

IBI5086
Introdução a Métodos Estatísticos
para a Bioinformática

Profa. Júlia Maria Pavan Soler
pavan@ime.usp.br

IME/USP – 2º Semestre/2020

Programa

- Álgebra linear básica: cálculo matricial, determinantes, sistemas lineares, produto interno, norma, ortogonalidade, autovalores e autovetores
- Estrutura de Dados: variáveis (resposta, explicativa), unidades amostrais e experimentais

1.1. Comparação de Grupos (2 ou mais): Testes Clássicos (teste t, Wilcoxon, modelos ANOVA) e Testes de Aleatorização, Comparações Múltiplas

1.2. Análise de Tabelas de Contingência: Testes Qui-Quadrado, Regressão Logística.

2. Análise Multivariada de Dados: Componentes Principais, Análise Discriminante e Classificação, Correlação Canônica, modelos MANOVA

3. Simulação de Monte Carlo, Intervalos de Confiança Bootstrap

Planejamento de Experimentos e Modelos ANOVA (Análise de Variância)

$$Y = f(X) + e$$

Variável resposta
quantitativa

Fatores
(preditores)

Erro
aleatório

Veremos os seguintes
Planejamentos:

- Estrutura dos Fatores (Tratamentos – variável X):
 - Delineamento com Um único Fator e seus níveis
 - Delineamento Fatorial Cruzado
 - Delineamento Fatorial Hierárquico (aninhado, *nested*)
- Estrutura das unidades amostrais (Aleatorização dos Tratamentos)
 - Delineamento Completamente Aleatorizado (DCA)
 - Delineamento Aleatorizado em Blocos Completos (DABC):



- Delineamento com uma Fator Aleatório

Delineamento Completamente Aleatorizado - DCA

T_1	T_2	...	T_a	← Tratamentos: 1 Fator em a níveis Fator de Efeito Fixo	
Y_{11}	Y_{12}	...	Y_{1a}	Esquema de aleatorização: atribuição completamente aleatória das unidades experimentais aos a tratamentos	
Y_{21}	Y_{22}	...	Y_{2a}		
...	...	Y_{ij}	...		← resposta da i -ésima unidade experimental exposta ao j -ésimo tratamento
Y_{n_11}	Y_{n_12}	...	Y_{n_1a}		

n_j



n_j réplicas no tratamento j

$$\sum_{j=1}^a n_j = n$$

Motivação

Considere o seguinte **delineamento completamente aleatorizado (DCA)** com um fator fixo em 4 níveis e seis réplicas por tratamento.

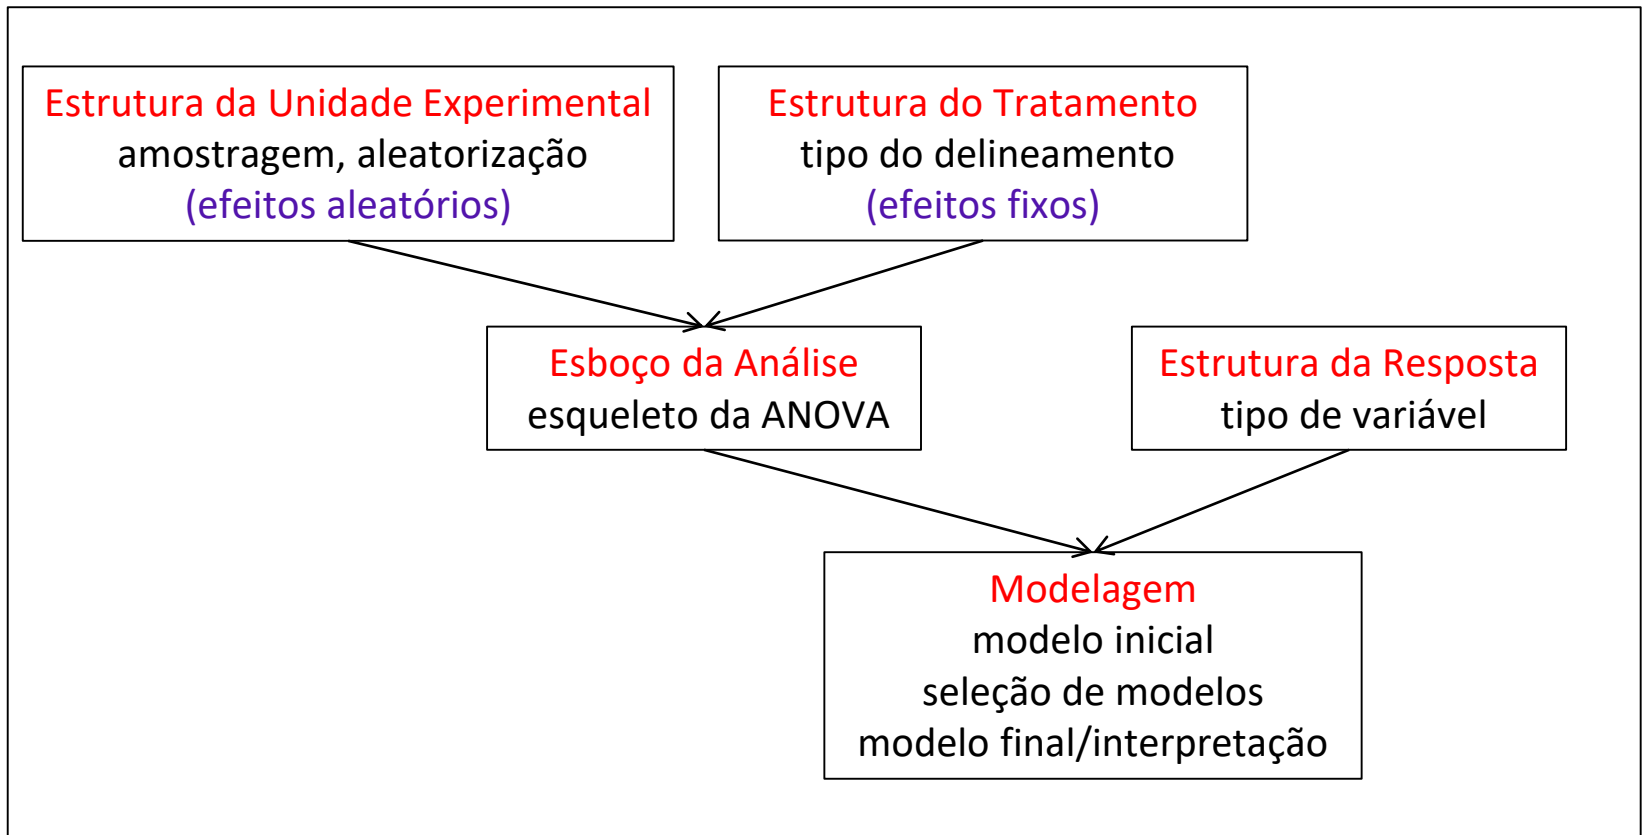
Dados: Avaliação de uma Resposta sob 4 tratamentos

T1	T2	T3	T4
6,2	12,7	7,0	8,3
4,8	11,3	4,4	7,1
3,0	9,3	3,8	11,7
5,6	9,5	5,0	10,0
7,1	11,7	5,5	8,5
4,8	15,3	3,2	12,4

Discuta o delineamento experimental e a estrutura dos dados.
Há evidência amostral para efeito de tratamento?

Planejamento e Análise de Dados

Estrutura Geral de Análise de Dados: (Goos and Gilmour, 2012)



Delimitação Completamente Aleatorizado - DCA

T1	T2	T3	T4
6,2	12,7	7,0	8,3
4,8	11,3	4,4	7,1
3,0	9,3	3,8	11,7
5,6	9,5	5,0	10,0
7,1	11,7	5,5	8,5
4,8	15,3	3,2	12,4

- ✓ **Estrutura das Unidades Experimentais**
 - ⇒ 24 unidades amostrais completamente aleatorizadas a 4 tratamentos
 - ⇒ 6 réplicas em cada tratamento (amostras balanceadas)
- ✓ **Estrutura de Tratamentos**
 - ⇒ 1 Fator (Tratamento) em 4 níveis
 - ⇒ Fator Fixo: T1, T2, T3 e T4
- ✓ **Estrutura da variável resposta**
 - ⇒ Uma única variável quantitativa de interesse

Estatísticas Descritivas

T1	T2	T3	T4
6,2	12,7	7,0	8,3
4,8	11,3	4,4	7,1
3,0	9,3	3,8	11,7
5,6	9,5	5,0	10,0
7,1	11,7	5,5	8,5
4,8	15,3	3,2	12,4

**Variabilidade
ENTRE Médias**


**Variabilidade
DENTRO dos
Tratamentos**

Variable	N	Mean	Median	TrMean	StDev	SE Mean
T1	6	5,250	5,200	5,250	1,408	0,575
T2	6	11,633	11,500	11,633	2,222	0,907
T3	6	4,817	4,700	4,817	1,348	0,550
T4	6	9,667	9,250	9,667	2,075	0,847

Variable	Minimum	Maximum	Q1	Q3
T1	3,000	7,100	4,350	6,425
T2	9,300	15,300	9,450	13,350
T3	3,200	7,000	3,650	5,875
T4	7,100	12,400	8,000	11,875

Há evidência amostral para a existência de efeito do tratamento? Discutir.

*Comparar a fonte de variação
ENTRE tratamentos com a
fonte de variação DENTRO
de tratamentos (Análise de
Variâncias – ANOVA)*



*n=6 é o tamanho amostral por grupo: Não é recomendável construir o boxplot com tão poucos pontos (em geral, para tamanhos amostrais maiores que 10)
Alternativa: Construir Dotplots!*


Modelos ANOVA (Análise de Variância)

- Considere a seguinte identidade:

$$y_{ij} = \bar{y} + (\bar{y}_j - \bar{y}) + (y_{ij} - \bar{y}_j)$$

Variável resposta	Média geral	Efeito de tratamento	Erro
----------------------	----------------	-------------------------	------

y_{ij} : resposta da unidade experimental i submetida ao j -ésimo tratamento


$$\sum_{ij} (y_{ij} - \bar{y})^2 = \sum_j n_j (\bar{y}_j - \bar{y})^2 + \sum_{ij} (y_{ij} - \bar{y}_j)^2$$

Soma de Quadrados Total	Soma de Quadrados de Tratamentos	Soma de Quadrados do Resíduo
----------------------------	--	------------------------------------

Tabela de ANOVA

DCA – Um único Fator

Fonte de Variação	Número de graus de liberdade	Soma de Quadrados	Quadrado Médio	Estat. F	Valor-p
Tratamento (Entre)	a-1	$\sum_j n_j (\bar{y}_j - \bar{y})^2$	SQTrat/(a-1)	$\frac{QMTrat}{QMRes}$	<i>p</i>
Resíduo (Dentro)	n-a	$\sum_{ij} (y_{ij} - \bar{y}_j)^2$	SQRes/(n-a)		
Total	n-1	$\sum_{ij} (y_{ij} - \bar{y})^2$			

$$F = \frac{QMTrat}{QMRes} \sim F_{(a-1), (n-a)}$$

QMResidual estima a variância de Y

$$s_c^2 = \frac{(n_1 - 1)s_1^2 + \dots + (n_a - 1)s_a^2}{n - a}$$

Tabela de ANOVA

T1	T2	T3	T4
6,2	12,7	7,0	8,3
4,8	11,3	4,4	7,1
3,0	9,3	3,8	11,7
5,6	9,5	5,0	10,0
7,1	11,7	5,5	8,5
4,8	15,3	3,2	12,4

Analysis of Variance for Resp					
Source	DF	SS	MS	F	P
Trat	3	201,45	67,15	20,59	0,000
Error	20	65,23	3,26		
Total	23	266,68			

Level	N	Mean	StDev
T1	6	5,250	1,408
T2	6	11,633	2,222
T3	6	4,817	1,348
T4	6	9,667	2,075

Pooled StDev = 1,806

Hipóteses: $H_0 : \mu_j = \mu, j = 1, \dots, a;$ $H_1 :$ Existe pelo menos uma diferença entre as médias

Suposições: Normalidade, Independência e Homocedasticidade Realizar análise de resíduos!

Conclusão: F=20,59 (p=0,000) Há evidência para a rejeição de H0

⇒ Existe pelo menos uma diferença entre as médias

Modelo ANOVA

Análise de Resíduos

Modelo Estrutural:

$$y_{ij} = \mu_j + e_{ij}$$

Modelo de Médias

$$= \mu + \tau_j + e_{ij}; \quad \sum_j \tau_j = 0$$

Modelo de Desvios de Média

$$= \begin{cases} \mu_1 + e_{i1} \\ \mu_1 + \tau_j + e_{ij}; j = 2, \dots, a \end{cases}$$

Modelo de Casela de Referência

Modelo Distribucional:

$$y_{ij} = \mu_j + e_{ij}; \quad e_{ij} \sim N(0; \sigma^2)$$

$$E(y_{ij}) = \mu_j; \quad \text{Var}(y_{ij}) = \text{Var}(e_{ij}) = \sigma^2$$

Modelo ANOVA

Análise de Resíduos

Checar as suposições do modelo:

- ✓ Normalidade
- ✓ Variância constante (homocedasticidade)
- ✓ Independência

Garantir que a estatística “F” da tabela de ANOVA tem distribuição $F(a-1, n-a)$.

Resultado importante: “Aleatorização” pode garantir isso!

$$y_{ij} = \mu_j + e_{ij}; \quad \Rightarrow \quad Y_{n \times 1} = X_{n \times a} \beta_{a \times 1} + e_{n \times 1}$$

Vetor de resposta Matriz de Panejamento Vetor de parâmetros Vetor de resíduos

ANOVA – Análises de Diagnóstico

$$y_{ij} = \bar{y}_j + (y_{ij} - \bar{y}_j)$$

\hat{y}_{ij} \hat{e}_{ij}
y ajustado resíduo

- Análises Descritivas dos Resíduos

⇒ Histogramas e box-plots dos resíduos

⇒ Quantis dos resíduos contra quantis da normal

} Distribuição simétrica?
Normalidade?

⇒ $\hat{e}_j \times \text{ordem}(\text{obs})$

erros independentes

$\hat{e}_j \times \hat{y}_j$

homocedasticidade

tendências não modeladas

ANOVA – Análises de Diagnóstico

$$\hat{e}_{ij} = y_{ij} - \hat{y}_{ij} = y_{ij} - \bar{y}_j = y_{ij} - h_{ii} y_{ij} = (1 - h_{ii}) y_{ij} \quad \text{Resíduo}$$


$$h_{ii} = X_i (X' X)^{-1} X_i$$

$$\tilde{e}_{ij} = \frac{\hat{e}_{ij}}{\sqrt{QM \text{ Res}}} \quad \text{Resíduo semi-studentizado}$$


$$r_{ij} = \frac{\hat{e}_{ij}}{\sqrt{QM \text{ Res} (1 - h_{ii})}} \quad \text{Resíduo studentizado}$$

Residual Model Diagnostics


Normal Plot of Residuals




I Chart of Residuals



Histogram of Residuals



Residuals vs. Fits



**E quando os dados não satisfazem as suposições impostas pelo modelo?
Quais são as medidas remédio?**

ANOVA – Análises de Diagnóstico

- Teste para a verificação da Normalidade
Teste de Shapiro-Wilk, Teste de Kolmogorov-Smirnov
- Testes para a verificação da homocedasticidade (variâncias homogêneas)
Teste de Bartlet (sensível a desvios da Normalidade)
Teste de Levene (robusto)

Hipótese de Interesse

$$y_{ij} = \mu_j + e_{ij} = \mu + \tau_j + e_{ij}; \quad e_{ij} \sim N(0; \sigma^2)$$

$$\left\{ \begin{array}{l} \mathbf{H}_0: \mu_j = \mu \Leftrightarrow \tau_j = 0; \quad j = 1, \dots, a \\ \mathbf{H}_1: \text{existe pelo menos uma diferença} \end{array} \right.$$

Existe evidência de diferenças entre as médias ?



As diferenças ENTRE médias são maiores que a variação DENTRO dos tratamentos ?

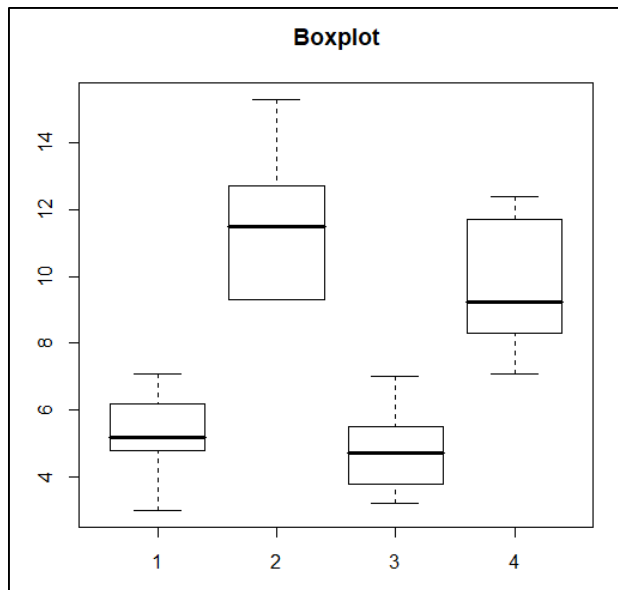
No caso da rejeição de H_0 ($p \leq \alpha$) e da análise de diagnóstico indicar que as premissas estão satisfeitas, o próximo passo da análise é a realização de “**comparações múltiplas**” entre as médias.

Comparações Múltiplas

Considerando os dados do exemplo:

$$\begin{cases} H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu & \Leftrightarrow \tau_1 = \dots = \tau_4 = 0 \\ H_1 : \exists \text{ pelo menos uma diferença entre as médias} \end{cases}$$

Conclusão: $F=20,59$ $p=0,000 \Rightarrow$ há evidência amostral para a rejeição de $H_0 \Rightarrow$ há pelo menos uma diferença entre as médias



Discuta as limitações envolvidas na realização de testes “t” individuais para todas as possíveis comparações entre duas médias!

Comparações Múltiplas

- **Intervalo de Confiança para μ_j ($j=1, \dots, a$)**

$$\bar{y}_j - t_{(\alpha/2; r-1)} \sqrt{\frac{QM Res}{n_j}} \leq \mu_j \leq \bar{y}_j + t_{(\alpha/2; r-1)} \sqrt{\frac{QM Res}{n_j}}$$

- **Intervalo de Confiança para a Diferença entre Médias**

$$\left(\bar{y}_j - \bar{y}_k \right) \pm t_{(\alpha/2; n_j+n_k-2)} \sqrt{QM Res \left(\frac{1}{n_j} + \frac{1}{n_k} \right)}$$

Qual é o nível de confiança global (ou, equivalentemente, o nível de significância global) quando são realizadas muitos testes simultaneamente (muitas comparações entre pares de médias)?

Tabela de ANOVA

One-way ANOVA: Resp versus Trat

Analysis of Variance for Resp

Source	DF	SS	MS	F	P
Trat	3	201,45	67,15	20,59	0,000
Error	20	65,23	3,26		
Total	23	266,68			

Individual 95% CIs For Mean
Based on Pooled StDev

Level	N	Mean	StDev	-----+-----+-----+-----		
T1	6	5,250	1,408	(-----*-----)		
T2	6	11,633	2,222		(-----*-----)	
T3	6	4,817	1,348	(-----*-----)		
T4	6	9,667	2,075		(-----*-----)	
Pooled StDev = 1,806				-----+-----+-----+-----		
				6,0	9,0	12,0

Defina H a hipótese a ser testada via a estatística F

Suposições envolvidas

Conclusão

Comparações Múltiplas

➔ **Nível de Significância Único para a Família de Comparações**

4 Tratamentos μ_1 μ_2 μ_3 μ_4

**Comparações
de interesse:**

$$\left\{ \begin{array}{l} H_{01} : \mu_1 = \mu_2 \quad \Rightarrow \quad \alpha_1 \\ H_{02} : \mu_1 = \mu_3 \quad \Rightarrow \quad \alpha_2 \\ H_{03} : \mu_1 = \mu_4 \quad \Rightarrow \quad \alpha_3 \\ H_{04} : \mu_2 = \mu_3 \quad \Rightarrow \quad \alpha_4 \\ H_{05} : \mu_2 = \mu_4 \quad \Rightarrow \quad \alpha_5 \\ H_{06} : \mu_3 = \mu_4 \quad \Rightarrow \quad \alpha_6 \end{array} \right.$$

$\alpha?$

Para testar as 6 hipóteses, qual é o nível de significância global para esta família de comparações entre pares de medias?

Comparações Múltiplas

- **Comparações aos Pares** (pares de médias sendo comparadas)

$$H : \mu_j = \mu_k \quad \Leftrightarrow \quad \mu_j - \mu_k = 0$$

- **Contrastes entre Médias**

$$H : \mu_1 = \frac{\mu_2 + \mu_3}{2} \quad \Leftrightarrow \quad \mu_1 - \frac{\mu_2 + \mu_3}{2} = 0$$

- **Combinações Lineares de Médias**

$$H : 0,30 \mu_1 + 0,20 \mu_2 + 0,50 \mu_3 = 0$$

Comparações Múltiplas

- **Método de Tukey**

$$H : \mu_j = \mu_k \quad ; \quad j \neq k \quad \Rightarrow \quad \binom{a}{2} = \frac{a(a-1)}{2} \text{ comparações}$$

Intervalo de Confiança Simultâneo de Tukey

$$\left(\bar{Y}_j - \bar{Y}_k \right) \pm q_{a;v;\alpha/2} s_c \sqrt{\frac{1}{n}}$$

↓
n-a

Delineamento Balanceado

$q_{a;v;\alpha/2}$: range studentizado (valor tabelado) **Critério HSD (Honest Significant Difference)**

$$\left(\bar{Y}_j - \bar{Y}_k \right) \pm \frac{q_{a;v;\alpha/2}}{\sqrt{2}} s_c \sqrt{\frac{1}{n_j} + \frac{1}{n_k}}$$

Não Balanceado

Table D.8: Percent points for the Studentized range.


Table entries are $q_{.05}(K, \nu)$.

ν	K												
	2	3	4	5	6	7	8	9	10	15	20	30	50
1	18.0	27.0	32.8	37.1	40.4	43.1	45.4	47.4	49.1	55.4	59.6	65.1	71.7
2	6.09	8.33	9.80	10.9	11.7	12.4	13.0	13.5	14.0	15.7	16.8	18.3	20.0
3	4.50	5.91	6.82	7.50	8.04	8.48	8.85	9.18	9.46	10.5	11.2	12.2	13.4
4	3.93	5.04	5.76	6.29	6.71	7.05	7.35	7.60	7.83	8.66	9.23	10.0	10.9
5	3.64	4.60	5.22	5.67	6.03	6.33	6.58	6.80	6.99	7.72	8.21	8.87	9.67
6	3.46	4.34	4.90	5.30	5.63	5.90	6.12	6.32	6.49	7.14	7.59	8.19	8.91
7	3.34	4.16	4.68	5.06	5.36	5.61	5.82	6.00	6.16	6.76	7.17	7.73	8.40
8	3.26	4.04	4.53	4.89	5.17	5.40	5.60	5.77	5.92	6.48	6.87	7.40	8.03
9	3.20	3.95	4.41	4.76	5.02	5.24	5.43	5.59	5.74	6.28	6.64	7.14	7.75
10	3.15	3.88	4.33	4.65	4.91	5.12	5.30	5.46	5.60	6.11	6.47	6.95	7.53
11	3.11	3.82	4.26	4.57	4.82	5.03	5.20	5.35	5.49	5.98	6.33	6.79	7.35
12	3.08	3.77	4.20	4.51	4.75	4.95	5.12	5.27	5.39	5.88	6.21	6.66	7.21
13	3.06	3.73	4.15	4.45	4.69	4.88	5.05	5.19	5.32	5.79	6.11	6.55	7.08
14	3.03	3.70	4.11	4.41	4.64	4.83	4.99	5.13	5.25	5.71	6.03	6.46	6.98
15	3.01	3.67	4.08	4.37	4.59	4.78	4.94	5.08	5.20	5.65	5.96	6.38	6.89
16	3.00	3.65	4.05	4.33	4.56	4.74	4.90	5.03	5.15	5.59	5.90	6.31	6.81
17	2.98	3.63	4.02	4.30	4.52	4.70	4.86	4.99	5.11	5.54	5.84	6.25	6.74
18	2.97	3.61	4.00	4.28	4.49	4.67	4.82	4.96	5.07	5.50	5.79	6.20	6.68
19	2.96	3.59	3.98	4.25	4.47	4.65	4.79	4.92	5.04	5.46	5.75	6.15	6.63
20	2.95	3.58	3.96	4.23	4.45	4.62	4.77	4.90	5.01	5.43	5.71	6.10	6.58
21	2.94	3.56	3.94	4.21	4.42	4.60	4.74	4.87	4.98	5.40	5.68	6.07	6.53
22	2.93	3.55	3.93	4.20	4.41	4.58	4.72	4.85	4.96	5.37	5.65	6.03	6.49
23	2.93	3.54	3.91	4.18	4.39	4.56	4.70	4.83	4.94	5.34	5.62	6.00	6.45
24	2.92	3.53	3.90	4.17	4.37	4.54	4.68	4.81	4.92	5.32	5.59	5.97	6.42
25	2.91	3.52	3.89	4.15	4.36	4.53	4.67	4.79	4.90	5.30	5.57	5.94	6.39
26	2.91	3.51	3.88	4.14	4.35	4.51	4.65	4.77	4.88	5.28	5.55	5.92	6.36
27	2.90	3.51	3.87	4.13	4.33	4.50	4.64	4.76	4.86	5.26	5.53	5.89	6.34
28	2.90	3.50	3.86	4.12	4.32	4.49	4.62	4.74	4.85	5.24	5.51	5.87	6.31
29	2.89	3.49	3.85	4.11	4.31	4.47	4.61	4.73	4.84	5.23	5.49	5.85	6.29
30	2.89	3.49	3.85	4.10	4.30	4.46	4.60	4.72	4.82	5.21	5.47	5.83	6.27
35	2.87	3.46	3.81	4.07	4.26	4.42	4.56	4.67	4.77	5.15	5.41	5.76	6.18
40	2.86	3.44	3.79	4.04	4.23	4.39	4.52	4.63	4.73	5.11	5.36	5.70	6.11
45	2.85	3.43	3.77	4.02	4.21	4.36	4.49	4.61	4.70	5.07	5.32	5.66	6.06
50	2.84	3.42	3.76	4.00	4.19	4.34	4.47	4.58	4.68	5.04	5.29	5.62	6.02
100	2.81	3.36	3.70	3.93	4.11	4.26	4.38	4.48	4.58	4.92	5.15	5.46	5.83
∞	2.77	3.31	3.63	3.86	4.03	4.17	4.29	4.39	4.47	4.80	5.01	5.30	5.65

Comparações Múltiplas

Intervalos de Confiança Simultâneos de Tukey a 95%

	1	2	3
2	-9.303 -3.464	$\mu_1 < \mu_2$	
3	-2.486 3.353	$\mu_1 = \mu_3$	$\mu_2 > \mu_3$ 3.897 9.736
4	-7.336 -1.497	$\mu_1 < \mu_4$	$\mu_2 = \mu_4$ -0.953 4.886
			$\mu_3 < \mu_4$ -7.770 -1.930




Conclusão? $(\mu_2 = \mu_4)^* > (\mu_1 = \mu_3)$ Diferenças significantes a um nível de significância global igual a 5%

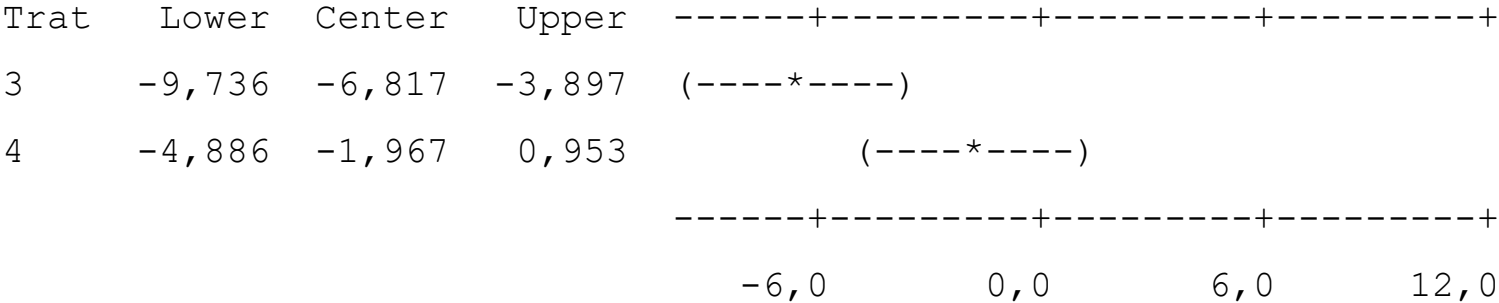
Diferentes apresentações dos ICS:

Tukey 95,0% Simultaneous Confidence Intervals


Trat = 1 subtracted from:



Trat = 2 subtracted from:



Trat = 3 subtracted from:



Dados do Exemplo

```
Tukey multiple comparisons of means
```

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

```
Fit: aov(formula = Resp ~ Trat, data = dados)
```

```
$Trat
```

	diff	lwr	upr	p adj
2-1	6.3500000	3.411858	9.288142	0.0000360
3-1	-0.4333333	-3.371476	2.504809	0.9756358
4-1	4.4166667	1.478524	7.354809	0.0022547
3-2	-6.7833333	-9.721476	-3.845191	0.0000149
4-2	-1.9333333	-4.871476	1.004809	0.2840071
4-3	4.8500000	1.911858	7.788142	0.0008789

Conclusão? $(\mu_2 = \mu_4)^* > (\mu_1 = \mu_3)$ Diferenças significantes a um nível de significância global igual a 5%

Comparações Múltiplas

- **Método de Contrastes Ortogonais**
- **Método de Dunnett**
- **Método de Scheffé**
- **Método de Bonferroni**
- **Método FDR**

Comparações Múltiplas


- **Método de Bonferroni**

$$H : \sum_{j=1}^a c_j \mu_j = 0 \quad ; \quad \sum c_j = 0$$

$$\sum_{j=1}^a c_j \bar{Y}_j \pm B \sqrt{\hat{V} \left(\sum c_j \bar{Y}_j \right)}$$

Intervalo de Confiança Simultâneo de Bonferroni (é mais conservador que o de Tukey)

$$B = t_{(n-a);(1-\alpha/2K)}$$



Correção de Bonferroni para “K” múltiplos testes

Comparações Múltiplas

Correções para Múltiplos Testes

Rejeitar H_{0j} se:	Método
$p_{(k)} < \alpha / K$	Correção de <u>Bonferroni</u> para múltiplos testes
$p_{(j)} < \alpha / (K - j + 1)$ <i>para todo $j = 1, \dots, k$</i>	Correção de <u>Holm</u> (Controle “forte” da taxa de erro para os múltiplos testes)
$p_{(j)} < j\alpha / K$ <i>para algum $j \geq k$</i>	Correção FDR (Taxa de Falsa Descoberta): <u>Benjamini-Hochberg</u> Controle menos conservador da taxa de erro para os múltiplos testes)

K : número total de testes α : nível de significância global fixado

$p_{(j)}$: nível descritivo (p-valor) ordenado, $p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(K)}$

	pt.valor	adjustb	adjusth	adjustfdr
[1,]	8.792659e-05	0.0005275596	0.0005275596	0.0004928938
[2,]	1.642979e-04	0.0009857876	0.0008214896	0.0004928938
[3,]	7.230700e-04	0.0043384199	0.0028922799	0.0014461400
[4,]	1.528013e-03	0.0091680765	0.0045840383	0.0022920191
[5,]	1.539205e-01	0.9235227555	0.3078409185	0.1847045511
[6,]	5.980538e-01	1.0000000000	0.5980537708	0.5980537708

Comparações Múltiplas


Correções para Múltiplos Testes

Valores-p dos Testes “t” bicaudal, Bolferroni, Holm e FDR (False Discover Rate)

	pt.valor	adjustb	adjusth	adjustfdr
T1-T2	8.792659e-05	0.0005275596	0.0005275596	0.0004928938
T1-T3	1.642979e-04	0.0009857876	0.0008214896	0.0004928938
T1-T4	7.230700e-04	0.0043384199	0.0028922799	0.0014461400
T2-T3	1.528013e-03	0.0091680765	0.0045840383	0.0022920191
T2-T4	1.539205e-01	0.9235227555	0.3078409185	0.1847045511
T3-T4	5.980538e-01	1.0000000000	0.5980537708	0.5980537708

Gráfico Vulcão

Distribuição dos valores-p de acordo com a expressão gênica diferencial entre dois tecidos.



Necessidade de adotar uma correção para os múltiplos testes.

Volcano plot for t-test comparing two groups. Spiked-in genes are denoted with blue. Among the rest of the genes, those with p-value < 0.01 are denoted with red.

Referência Bibliográfica

Box, G.E.; Hunter, W.G. and Hunter, J.S. (1978). *Statistics for Experimenters. An Introduction to Designs, Data Analysis and Model Building*. John Wiley & Sons.

→ Neter, J.K.; Kutner, M; Wasserman, W. and Nachtsheim, C.J. (2016). *Applied Linear Statistical Models*. 4th ed., Times Mirror Higher Education Group.

Oehlert, GW. *A First Course in Design and Analysis of Experiments*. Univ. of Minnesota, Licensed by Creative Commons, 2010.