitativa - 2016



- Execução do teste – comando:


```
# Criação do objeto com os resultados do teste do sinal
library(BSDA) # Para comando do teste do sinal
dif.sign <- SIGN.test(dif, md = 0, alternative = "two.sided", conf.level = 0.95)
```
- Resultado - saída:


```
> dif.sign
One-sample Sign-Test

data:  dif
s = 14, p-value = 0.01273
alternative hypothesis: true median is not equal to 0
95 percent confidence interval:
 1.000000 2.707563
sample estimates:
median of x
 1.5
```

43

Pesquisa Quantitativa - 2016



- Intervalo de 95% confiança para a mediana das diferenças
 - √ [1,0; 2,7]
- IC de 95% para a média
 - √ Resultado do procedimento paramétrico (intervalo t)
 - √ [0,5; 2,7]

44

Pesquisa Quantitativa - 2016

Teste de Wilcoxon de Postos Sinalizados



- Outro teste não paramétrico com funcionamento similar
 - √ Testa as mesmas hipóteses
 - √ É melhor para detectar afastamentos de H_0

45

Pesquisa Quantitativa - 2016



- Execução do teste – comando:


```
# Criação do objeto com os resultados do teste do sinal
dif.wilc <- > with(cabecas, wilcox.test(cartolina, metal, mu = 0,
alternative = "two.sided", paired=TRUE, exact = FALSE,
conf.int = TRUE, conf.level = 0.95))
```
- Resultado - saída:


```
> dif.wilc
Wilcoxon signed rank test with continuity correction

data: cartolina and metal
V = 130.5, p-value = 0.01052
alternative hypothesis: true location shift is not equal to 0
95 percent confidence interval:
 0.5000399 2.9999637
sample estimates:
(pseudo)median
 1.500075
```

46

Pesquisa Quantitativa - 2016



- P-valor do teste:
 - √ Wilcoxon: 0,011
 - √ Sinais: 0,0127
- Conclusão:
 - √ A mesma em ambos os testes
- Intervalo de 95% confiança para a mediana das diferenças
 - √ Wilcoxon: [0,5; 3,0]
 - √ Sinais: [1,0; 2.7]

47

Pesquisa Quantitativa - 2016

Teste do Sinal – Uso



- Condições para uso:
 - √ Pode ser usado sempre, desde que
 - as observações sejam independentes (caso de uma amostra)
 - os diferentes pares de observações sejam independentes (caso de amostras emparelhadas)
 - √ O teste é muito sensível ao afastamento da hipótese de independência

48

Pesquisa Quantitativa - 2016



- Vantagens:
 - √ Livre de distribuição (*distribution-free*)
 - Válido para dados de qualquer distribuição (normal ou não)
 - √ Não é sensível a valores atípicos
- Desvantagens:
 - √ O teste t é superior quando suas suposições forem válidas

Pesquisa Quantitativa - 2016

49



- Em geral, testes não paramétricos são úteis quando:
 - √ Têm-se amostras muito pequenas ($n \leq 10$)
 - Há menor capacidade de verificar a validade das suposições do teste t ou de detectar valores atípicos
 - √ Execução de teste unilateral em situações que se suspeita de que os dados sejam oriundos de distribuição assimétrica
 - √ Existência de observação suspeita (grande ou pequena) que julgamos ser real em vez de apenas um erro.

Pesquisa Quantitativa - 2016

50



Duas Amostras Independentes

Pesquisa Quantitativa - 2016

51



Duas Amostras Independentes

- Comparação de parâmetros de amostras independentes de duas populações diferentes:
 - √ Comparar as duas médias populacionais
 - √ Comparar as duas dispersões populacionais

Pesquisa Quantitativa - 2016

52

Questões de Desenho do Estudo



- Experimentos x Estudos Observacionais
 - √ Dados são analisados da mesma maneira
 - √ Distinção se torna importante quando vamos interpretar os resultados da análise
 - √ Importante:
 - Deve-se ter muito cuidado ao fazer inferências causais a partir de dados observacionais

Pesquisa Quantitativa - 2016

53

Questões de Análise




- É importante representar graficamente os dados:
 - √ Examinar um gráfico apropriado é a maneira mais rápida de ver o que está acontecendo
 - √ Pode evitar o aparecimento de falsos juízos perigosos

Pesquisa Quantitativa - 2016

54

- Exemplo:



- √ Apenas a comparação entre as médias não permitiria observar a superposição significativa do nível do hormônio entre os dois grupos

Pesquisa Quantitativa - 2016

55

Questões de Análise



- Aplicabilidade de ferramentas formais de análise:
 - √ Todos os métodos formais de análise fazem suposições:
 - As suposições do método que desejamos usar são satisfeitas?
 - Se não, este fato pode nos causar problemas?

Pesquisa Quantitativa - 2016

56

Questões de Análise



- Outras características que não as médias:
 - √ Há outras características dos dados que não as médias que seriam interessante de se comparar?
 - √ Que procedimento adotar com tal finalidade?

Comparação de Duas Médias



- Suposição
 - √ Duas amostras aleatórias das populações:
 - População 1: $N(\mu_1, \sigma_1)$
 - População 2: $N(\mu_2, \sigma_2)$

- Intervalo de confiança para $\mu_1 - \mu_2$:

$$(\bar{x}_1 - \bar{x}_2) \pm t \times \text{ep}(\bar{x}_1 - \bar{x}_2) .$$

- Teste t para $H_0: \mu_1 - \mu_2 = 0$

$$t_0 = \frac{(\bar{x}_1 - \bar{x}_2)}{\text{ep}(\bar{x}_1 - \bar{x}_2)} .$$

- Cálculo manual:

√ Erro padrão:
$$\text{ep}(\bar{x}_1 - \bar{x}_2) = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} .$$

√ Graus de liberdade: $gl = \min\{(n_1 - 1), (n_2 - 1)\} .$

- √ Aproximação conservadora do procedimento de Welch (cálculo complicado)



- Cálculo computacional:

- √ Variabilidade das populações:

- Caso 1: variâncias iguais (homocedasticidade)
- Caso 2: variâncias diferentes (heterocedasticidade)

- √ Cada pacote apresenta *defaults* diferentes

- √ Recomenda-se como escolha de rotina considerar as variâncias das populações diferentes (heterocedasticidade)





- Variâncias desiguais – Heterocedasticidade
- √ Erro padrão:
$$\text{ep}(\bar{x}_1 - \bar{x}_2) = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$$
- √ Graus de liberdade – Aproximação de Satterthwaite

$$gl = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}\right)^2}{\frac{1}{n_1-1} \left(\frac{s_1^2}{n_1}\right)^2 + \frac{1}{n_2-1} \left(\frac{s_2^2}{n_2}\right)^2}$$

- Em amostragens repetidas, o valor fornecido muda de amostra a amostra
- Frequentemente obterá valores não inteiros (saídas)
- √ Estatística de teste t_0 não tem distribuição exata
- √ Cálculo manual garante uma aproximação conservadora dos graus de liberdade

61

Pesquisa Quantitativa - 2016



- Variâncias iguais – Homocedasticidade
- √ Erro padrão:
$$\text{ep}(\bar{x}_1 - \bar{x}_2) = s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$
- √ s_p^2 : estimativa combinada da variância única:

$$s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$$

- Combina a informação das duas amostras para formar uma única estimativa
- √ Graus de liberdade: $gl = n_1 + n_2 - 2$
- √ Hipótese de homocedasticidade deve sempre ser verificada
 - Na prática, raramente é verdadeira

62

Pesquisa Quantitativa - 2016



- Teste é razoavelmente robusto às variâncias diferentes (heterocedasticidade) quando os tamanhos das amostras são iguais
- √ Perde-se bastante quando a suposição de variâncias iguais é falsa e os tamanhos das amostras são diferentes
- Há autores que recomendam o uso rotineiro do procedimento de Welch
- √ Variâncias diferentes

63

Pesquisa Quantitativa - 2016



Robustez do Teste t de Duas Amostras

- Testes t e intervalos t para duas amostras são ainda mais robustos diante de não normalidade do que os testes t para 1 amostra
- √ Especialmente quando as formas das duas distribuições são semelhantes e os tamanhos das amostras são iguais
 - Mesmo para amostras tão pequenas quanto $n_1=n_2=5$
- √ Pode-se aplicar para $n_1 + n_2$ as recomendações sobre tamanhos amostrais do caso de 1 amostra

64

Pesquisa Quantitativa - 2016

Testes Não Paramétricos de Duas Amostras



- Alternativas mais conhecidas:
 - √ Teste da soma de postos de Wilcoxon
 - √ Teste de Mann-Whitney
- Ambos são equivalentes e produzem os mesmos p-valores

- Testes são baseados apenas na ordenação dos dados
 - √ Livre de distribuição
 - √ Testa-se a igualdade das medianas populacionais
 - √ Intervalos de confiança fornecidos são para a diferença das duas medianas
- Intervalos de confiança não paramétricos
 - √ Intervalos de confiança obtidos pelos pacotes por meio da inversão do teste



Exemplo



- Nível de hormônio masculino
 - √ Níveis de androsterona urinária (mg/24h)
 - √ Grupos de homens com boa saúde física:
 - Grupo 1: 11 homens
 - Grupo 2: 15 homens
- Os níveis médios dos grupos são iguais?

• Estatísticas Descritivas - Saída R



```
> library(pastecs)# fornece resumo de estatísticas descritivas
> aggregate(nivel ~ orientacao, data = androsterona, stat.desc, basic = F)

orientacao nivel.median nivel.mean nivel.SE.mean nivel.CI.mean.0.95 nivel.var
1 Hom 2.3000000 2.5000000 0.2382476 0.5109902 0.8514286
2 Het 3.8000000 3.5181818 0.2173469 0.4842790 0.5196364

nivel.std.dev nivel.coef.var
1 0.9227289 0.3690915
2 0.7208581 0.2048951
```

• Estatísticas descritivas – Quadro resumo

Grupos	\bar{x}	s_x	n
1	3,518	0,721	11
2	2,500	0,923	15

• Dados amostrais:

Gráfico de Pontos
Androsterona

Grupo 2

Grupo 1

Nível do hormônio (mg/24h)

✓ Grupo 2 tem média mais baixa, alguns dos indivíduos deste grupo têm níveis mais altos do que a maioria do grupo 1

✓ Leve assimetria e maior dispersão no grupo 2

Pesquisa Quantitativa - 2016

• Verificação normalidade das amostras

Gráfico de Normalidade

Grupo 1

Grupo 2

Quantis teóricos

Diferenças de reação

Indício de heterodasticidade

```
> shapiro.test(nivel.1)
Shapiro-Wilk normality test
data: nivel.2
W = 0.95746, p-value = 0.7396
```

```
> shapiro.test(nivel.2)
Shapiro-Wilk normality test
data: nivel.2
W = 0.92782, p-value = 0.2531
```

✓ Grupo 2 apresenta desvios (extremidades)

✓ Testes não têm evidência contra normalidade

Pesquisa Quantitativa - 2016

• Considerações para aplicação do teste t:

✓ Avaliação empírica

- Possibilidade de comportamento não normal para os dados

✓ Gráficos de probabilidade estão razoáveis e teste formais não apresentaram evidência contrária à suposição de normalidade

- Em amostras pequenas pode ser difícil verificar normalidade dos dados

✓ Estamos também protegidos pela robustez dos testes t e intervalos t.

Pesquisa Quantitativa - 2016

• Parâmetro de interesse:

✓ $\mu_1 - \mu_2$: diferença desconhecida entre os valores verdadeiros dos níveis médios de androsterona nos dois grupos

• Hipóteses

✓ $H_0: \mu_1 - \mu_2 = 0$ vs. $H_1: \mu_1 - \mu_2 \neq 0$

Pesquisa Quantitativa - 2016



Programa de Pós-Graduação em Administração

- Teste t – Cálculo manual:
 - √ Erro padrão:
 - Grupos independentes

$$ep(\bar{x}_1 - \bar{x}_1) = \sqrt{\frac{s_1^2}{n_N} + \frac{s_1^2}{n_S}}$$

$$= \sqrt{\frac{0,721^2}{11} + \frac{0,923^2}{15}}$$

$$= 0,32257.$$

- Estatística de teste:

$$t_0 = \frac{\text{estimativa} - \text{valor admitido por hipótese}}{\text{erro padrão}}$$

$$= \frac{(3,518 - 2,500) - 0}{0,32257} = 3,15887.$$
- p-valor:
 - √ Distribuição amostral: t_{10} [gl=min(11-1,15-1)=10]
 - $p - \text{valor} = 2 \times \Pr\{T \geq 3,15887\} = 0,010178.$

73



Programa de Pós-Graduação em Administração

√ IC de 95% para a verdadeira diferença ($\mu_1 - \mu_2$)

$$(\bar{x}_1 - \bar{x}_2) \pm t_{10} \times ep(\bar{x}_1 - \bar{x}_2) =$$

$$(3,518 - 2,500) \pm 2,228139 \times 0,32257 =$$

$$[0,30; 1,74].$$

74



Programa de Pós-Graduação em Administração

- Teste t – variâncias diferentes:


```
# Criação do objeto com os resultados do teste t para diferença
dif.t <- t.test(nivel ~ orientacao, mu = 0, alternative = "two.sided",
               paired = FALSE, conf.level = 0.95, data = androsterona)
```
- Resultado - saída:


```
> dif.t
Welch Two Sample t-test

data: nivel by codigo
t = 3.1572, df = 23.862, p-value = 0.004278
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.3523851 1.6839786
sample estimates:
mean in group 1 mean in group 2
 3.518182          2.500000
```

75



Programa de Pós-Graduação em Administração

```
> dif.t
Welch Two Sample t-test

data: nivel by codigo
t = 3.1572, df = 23.862, p-value = 0.004278
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.3523851 1.6839786
sample estimates:
mean in group 1 mean in group 2
 3.518182          2.500000
```

- Conclusão:
 - √ Evidência muito forte de uma diferença significativa entre as médias verdadeiras
 - √ Com 95% de confiança, nível médio do hormônio é maior no grupo 1 não menos que 0,4 mg/24h e e não mais que 1,7 mg/24h do que o nível médio do grupo 2

76



- **Teste t combinado – variâncias iguais:**

```
# Criação do objeto com os resultados do teste t para diferença

# para a diferença - procedimento combinado
dif.comb <- t.test(nivel ~ orientacao, mu = 0, alternative = "two.sided",
                 var.equal = T, paired = FALSE, conf.level = 0.95,
                 data = androsterona)
```

- **Resultado - saída:**

```
> dif.comb

Two Sample t-test

data: nivel by grupo
t = 3.0372, df = 24, p-value = 0.005679
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.326298 1.710066
sample estimates:
mean in group 1 mean in group 2
   3.518182      2.500000
```

77

Pesquisa Quantitativa - 2016



- **Teste não paramétrico – Mann-Whitney:**

```
# Criação do objeto com os resultados do teste não paramétrico

# Teste de Mann-Whitney-Wilcoxon
dif.wilc <- wilcox.test(nivel ~ orientacao, data = androsterona, mu = 0,
                      paired = FALSE, alternative = "two.sided",
                      exact = FALSE, conf.int = TRUE, conf.level = 0.95)
```

- **Resultado - saída:**

```
> dif.wilc

Wilcoxon rank sum test with continuity correction

data: nivel by orientacao
W = 132.5, p-value = 0.01003
alternative hypothesis: true location shift is not equal to 0
95 percent confidence interval:
 0.3999628 1.8000446
sample estimates:
difference in location
   1.100007
```

78

Pesquisa Quantitativa - 2016



- **Comparação dos resultados:**

Teste	p-valor	Intervalo de confiança
t – Welch	0,0044	[0,35; 1,68]
T combinado	0,0057	[0,33; 1,71]
Mann-Whitney	0,0100	[0,40; 1,80]
t – cálculo manual	0,0102	[0,30; 1,74]

- ✓ Valores são bem semelhantes
- ✓ Mesmas conclusões dos testes
- ✓ Pequenas diferenças nos intervalos de confiança

79

Pesquisa Quantitativa - 2016



Mais de Duas Amostras

80

Pesquisa Quantitativa - 2016

Análise de Variância de um Fator



- Problema mais geral:
 - √ Comparar a média de várias (k) populações ou grupos usando amostras independentes
- Análise de variância de um fator:
 - √ Situações em que há apenas um fator (ou variável categórica) definindo pertinência a grupo

Pesquisa Quantitativa - 2016

81

Teste F para Anova de um Fator



- Hipóteses:
 - √ H_0 : Todas as k médias verdadeiras são iguais
 - √ H_1 : Existem diferenças entre algumas delas
- Formalização:
 - √ $H_0: \mu_1 = \mu_2 = \dots = \mu_k$
 - √ H_1 : pelo menos uma diferença entre as médias

Pesquisa Quantitativa - 2016

82

Exemplo



- Comparação de quatro métodos de leitura:
 - √ Investigação sobre os efeitos de diferentes métodos para compreensão de leitura
 - √ Amostra de 50 alunos entre 13 e 14 anos
 - √ Métodos:
 - Mapeamento: uso de diagramas para observar e relacionar pontos principais
 - Varredura: leitura de introduções, passando os olhos para uma visão geral, antes de ler em detalhes
 - Ambos
 - Nenhum

Pesquisa Quantitativa - 2016

83

- Interesse:
 - √ Saber a efetividade dos métodos
- Medidas:
 - √ Idade de leitura (teste Gapadol)
 - √ Obter idades de leitura antes e depois do período de instrução (6 semanas)
- Classificação dos estudantes:
 - √ 4 grupos, dependendo de qual os métodos de leitura eles utilizaram antes do 2º teste
- Resposta:
 - √ Diferença dos escores de teste de leitura (em anos de idade de leitura)



Pesquisa Quantitativa - 2016

84



- **Questão:**
 - √ Os aumentos, em média, são maiores para os alunos que usaram mapeamento, varredura ou ambos?
- **Cuidado da pesquisa:**
 - √ Se usada a idade de leitura após período de instrução, quaisquer diferenças poderiam ser apenas devido a diferenças em habilidade de leitura entre os grupos

85

Pesquisa Quantitativa - 2016



- **Estatísticas Descritivas - Saída R**

```

> library(pastecs)# fornece resumo de estatísticas descritivas
> aggregate(aumento ~ metodo, data = leitura, stat.desc, basic = F)

metodo aumento.median aumento.mean aumento.SE.mean aumento.CI.mean.0.95
1 Ambos 1.6000000 1.4590909 0.3290850 0.6843697
2 Mapa 1.0000000 1.2333333 0.4160298 0.9156755
3 Nenhum -0.7000000 -0.5555556 0.3782677 0.8722868
4 Varredura 1.0000000 0.9142857 0.4920456 1.2039921

aumento.var aumento.std.dev aumento.coef.var
1 2.3825325 1.5435454 1.0578816
2 2.0769697 1.4411696 1.1685159
3 1.2877778 1.1348030 -2.0426453
4 1.6947619 1.3018302 1.4238768
    
```

Grupos	\bar{x}	s_x
Ambos	1,459	1,544
Mapa	1,233	1,441
Scan	0,914	1,302
Nenhum	-0,556	1,135

Variabilidade aparenta ser a mesma nos grupos

86

Pesquisa Quantitativa - 2016



- **Visualização gráfica:**




Gráfico de Pontos
Habilidade de Leitura

Diferenças nos escores (anos de idade de leitura)


- √ Escores para cada um dos 3 grupos parecem deslocados para a direita (em relação a nenhum)
- √ Aparentemente todos os tratamentos parecem ter algum efeitos
 - Efeitos semelhantes

87

Pesquisa Quantitativa - 2016



- **Gráfico dos erros:**



Comparação Intervalos Individuais

Média +/- erro

Tratamentos

- √ Quando os IC's individuais não se sobrepõem, o IC para a diferença não conterá 0
 - Parece haver pelo menos uma diferença estatisticamente significante no gráfico

88

Pesquisa Quantitativa - 2016

Tabela Anova

• Tabela Anova – comando:

```
# Criação do objeto com o ajuste
leitura.mod = lm(aumento ~ metodo, data = leitura)
```

• Resultado - saída:

```
> anova(leitura.mod)
Analysis of Variance Table

Response: aumento
Df Sum Sq Mean Sq F value Pr(>F)
metodo 3 27.062 9.0205 4.445 0.007977 **
Residuals 46 93.351 2.0294
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Há pelo menos uma diferença entre as médias verdadeiras

√ Evidência muito forte contrária à hipótese de igualdade das médias

89

• Plot das médias:

Médias dos Grupos

√ Aparentemente, há diferenças entre os aumentos médios de idade de leitura entre os grupos

90

• Importante:

- √ Teste não indica onde estão as diferenças, nem sua intensidade
- √ Para estimar o tamanho das diferenças são necessários intervalos de confiança

91

Interpretação do p-valor do Teste F

- p-valor grande:
 - √ Diferenças observadas entre as médias amostrais podem ser explicadas simplesmente em termos da variação amostral
- p-valor pequeno:
 - √ Evidência de que existem diferenças reais entre pelo menos duas médias verdadeiras (sem indicação de qual diferença, nem de sua intensidade)

92

Suposições da Anova

- Todos os grupos têm a mesma variância verdadeira
- Estimativa combinada do desvio padrão é empregada no cálculo dos erros padrão para as médias individuais e para as diferenças entre elas



Programa de Pós-Graduação em Administração

93

Pesquisa Quantitativa - 2016

- Diferenças (controle = Nenhum)
 - √ erros padrão individuais (baseados em s_p)

```

> summary(leitura.mod)
> sp <- summary(leitura.mod)$sigma
> sp
[1] 1.424557
            
```

Intercepto: média grupo "Nenhum"

Coefficientes: diferença entre a média do grupo e "Nenhum"

Erro padrão: calculado com s_p

```

Call:
lm(formula = aumento ~ metodo, data = leitura)

Residuals:
    Min       1Q   Median       3Q      Max
-2.8591 -1.0229 -0.1444  0.9602  2.8409

Coefficients:
(Intercept)  -0.5556  0.4749  -1.170  0.248045
metodoAmbos   2.0146  0.5637   3.574  0.000839 ***
metodoMapa    1.7889  0.6282   2.848  0.006560 **
metodoVarredura 1.4698  0.7179   2.047  0.046355 *
            
```

√ Refere-se ao teste da diferença de médias entre o grupo indicado na linha e o grupo "Nenhum"

- Evidência forte de diferenças significativa: ("Mapa" - "Nenhum") e ("Ambos" - "Nenhum")



Programa de Pós-Graduação em Administração

94

Pesquisa Quantitativa - 2016

- IC's de 95% para a diferença da média de cada grupos com o grupo de controle ("Nenhum"):

√ Erro padrão calculado a partir de s_p

```

> confint(leitura.mod)
                2.5 %    97.5 %
(Intercept)  -1.51138352  0.4002724
metodoAmbos   0.88002958  3.1492633
metodoMapa    0.52444734  3.0533304
metodoVarredura 0.02476521 2.9149173
            
```

√ Sugere-se que as médias de "Nenhum" e "Varredura" sejam iguais

√ E o nível de confiança global nestas 3 comparações de diferenças?



Programa de Pós-Graduação em Administração

95

Pesquisa Quantitativa - 2016

- Comparações emparelhadas de Fisher
 - √ Compara todas as diferenças entre médias

```

> MSerro <- anova(leitura.mod)[["Mean Sq"]][2]
> DFerro <- anova(leitura.mod)[["Df"]][2]
> LSD.test(leitura.mod, "metodo", DFerro, MSerro, console = TRUE)
            
```

metodo,	means and individual	(95 %)	CI
	aumento	std r	LCL UCL Min Max
Ambos	1.4590909	1.543545	22 0.8477413 2.0704405 -1.4 4.3
Mapa	1.2333333	1.441170	12 0.4055620 2.0611046 -1.4 3.6
Nenhum	-0.5555556	1.134803	9 -1.5113835 0.4002724 -2.0 1.6
Varredura	0.9142857	1.301830	7 -0.1695213 1.9980928 -0.9 3.3

alpha: 0.05 ; Df Error: 46
Critical Value of t: 2.012896

Means with the same letter are not significantly different

Groups,	Treatments and means
a	Ambos 1.459091
a	Mapa 1.233333
a	Varredura 0.9142857
b	Nenhum -0.5555556

Sugere que "Ambos", "Mapa" e "Scan" têm a mesma média verdadeira



Programa de Pós-Graduação em Administração

96

Pesquisa Quantitativa - 2016



- Comparações emparelhadas de Fisher:
 - √ IC de cada diferença têm 95% de cobertura
 - √ Chance de cobertura de todos os IC's é menor
 - Family-wise error: 0,198, nas 6 comparações do slide anterior
 - Significa que a chance de todos os 6 IC's cobrirem o verdadeiro valor da diferença é 1 em 5
 - √ Quanto mais comparações simultâneas, pior o problema

97

Pesquisa Quantitativa - 2016



- Comparações emparelhadas de Tukey
 - √ Nível global de confiança: 95%

```

> leitura.mod2 <- aov(aumento ~ metodo, data = leitura)
> TukeyHSD(x = leitura.mod2, "metodo", conf.level=0.95)
Tukey multiple comparisons of means
 95% family-wise confidence level

Fit: aov(formula = aumento ~ metodo, data = leitura)

$metodo
      diff      lwr      upr      p adj
Ambos-Nenhum  2.0146465  0.5121756  3.517117  0.0045033
Mapa-Nenhum   1.7888889  0.1145029  3.463275  0.0321119
Varredura-Nenhum 1.4698413 -0.4437427  3.383425  0.1859365
Mapa-Ambos   -0.2257576 -1.5884421  1.136927  0.9709011
Varredura-Ambos -0.5448052 -2.1925747  1.102964  0.8145109
Varredura-Mapa -0.3190476 -2.1249529  1.486858  0.9650797
    
```

Todos os intervalos, exceto dois contém 0

- √ Diminui a precisão dos intervalos
 - Taxa individual é 0,0106

98

Pesquisa Quantitativa - 2016



- Intervalos que não contém zero
 - √ “Mapa” e “Nenhum”:
 - Verdadeiro aumento no escore do teste é maior, em média, para o grupo “Mapa” do que para o grupo “Nenhum” por entre 0,1 e 3,5
 - (limite inferior de confiança muito próximo de 0)
 - √ “Ambos” e “Nenhum”
 - [0,5; 3,5]: pode ser lido de maneira análoga
 - √ Há evidência que os métodos são efetivos, mas há informação insuficiente nos dados para se poder dizer qual deles é melhor

99

Pesquisa Quantitativa - 2016



- IC individuais para nível de confiança global de 95%

95% family-wise confidence level

Linear Function

100

Pesquisa Quantitativa - 2016

Teste F



- Aplica-se a situações em que têm-se k amostras independentes de cada uma de k populações
- Suposição
 - √ Dados do i-ésimo grupo $\sim N(\mu_i, \sigma)$
 - √ Mesmos desvios padrão das populações subjacente

101

Tabela Anova




- Interpretação:

Analysis of Variance Table

Response: aumento

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
metodo	3	27.062	9.0205	4.445	0.007977
Residuals	46	93.351	2.0294		

- √ Linha do fator:
 - Variabilidade entre os grupos
- √ Linha dos resíduos (erros)
 - Variabilidade dentre dos grupos



102

Notação



x_{ij} : j-ésima observação no i-ésimo grupo
 \bar{x}_i : média amostral do grupo i
 s_i : desvio padrão do grupo i
 n_i : quantidade de observações do grupo i
 $n = \sum n_i$: total global de observações
 $\bar{x}_{..}$: média global

103



Fonte de Variação	Soma de Quadrados	gl	Média Quadrática ^a	F_0
Entre	$\sum n_i(\bar{x}_i - \bar{x}_{..})^2$	k - 1	s_B^2	$f_0 = \frac{s_B^2}{s_W^2}$
Dentro	$\sum (n_i - 1)s_i^2$	n - k	s_W^2	
Total	$\sum \sum (x_{ij} - \bar{x}_{..})^2$	n - 1		

^aMédia quadrática = (soma de quadrados)/gl.

- P-valor:
 - √ $p = \Pr\{F \geq f_0\}$

104

Quantidades da Tabela Anova



- s_B^2 : média quadrática entre os grupos

$$s_B^2 = \frac{\sum n_i(\bar{x}_i - \bar{x}_{..})^2}{k - 1}$$
 - √ Medida de variabilidade das médias amostrais (quão afastadas elas estão)
- s_W^2 : média quadrática dentro dos grupos

$$s_W^2 = \frac{\sum (n_i - 1)s_i^2}{n - k}$$
 - √ Média ponderada dos desvios padrão dos grupos – (reflete a variabilidade dentro das amostras)

Pesquisa Quantitativa - 2016 106



- f_0 : estatística F

$$f_0 = \frac{s_B^2}{s_W^2}$$
 - √ Compara a variabilidade das médias amostrais com a variabilidade interna dos grupos
- Evidência contra H_0 :
 - √ Valores de f_0 que sejam grandes se H_0 fosse verdadeira
- Quando $k = 2$, $f_0 = t_0^2$
 - √ t_0 do teste t combinado
 - √ p-valor é o mesmo do teste t bilateral com estimativa combinada

Pesquisa Quantitativa - 2016 107



- Quando H_0 é verdadeira:

$$f_0 \sim F_{gl_1, gl_2}$$
 - √ gl_1 : graus de liberdade no numerador
 - √ gl_2 : graus de liberdade no denominador
- p-valor:

$$p\text{-valor} = \Pr\{F \geq f_0\}$$

Pesquisa Quantitativa - 2016 108

Exemplo



- Vacinas contra coqueluche
 - √ Comparação de vacina padrão (WCV) com uma nova vacina (APV) e DAPV (vacina APV com o dobro de potência).
 - √ Estudo aleatorizado, duplo cego, com 91 crianças de 17 a 19 meses
 - √ Variável medida:
 - Concentração de anticorpos de coqueluche medida no sangue, 1 mês após imunização
 - Medidas na escala log(UI/mL)

Pesquisa Quantitativa - 2016 109

• Avaliação gráfica:

- ✓ Valor atípico (-2,30) no grupo APV foi um erro
- ✓ Indício de diferença entre a vacina experimental e a vacina padrão (WCP)
- ✓ Pouca ou nenhuma diferença entre as duas diferentes potências da vacina experimental (APV e DAPV)
- ✓ Interessante estimar os tamanhos das diferenças

PP
GA
Programa de Pós-Graduação em Administração

110

• Anova – todo o conjunto de dados:

```
# Criação do objeto com o ajuste
coqueluche.mod1 <- lm(concentracao ~ vacina, data = coqueluche)
```

• Resultado - saída:

```
> anova(coqueluche.mod1)
Analysis of Variance Table

Response: concentracao
Df Sum Sq Mean Sq F value Pr(>F)
vacina  2  13.519   6.7597   3.9224 0.02335 *
Residuals 88 151.653   1.7233
---
Signif. codes:  0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

✓ Evidência contrária à hipótese de igualdade das médias

PP
GA
Programa de Pós-Graduação em Administração

111

• Anova – sem valor atípico:

```
# Criação do objeto com o ajuste
# valor atipico: linha 25
coqueluche.mod2 <- lm(concentracao ~ vacina, data = coqueluche[-25,])
```

• Resultado - saída:

```
> anova(coqueluche.mod2)
Analysis of Variance Table

Response: concentracao
Df Sum Sq Mean Sq F value Pr(>F)
vacina  2  15.829   7.9143   6.1752 0.003106 **
Residuals 87 111.502   1.2816
---
Signif. codes:  0 '****' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Há pelo menos uma diferença entre as médias verdadeiras

✓ Sinaliza evidência clara de que existem diferenças entre as médias verdadeiras

PP
GA
Programa de Pós-Graduação em Administração

112

• Boxplot:

PP
GA
Programa de Pós-Graduação em Administração

113



- Comparações emparelhadas de Tukey
 - √ Nível global de confiança: 95%

```

> coqueluche.mod3 <- aov(concentracao ~ vacina, coqueluche[-25,])
> TukeyHSD(x = coqueluche.mod3, "vacina", conf.level=0.95)
Tukey multiple comparisons of means
 95% family-wise confidence level

Fit: aov(formula = concentracao ~ vacina, data = coqueluche[-25, ])
$vacina
      diff      lwr      upr      p adj
DAPV-APV  0.07097887 -0.6264043  0.7683621  0.9680650
WCV-APV  -0.85082759 -1.5538061 -0.1478490  0.0135082
WCV-DAPV -0.92180645 -1.6131583 -0.2304546  0.0057456
            
```

DAPV – APV contém 0

- √ Não há diferença entre vacinas DAPV e APV
- √ Grupo controle diferente dos grupos tratamento

114



Suposições Subjacentes no Teste F

- Independência das amostras:
 - √ Suposição crucial
 - √ Em geral, só sabemos que ela é verdadeira quando as amostras consistem em indivíduos ou objetos ou processos fisicamente não relacionados
 - √ Dados emparelhados podem ser incorretamente analisados como se fossem provenientes de amostras independentes

115



- Dados normalmente distribuídos
 - √ Teste F com robustez semelhante a do teste t para 2 amostras
 - Especialmente, quando tamanhos das amostras são muito semelhantes

116



- Homocedasticidade:
 - √ Mesmo nível de variabilidade subjacente (variância ou desvio padrão) em cada grupo
 - √ Regra prática (conservadora):
 - Desvios desta hipótese não prejudicarão a análise se a razão do maior desvio padrão para o menor não for maior que 2
 - √ Embora o teste F seja razoavelmente robusto diante da heterocedasticidade, os IC's não o são
 - IC's longos demais para grupos menos variáveis
 - IC's estreitos demais para grupos mais variáveis
 - √ Solução:
 - IC's para as médias individuais e para as diferenças

117



- O que fazer se as suposições forem gravemente violadas?
 - √ Opções discutidas para o teste t
 - √ Teste não paramétrico alternativo para teste F
 - Teste de Kruskal-Wallis
 - √ Alternativas computacionais para comparação de mais de duas médias sem suposição de homocedasticidade

Pesquisa Quantitativa - 2016

118



Testes para Diferenças de Dispersão

- Testes baseados nos desvios padrão são suspeitos
 - √ Muito sensíveis à não normalidade dos dados
- Testes não paramétricos robustos para testar se as populações têm dispersão diferentes
 - √ Utilizam outra medida de dispersão

Pesquisa Quantitativa - 2016

119



Teste de Levene

- Utiliza desvios absolutos
 - √ Variância utiliza desvios quadráticos
- Calcula-se para cada grupo:
$$y_{ij} = |x_{ij} - \bar{x}_i|.$$
 - √ Com dispersão maior num grupo do que em outro
 - Desvio absolutos médio será maior

Pesquisa Quantitativa - 2016

120



- Procedimento:
 - √ Usar teste F para testar se a média verdadeira dos desvios absolutos (y_{ij}) são iguais para todos os grupos
 - É o mesmo que testar a igualdade das dispersões
- Versão robusta do teste de Levene
 - √ Usa mediana amostral no cálculo dos desvios (Desvios medianos)
 - √ Aplica-se Anova nos desvios medianos

Pesquisa Quantitativa - 2016

121

Exemplo

- Vacina contra coqueluche
- ✓ Teste de Levene

```

> library("car")# para o comando do teste de Levene
> # teste robusto de Levene
> leveneTest(concentracao ~ vacina, data = coqueluche, center = median)

Levene's Test for Homogeneity of Variance (center = median)
  Df F value Pr(>F)
group 2  5.4234 0.00601 **
    88
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
    
```

✓ Sinaliza uma forte evidência de pelo menos uma diferença nas dispersões dos grupos

122

- Box-plot :

- ✓ Grupo de controle parece muito mais variável do que os grupos de tratamento
- ✓ Seu desvio padrão é cerca de 2 vezes maior
 - Poderíamos até confiar no teste F
- ✓ Contudo, não confiaríamos nos IC's obtidos a partir do programa Anova com um fator

123

Exemplo – Verificação das Suposições

- Comparação de quatro métodos de leitura

Gráfico de Pontos
Habilidade de Leitura

- ✓ Desvios padrão amostrais são muito semelhantes
 - Razão maior/menor < 2
- ✓ Gráficos de pontos não evidencia comportamento não normal severo
- ✓ Preocupação:
 - Alguma aglomeração em “Mapas”
 - Maior observação “Scan” é atípico? (mas variação é a mesma de outros)

Grupos	\bar{x}	s_x
Ambos	1,459	1,544
Mapa	1,233	1,441
Scan	0,914	1,302
Nenhum	-0,556	1,135

124

- Conclusão:
 - ✓ Não se observa nenhuma violação importante das suposições no modelo Anova
 - ✓ Resultados anteriores poderiam ser confirmados

125

• Verificação formal da homocedasticidade

√ Teste de Levene:

```
> library("car")# para o comando do teste de Levene
> # teste robusto de Levene
> leveneTest(aumento ~ metodo, data = leitura, center = median)
```

Levene's Test for Homogeneity of Variance (center = median)

Df	F value	Pr(>F)
group 3	0.8733	0.4618
46		

√ P-valor do teste confirma a avaliação de homocedasticidade (variâncias iguais em todos os grupos)

126

Investigações Adicionais da Adequação do Modelo

- Modelo de população: $X_{ij} \sim N(\mu_i, \sigma_i), j = 1, 2, \dots, n_i$
 $i = 1, 2, \dots, k.$
- Modelo de Medição: $X_{ij} = \mu_i + \epsilon_{ij}$
 $\epsilon_{ij} \sim N(0, \sigma_i).$

√ μ_i : média verdadeira do grupo i

√ ϵ_{ij} : perturbações (erros) aleatórias

127

- Erros e resíduos:
 - √ $U_{ij} = X_{ij} - \mu_i$: erro (perturbação)
 - distância entre as observações e suas médias
 - √ $\hat{u}_{ij} = x_{ij} - \bar{x}_{ij}$: resíduo
 - Estima a distância verdadeira
- Análise dos resíduos:
 - √ \hat{u}_{ij} vs. grupo i
 - √ Gráfico de normalidade de todos os resíduos

128

- \hat{u}_{ij} vs. grupo i
 - √ Para pesquisar diferenças nas dispersões entre grupos

Métodos de Leitura
Dados Originais

Métodos de Leitura
Resíduos

√ Pontos deslocados (médias no mesmo nível 0)


√ Gráfico não apresenta indícios de heterocedasticidade

- Teste de Levene formalizou essa indicação

129

- Gráfico de normalidade de todos os \hat{u}_{ij} :
 ✓ Se adotada a hipótese de homocedasticidade

Gráfico de Normalidade
Métodos de Leitura



```
> shapiro.test(leitura.mod$residuals)
Shapiro-Wilk normality test
data: leitura.mod$residuals
W = 0.98346, p-value = 0.704
```

Teste não apresenta qualquer evidência contra a suposição de normalidade

✓ Gráfico de probabilidade normal dos resíduos indica que eles parecem bem comportados

130

Exemplo

- Vacinas contra coqueluche:
 ✓ Pressuposto de homocedasticidade

```
> library("car")# para o comando do teste de Levene
> # teste robusto de Levene
> leveneTest(concentracao ~ vacina, data = coqueluche, center = median)


Levene's Test for Homogeneity of Variance (center = median)
Df F value Pr(>F)
group 2 5.4234 0.00601 **
      88
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

✓ Teste de Levene apresenta forte evidência de violação da hipótese de homocedasticidade


132

- \hat{u}_{ij} vs. grupo i
 ✓ Pesquisa gráfica de diferenças nas dispersões

Comparação de Vacinas
Dados Originias



Comparação de Vacinas
Resíduos




✓ Grupo controle (WCV) com maior dispersão
 ✓ Gráfico apresenta indícios de heterocedasticidade
 – Teste de Levene formalizou essa indicação

133

- Gráfico de normalidade de todos os \hat{u}_{ij} :
 ✓ Se adotada a hipótese de homocedasticidade

Gráfico de Normalidade
Vacinas Coqueluche



```
> shapiro.test(coqueluche.mod2$residuals)
Shapiro-Wilk normality test
data: coqueluche.mod2$residuals
W = 0.98133, p-value = 0.2231
```

Teste não apresenta qualquer evidência contra a suposição de normalidade

✓ Gráfico de probabilidade normal dos resíduos indica que eles parecem bem comportados

134

Teste de Kruskal-Wallis



- Equivalente não paramétrico para ANOVA
 - √ Variável medida em escala ordinal ou numérica
- Usado se:
 - √ Houver pressupostos comprometidos
 - normalidade e homocedasticidade.
 - √ Quantidades mínimas
 - Sujeitos: 5
 - Grupos: 3

135

Pesquisa Quantitativa - 2016



- Uso:
 - √ Verificar se as amostras têm a mesma distribuição.
- Procedimento:
 - √ Baseado nos postos (ranks) das observações em cada grupo.
- Hipóteses:
 - √ H_0 : grupos têm a mesma distribuição
 - √ H_1 : grupos não têm a mesma distribuição
- Se todas distribuições tiverem mesma forma
 - √ H_0 será a igualdade das medianas dos grupos

136

Pesquisa Quantitativa - 2016

Exemplo



- Vacina contra coqueluche
 - √ Teste de Kruskal-Wallis

```

> kruskal.test(concentracao ~ vacina, data = coqueluche)

Kruskal-Wallis rank sum test

data:  concentracao by vacina
Kruskal-Wallis chi-squared = 6.3843, df = 2, p-value = 0.04108
    
```

- √ Evidência contra a hipótese de mesma distribuição dos grupos de vacinas

137

Pesquisa Quantitativa - 2016

Referências

Bibliografia Recomendada



- AGRESTI, A.; FINLAY, B. *Métodos estatísticos para as ciências sociais*. Penso, 2012.
- MOORE, D. S.; MCCABE, G. P.; DUCKWORTH, W. M.; SLOVE, S. L. *A prática da estatística empresarial: como usar dados para tomar decisões*. LTC, 2006.
- WILD, J. W.; SEBER, G. A. F. *Encontros com o acaso: um primeiro curso de análise de dados e inferência*. LTC, 2004.