

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

- Estrutura dos Fatores (Tratamentos – variável X):

- ✓ **Delineamento com Um único Fator e seus níveis**

Já vimos:

- Delineamento Fatorial Cruzado

- Delineamento Fatorial Hierárquico (aninhado, *nested*)

- Estrutura das unidades amostrais (Aleatorização dos Tratamentos)

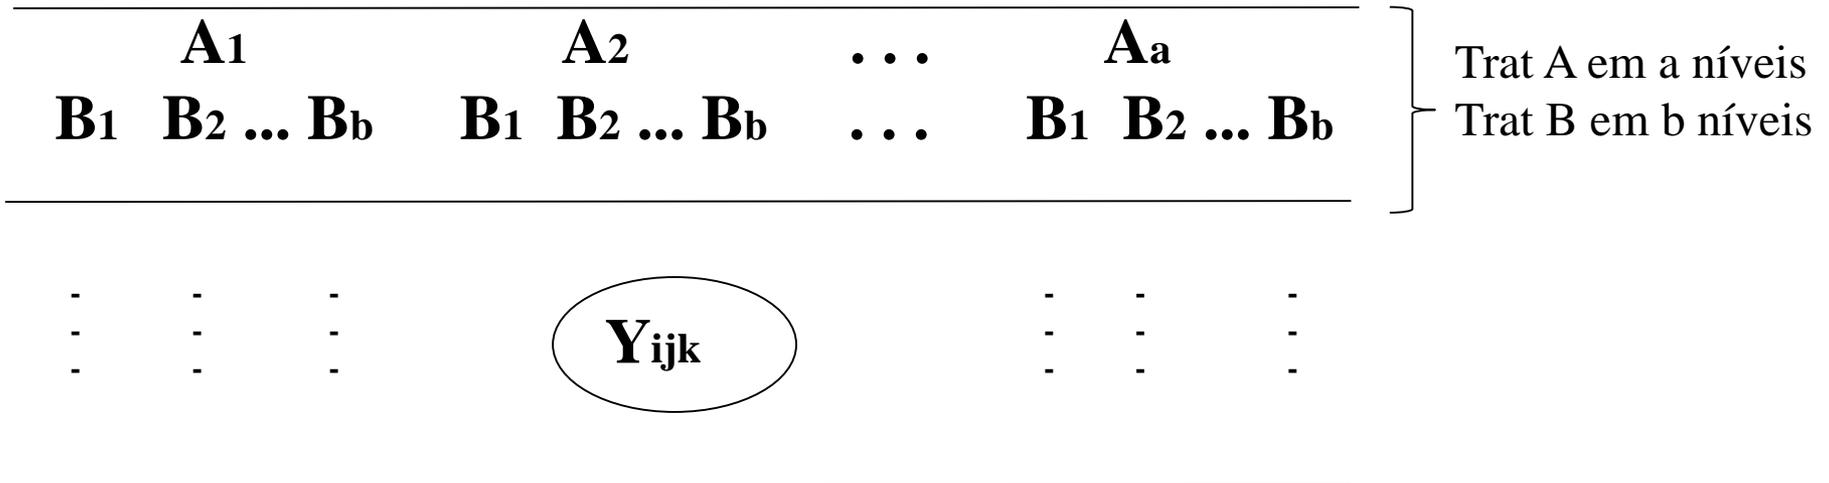
- ✓ **Delineamento Completamente Aleatorizado (DCA)**

- Delineamento Aleatorizado em Blocos Completos (DABC):

- Delineamento com uma Fator Aleatório

DCA Fatorial

Estrutura de aleatorização ↑
Estrutura de Tratamentos ↑



- Y_{ijk} : resposta do i-ésimo indivíduo submetido ao j-ésimo nível do tratamento A e k-ésimo nível do tratamento B
- Estrutura de Tratamento \Rightarrow 2 ou + Fatores Cruzados (**Fatorial a x b**)
- **Delineamento Completamente Aleatorizado** (DCA) com réplicas em cada combinação dos níveis dos fatores

Exemplo

Dados: Uma resposta de interesse é avaliada em unidades experimentais (n=24) submetidas a dois tratamentos (A e B), cada um em dois níveis (Baixo e Alto)

T1	T2	T3	T4	← Um Fator em 4 níveis
Baixo		Alto		← Trat A (Fator1)
Baixo	Alto	Baixo	Alto	← Trat B (Fator2)
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	

A atribuição aleatória dos Tratamentos (4) às unidades experimentais (n=24).

Delineamento balanceado com 6 réplicas

Exemplo: DCA com 1 Fator em 4 níveis

Passo1: Entender o estudo

Passo2: Adotar um modelo teórico de análise

Passo3: Ajuste do modelo e análise de diagnóstico

Dados de um DCA com 1 Fator em 4 níveis

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

$$H_0 : \mu_j = \mu$$

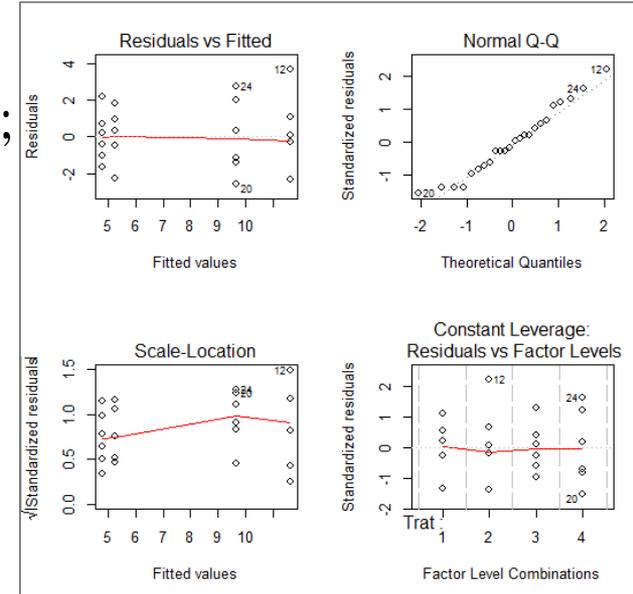
H_1 : Existe pelo menos uma diferença

$$y_{ij} = \mu_j + e_{ij} = \mu_1 + \tau_j + e_{ij};$$

$$j = 2, 3, 4; i = 1, \dots, 6$$

$$e_{ij} \stackrel{iid}{\sim} N(0; \sigma^2);$$

$$y_{ij} \sim N(\mu_j; \sigma^2)$$



Passo4: Análise dos resultados e Conclusão

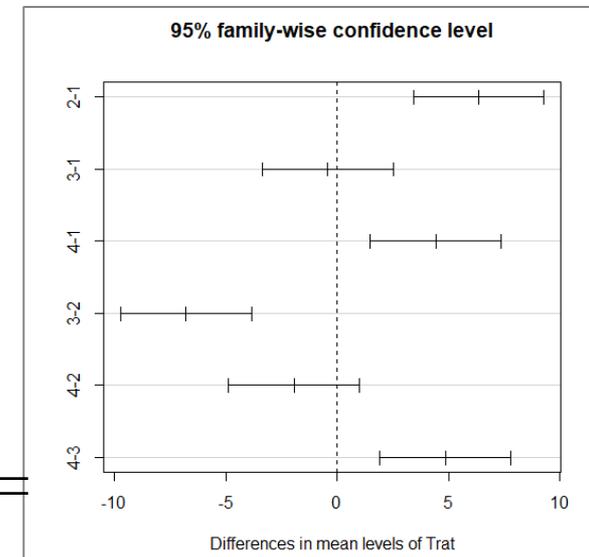
Analysis of Variance Table

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Trat	3	199.937	66.646	20.16	2.924e-06
Residuals	20	66.117	3.306		

Coefficients

(Intercept)	Trat2	Trat3	Trat4
5.250	6.350	-0.433	4.417

$$(\mu_2 = \mu_4) > (\mu_1 = \mu_3) \leftarrow$$



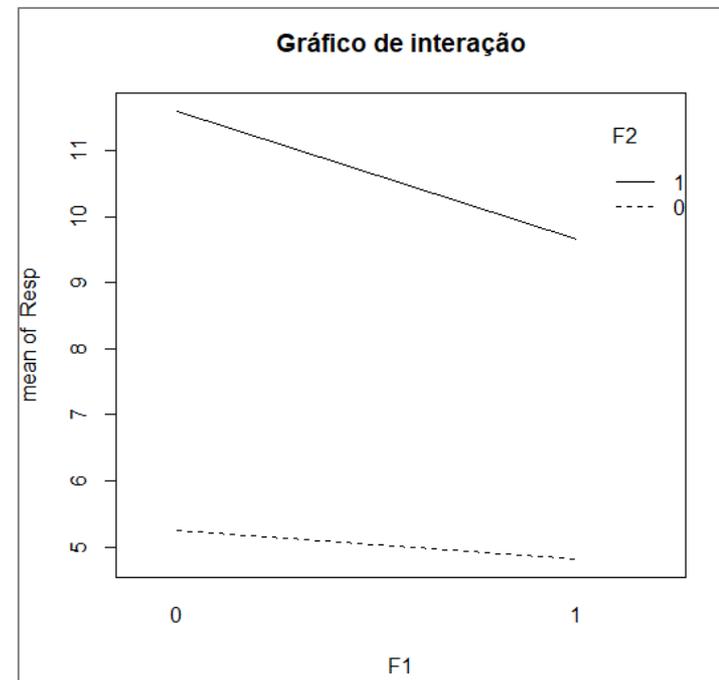
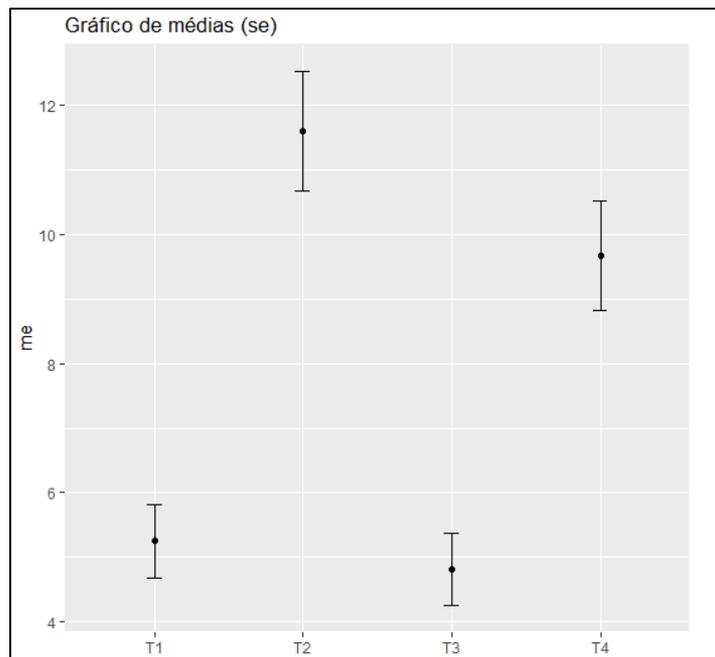
DCA – Estrutura de Tratamento

Dados de um DCA com 1 Fator em 4 níveis

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

1 Fator em 4 níveis \Rightarrow Fatorial 2x2

T1	T2	T3	T4	
Baixo	Baixo	Alto	Alto	Trat A (F1)
Baixo	Alto	Baixo	Alto	Trat B (F2)



DCA – Estrutura de Tratamento

DCA com 1 Fator em J níveis:

$$y_{ij} = \mu_j + e_{ij} = \mu_1 + \tau_j + e_{ij};$$

$$e_{ij} \stackrel{iid}{\sim} N(0; \sigma^2); \quad y_{ij} \stackrel{ind}{\sim} N(\mu_j; \sigma^2); \quad j = 1, \dots, J; \quad i = 1, \dots, n_j = r$$

DCA Fatorial axb:

$$y_{ijk} = \mu_{jk} + e_{ijk} = \mu_{00} + \tau_j + \beta_k + \gamma_{jk} + e_{ijk};$$

$$e_{ijk} \stackrel{iid}{\sim} N(0; \sigma^2); \quad y_{ijk} \stackrel{ind}{\sim} N(\mu_{jk}; \sigma^2); \quad j = 1, \dots, a; k = 1, \dots, b; \quad i = 1, \dots, n_{jk} = r$$



J = axb

y_{ijk} : resposta da unidade i submetida aos níveis j do Fator A e k do Fator B

μ_{00} : valor esperado da resposta para o Trat de referência (A e B nos níveis baixos)

τ_j : desvio em relação a μ_{00} devido ao **efeito (principal) do Fator A** no nível j

β_k : desvio em relação a μ_{00} devido ao **efeito (principal) do Fator B** no nível k

γ_{jk} : **efeito de interação entre os fatores A e B**. É o desvio do efeito aditivo dos fatores

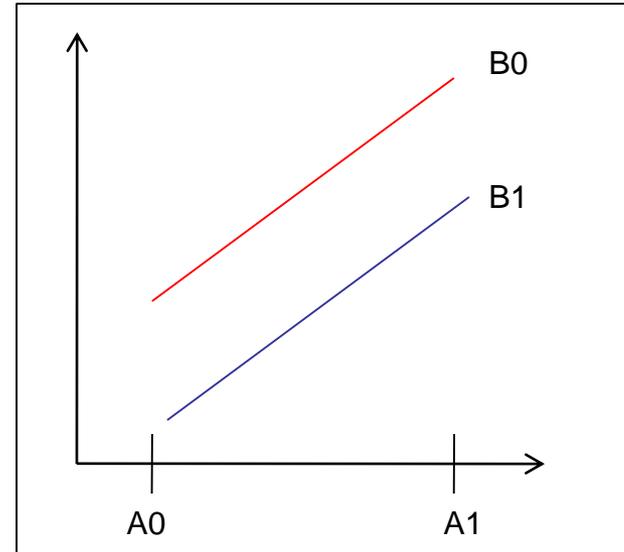
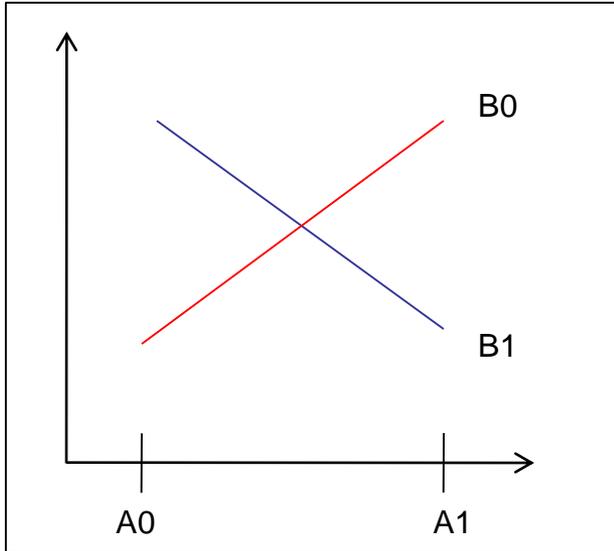
e_{ijk} : efeito aleatório, suposto normal, independente e homocedástico.

Perfis de Médias – Efeito de Interação Fatorial 2x2

Existência de Interação

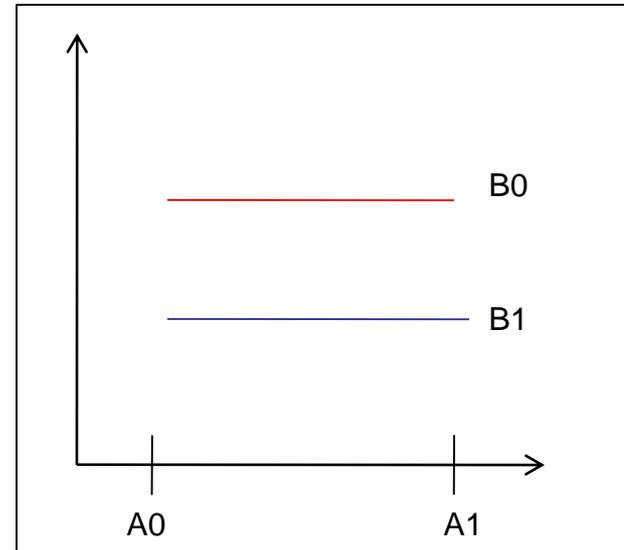
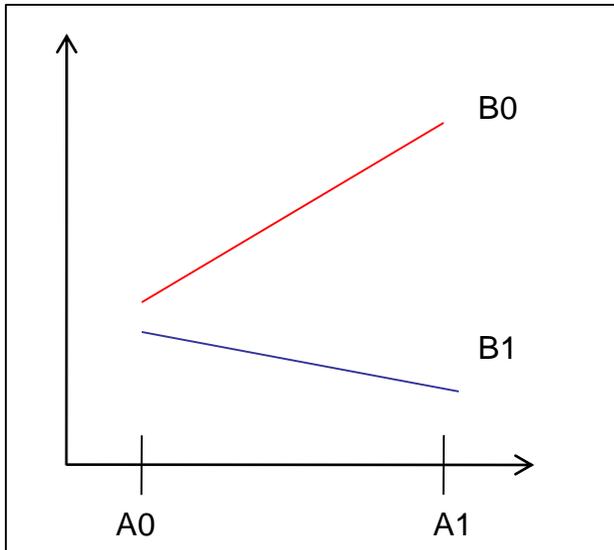
Não Existência de Interação

A direção do Efeito de B muda de acordo com o nível de A



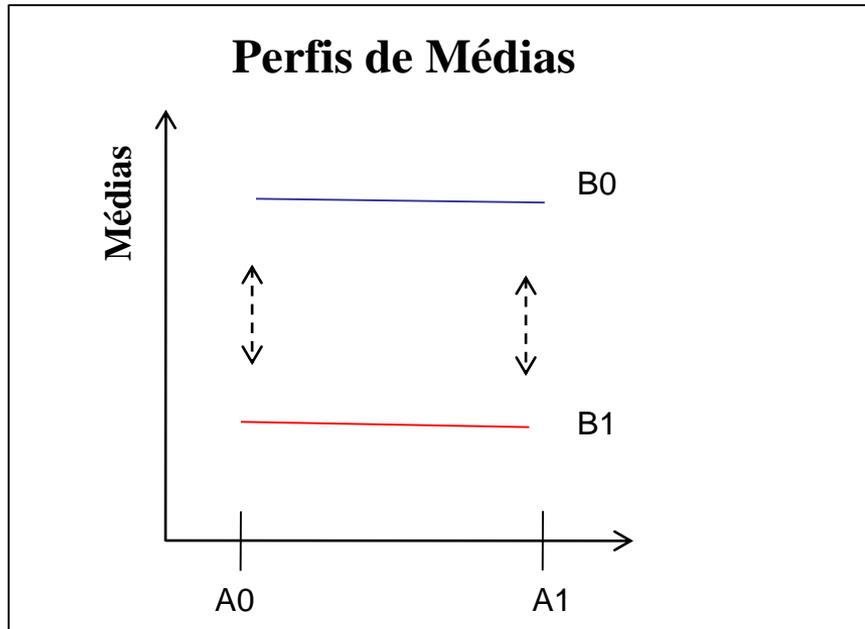
Efeito principal tanto de A como de B

A magnitude do Efeito de B muda de acordo com o nível de A

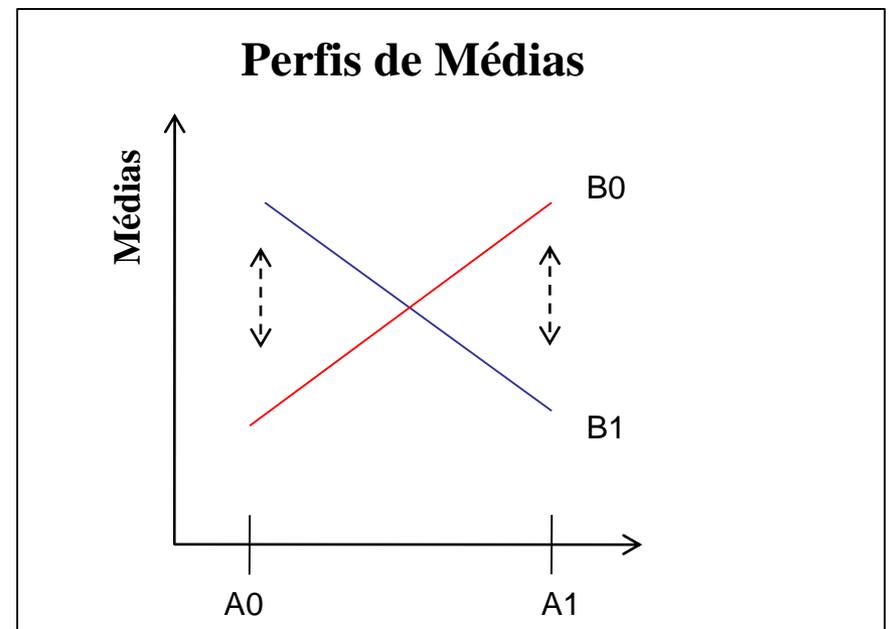


Efeito principal somente de B

Perfis de Médias – Efeito de Interação Fatorial 2x2



Inexistência de interação entre os fatores
(paralelismo)



Existência de interação entre os fatores
(desvio do paralelismo)

$$H_0 : \mu_{00} - \mu_{01} = \mu_{10} - \mu_{11}$$

$$H_1 : \mu_{00} - \mu_{01} \neq \mu_{10} - \mu_{11}$$

Efeito de interação é definido
como um contraste entre
médias

DCA com um Fator em J níveis

Decomposição de Fontes de Variação

F.V.	nºg.l.	SQ	
Entre Trat.	J-1	$\sum_j n_j (\bar{y}_{.j} - \bar{y})^2$	<div style="display: flex; align-items: center;"> <div style="font-size: 3em; margin-right: 10px;">{</div> <div> <p>Fator A a-1</p> <p>Fator B b-1</p> <p>Interação (a-1)(b-1)</p> </div> </div>
Resíduo	n-J	$\sum_{ij} (y_{ij} - \bar{y}_{.j})^2$	<div style="border: 1px dashed red; padding: 5px; display: inline-block;"> <p>(a-1)+(b-1)+(a-1)(b-1)=ab-1=J-1</p> </div>
Total	n-1	$\sum_{ij} (y_{ij} - \bar{y})^2$	

$$\mathbf{J=ab \quad n=abr \quad n_j=r}$$

Decomposição da soma de quadrados Entre Tratamentos e do correspondente número de graus de liberdade de acordo com Efeitos Principais e de Interação entre os fatores

Delineamento Fatorial

Modelo e Fontes de Variação

$$y_{ijk} = \mu_{jk} + \varepsilon_{ijk} = \mu + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad e_{ijk} \stackrel{iid}{\sim} N(0; \sigma^2)$$



Identidade útil:

$$y_{ijk} - \bar{y} = (\bar{y}_{j.} - \bar{y}) + (\bar{y}_{.k} - \bar{y}) + (\bar{y}_{jk} - \bar{y}_{j.} - \bar{y}_{.k} + \bar{y}) + (y_{ijk} - \bar{y}_{jk})$$



$$\sum_{ijk} (y_{ijk} - \bar{y})^2$$

SQTotal

$$\sum_j br(\bar{y}_{j.} - \bar{y})^2$$

SQA

$$\sum_k ar(\bar{y}_{.k} - \bar{y})^2$$

SQB

$$\sum_{jk} r(\bar{y}_{jk} - \bar{y}_{j.} - \bar{y}_{.k} + \bar{y})^2$$

SQA*B

$$\sum_{ijk} (y_{ijk} - \bar{y}_{jk})^2$$

SQRes

associadas aos Efeitos principais dos fatores A e B

associada ao Efeito de Interação

Tabela de ANOVA

DCA – Fatorial axb

F.V.	g.l.	SQ	QM	F
Fator A	a-1	$\sum_j br(\bar{y}_j - \bar{y})^2$	QM(A)	QM(A)/QMRes
Fator B	b-1	$\sum_k ar(\bar{y}_k - \bar{y})^2$	QM(B)	QM(B)/QMRes
Interação A*B	(a-1)(b-1)	$\sum_{jk} r(\bar{y}_{jk} - \bar{y}_j - \bar{y}_k + \bar{y})^2$	QM(A*B)	QM(A*B)/QMRes
Resíduo	n-(ab-1)	$\sum_{ijk} (y_{ijk} - \bar{y}_{jk})^2$	QMRes	
Total	n-1	$\sum_{ijk} (y_{ijk} - \bar{y})^2$		

Testar primeiro o efeito de interação ($H_{01}: \gamma_{ij}=0$)

Se H_{01} for rejeitada, realizar comparações múltiplas para estudar o efeito de interação

Se H_{01} não for rejeitada, testar os efeitos principais dos fatores (modelos reduzidos, aditivos)

Tabelas ANOVA

Dados de um DCA com 1 Fator em 4 níveis

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

Tabela ANOVA: Modelo de 1 Fator em 4 níveis

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Trat	3	199.937	66.646	20.16	2.924e-06
Residuals	20	66.117	3.306		

Coefficients (codificação: Trat=1,2,3,4)

(Intercept)	Trat2	Trat3	Trat4
5.250	6.350	-0.433	4.417

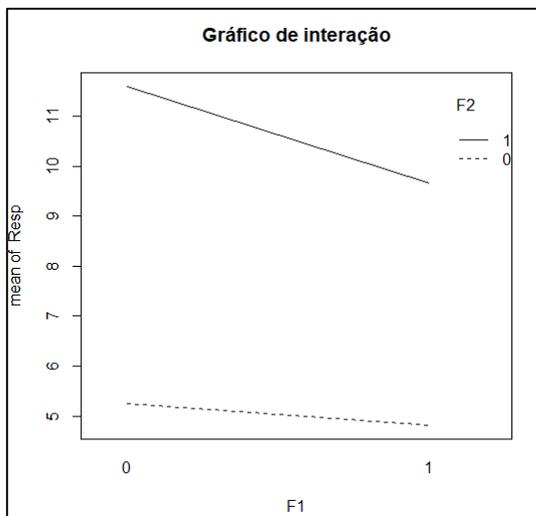


Tabela Anova: Modelo Fatorial 2x2 (Interação)

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
F1	1	8.402	8.402	2.5415	0.1266
F2	1	188.160	188.160	56.9176	2.849e-07
F1:F2	1	3.375	3.375	1.0209	0.3244
Residuals	20	66.117	3.306		

Coefficients (codificação: F1 (0=30% 1=100%) F2 (0=SN 1=N))

(Intercept)	F1	F2	F1:F2
5.250	-0.433	6.350	-1.50

Obter Modelos reduzidos (sem interação → só F2)

ANÁLISE DE VARIÂNCIA – MODELO REDUZIDO

EFEITOS PRINCIPAIS

Source	DF	SS	MS	F	P
F1	1	8,640	8,640	2,64	0,119
F2	1	189,282	189,282	57,81	0,000
Error	21	68,757	3,274		
Total	23	266,678			

Concl. ?

ANÁLISE DE VARIÂNCIA – MODELO “MAIS” REDUZIDO

EFEITO PRINCIPAL DE F2

Source	DF	SS	MS	F	P
F2	1	189,28	189,28	53,80	0,000
Error	22	77,40	3,52		
Total	23	266,68			

Concl. ?

Não é necessário aplicar o teste de Tukey neste caso.

O teste F (=53,80) é equivalente ao teste t para amostras independentes (sob homocedasticidade) $t_{22}^2 = F_{1,22}$

Delineamento Aleatorizado em Blocos Completos

	Tratamentos				
Bloco	T ₁	T ₂	...	T _a	
B ₁	Y ₁₁	Y ₂₁	...	Y _{a1}	<i>“aleatorização restrita” dentro de blocos</i>
B ₂	Y ₁₂	Y ₂₂	...	Y _{a2}	
	Y _{ij}	...	<i>a unidades experimentais dentro de cada bloco são aleatoriamente atribuídas aos tratamentos</i>
B _r	Y _{1r}	Y _{2r}	...	Y _{ar}	

**r replicações em cada
tratamento**

Delineamento Aleatorizado em Blocos Completos

Estrutura dos Dados

- **Fatores** {
 - Tratamento:** *fator de interesse*
 - Bloco:** *fator de controle*
- **Aleatorização Restrita (Dentro do Bloco)**
- **Variável Resposta**

Vantagem da Blocagem

eliminar o efeito de uma fonte de variação conhecida (bloco)



redução do efeito residual

Exemplo

Dados: Medidas realizadas de acordo com um tratamento sob Blocagem (fator de Controle)

Bloco	Tratamento			
	T1	T2	T3	T4
B1	6,2	12,7	7,0	8,3
B2	4,8	11,3	4,4	7,1
B3	3,0	9,3	3,8	11,7
B4	5,6	9,5	5,0	10,0
B5	7,1	11,7	5,5	8,5
B6	4,8	15,3	3,2	12,4

Estrutura de Blocos (hipotético): coluna de água de um rio.

Delineamento Completamente Aleatorizado

Delineamento Aleatorizado em Blocos Completos

DCA

T1	T2	...	T _a
⋮	⋮		⋮
⋮	⋮		⋮
n₁	n₂	...	n_a

n

Aleatorização irrestrita das n unidades experimentais aos a tratamentos

DAB

	T1	T2	...	T _a
B1	⋮	⋮		⋮
B2	⋮	⋮		⋮
...	⋮	⋮		⋮
Br	⋮	⋮		⋮
	r	r	...	r

Aleatorização restrita das a unidades experimentais dentro de cada um dos r blocos

Modelo Teórico - Aditividade

$$\begin{aligned}y_{ij} &= \mu_{ij} + e_{ij} \\ &= \underbrace{\mu_j + \beta_i}_{\text{componente fixo}} + e_{ij}\end{aligned}$$

$$e_{ij} \stackrel{iid}{\sim} N(0; \sigma^2)$$

↑ componente aleatório

$$y_{ij} = \mu + \tau_j + \beta_i + e_{ij}$$

↑ efeito do tratamento

↑ Efeito do bloco

$$\sum_{j=1}^J \tau_j = \sum_{i=1}^r \beta_i = 0$$

Suposição: Modelo Aditivo (não há efeito de interação entre os fatores)

Modelo Teórico / Estimadores

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



identidade útil na obtenção das estatísticas

Resíduo é o efeito de interação entre os fatores

$$y_{ij} = \bar{y} + (\bar{y}_{.j} - \bar{y}) + (\bar{y}_i - \bar{y}) + (y_{ij} - \bar{y}_{.j} - \bar{y}_i + \bar{y})$$

Valor observado

$$\underbrace{\hat{\tau}_j}_{\text{}} \quad \underbrace{\hat{\beta}_i}_{\text{}} \quad \underbrace{\hat{e}_{ij}}_{\text{}}$$

\hat{y}_{ij} Valor predito

Hipótese de Interesse


$$Y_{ij} \sim N(\mu_j + \beta_i; \sigma^2)$$

$$\left\{ \begin{array}{l} H_0 : \mu_1 = \mu_2 = \dots = \mu_J = \mu \\ H_1 : \text{existe pelo menos uma diferença} \end{array} \right.$$



Em geral, não há interesse em testar o efeito do fator Bloco (apesar de, teoricamente, ser possível testar!)

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_r = \beta \quad \text{Qual é a estatística deste teste ?}$$

Porém, note que não é possível testar o efeito de interação entre os fatores tratamento e bloco! Este efeito define o resíduo do modelo.

Tabela de ANOVA

$$H_0: \mu_1 = \mu_2 = \dots = \mu_J = \mu$$

F.V.	g l	SQ	QM	F	p
TRAT	J-1	$\sum_r (\bar{y}_{.j} - \bar{y})^2$	SQTrat/(J-1)	$\frac{QMTrat}{QMRes}$	
BLOCO	r-1	$\sum_J (\bar{y}_{i.} - \bar{y})^2$			
RESÍDUO	(J-1)(r-1)	$\sum_{ij} (y_{ij} - \bar{y}_{.j} - \bar{y}_{i.} + \bar{y})^2$	SQRes/(J-1)(r-1)		
TOTAL	rJ-1	$\sum_{ij} (y_{ij} - \bar{y})^2$			

(r-1)+(J-1)(r-1) = rJ-J

g.l. da interação

$$F = \frac{QMTrat}{QMRes} \stackrel{H_0}{\sim} F_{(J-1), (J-1)(r-1)}$$

Como tomar decisão sobre H_0 ?

Em geral, não há interesse em testar o efeito do fator Bloco e, além das premissas clássicas, a validade do modelo aditivo deve ser investigada.

Tabela de ANOVA - DABC

Compare com a tabela de ANOVA do correspondente DCA.

$$H: \mu_1 = \mu_2 = \dots = \mu_a = \mu$$

F.V.	g.l.	SQ	QM	F	p
TRAT	3	201.448	67.149	19.79	0.000
BLOCO	5	14.343	2.869	0.85	0.538
RESÍDUO	15	50.346	3.392		
TOTAL	23	266.678			

Com a inclusão do fator bloco, houve ganho em precisão na estimação do efeito do tratamento?

Compare o número de graus de liberdade dos delineamentos DCA e DABC definidos para o mesmo conjunto de dados!

Modelos ANOVA

DCA: Delineamento Completamente Aleatorizado

Analysis of Variance Table

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
Trat	3	199.937	66.646	20.16	2.924e-06	***
Residuals	20	66.117	3.306			

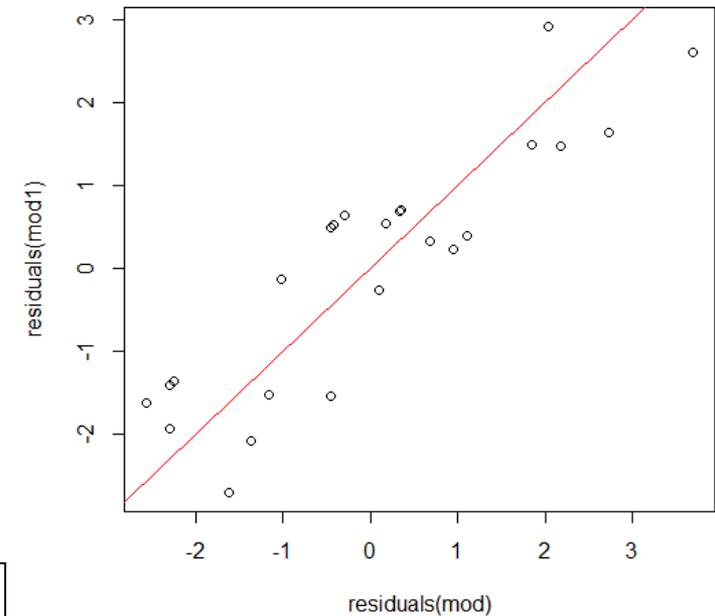
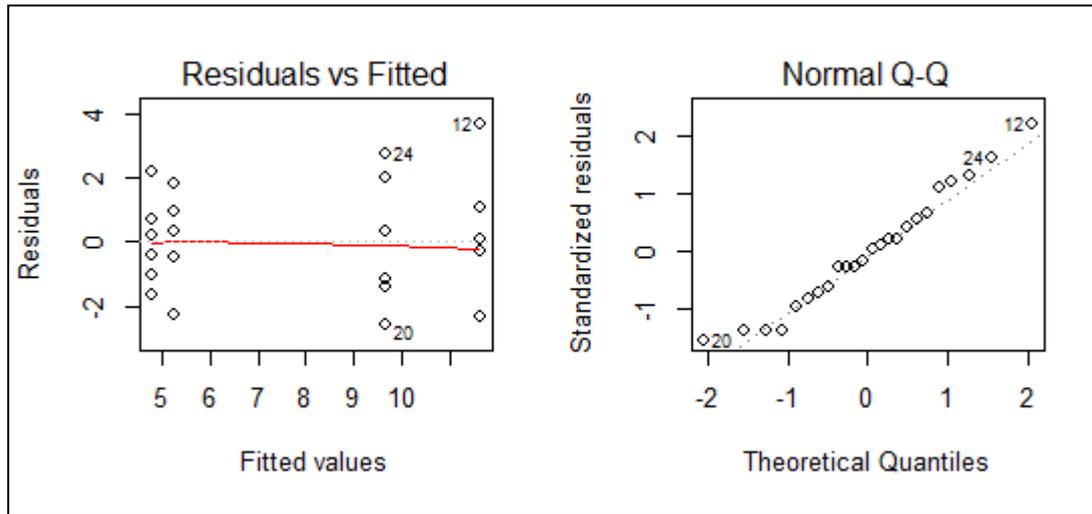
DABC: Delineamento Aleatorizado em Blocos Completos

Analysis of Variance Table

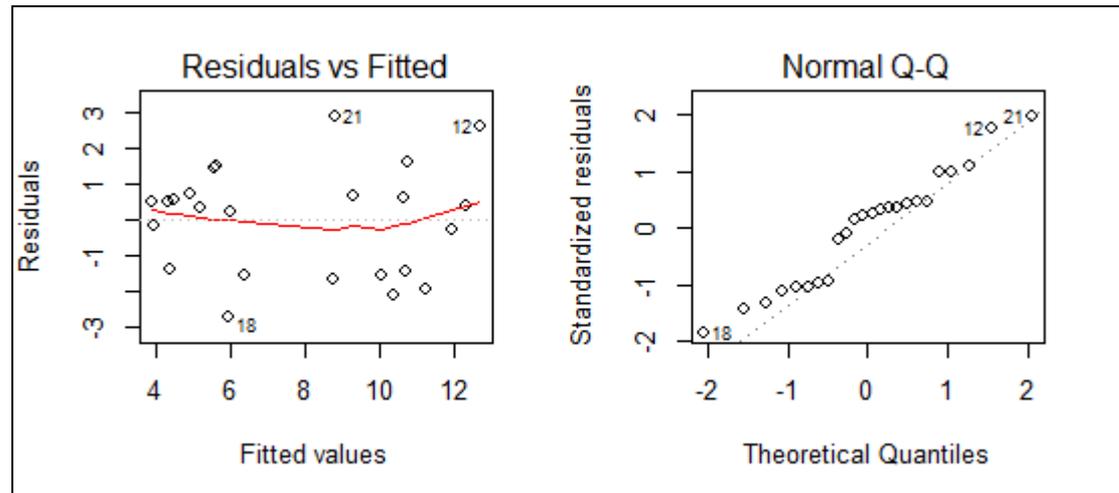
	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
Trat	3	199.937	66.646	19.3593	2.04e-05	***
Bloco	5	14.478	2.896	0.8411	0.5412	
Residuals	15	51.638	3.443			

Modelos ANOVA

ANOVA-DCA



ANOVA-DABC



Não há evidência amostral de ganho em precisão devido à inclusão do fator Bloco: sob o DCA (QMRes=3,306) e sob o DABC (QMRes=3,443)

Dados: Respostas avaliadas sob os Tratamentos (T1, T2, T3 e T4)

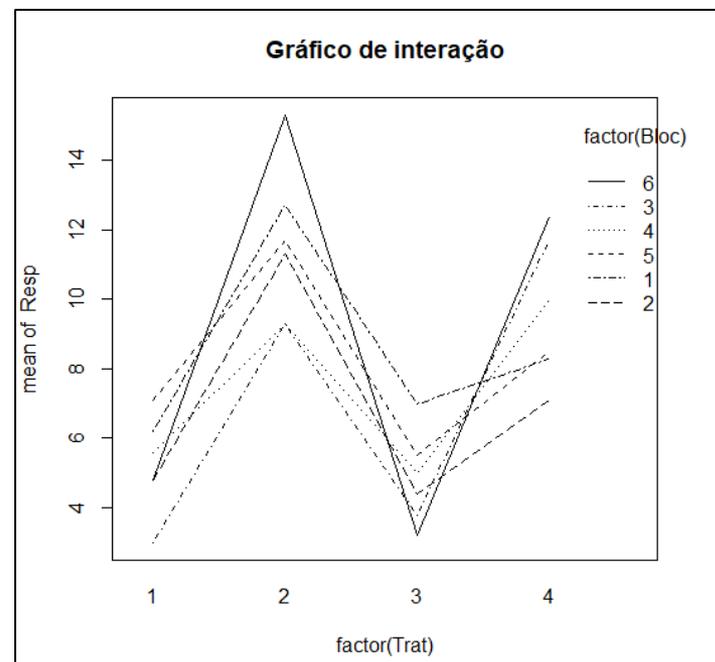
	trat	bloco	resp
1	1	1	6.2
2	2	1	12.7
3	3	1	7.0
4	4	1	8.3
5	1	2	4.8
6	2	2	11.3
7	3	2	4.4
8	4	2	7.1
9	1	3	3.0
10	2	3	9.3
11	3	3	3.8
12	4	3	11.7
13	1	4	5.6
14	2	4	9.3
15	3	4	5.0
16	4	4	10.0
17	1	5	7.1
18	2	5	11.7
19	3	5	5.5
20	4	5	8.5
21	1	6	4.8
22	2	6	15.3
23	3	6	3.2
24	4	6	12.4

Estimativas dos parâmetros do modelo (no "R")

Intercept	trat2	trat3	trat4		
5.9666667	6.3500000	-0.4333333	4.4166667		
	bloco2	bloco3	bloco4	bloco5	bloco6
	-1.6500000	-1.6000000	-1.0750000	-0.3500000	0.3750000

Interprete as estimativas dos parâmetros do modelo estrutural adotado na análise dos dados (sob o DABC)!

Há indicação de efeito de interação entre os fatores Tratamento e Bloco?



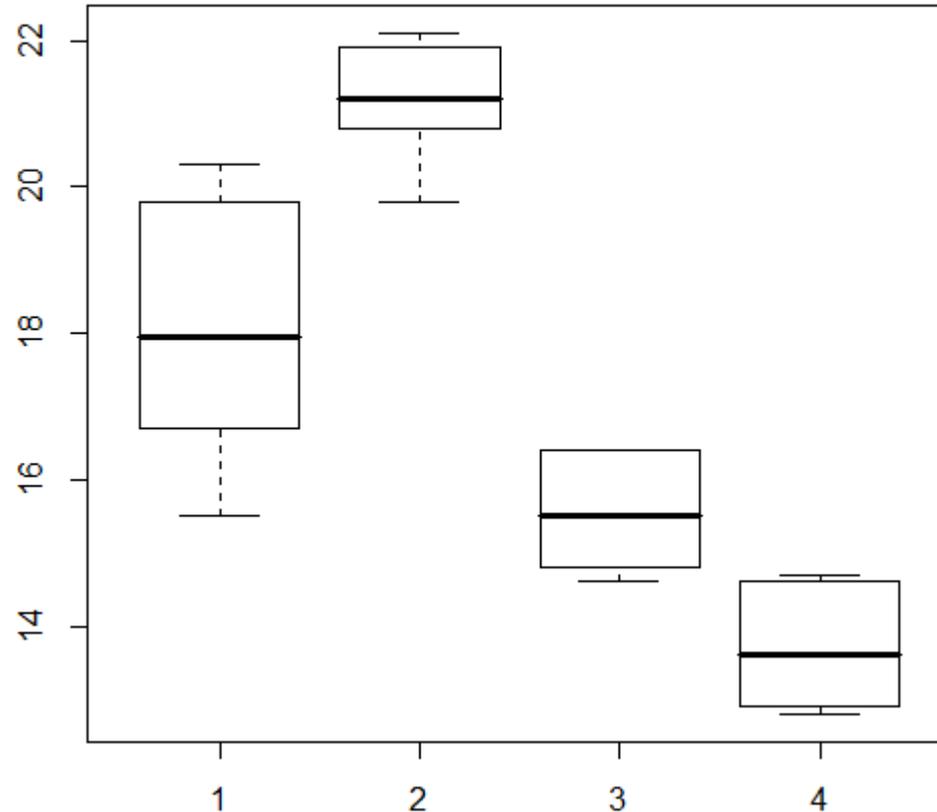
Exemplo

Dados: Crescimento de plantas (cm) de acordo com a variedade

Canteiro	Var1	Var2	Var3	Var4	
1	19,8	21,9	16,4	14,7	Blocos: canteiros
2	16,7	19,8	15,4	13,5	
3	17,7	21,0	14,8	12,8	
4	18,2	21,4	15,6	13,7	
5	20,3	22,1	16,4	14,6	
6	15,5	20,8	14,6	12,9	

Modelo ANOVA - DABC

Crescimento de plantas de acordo com Variedade



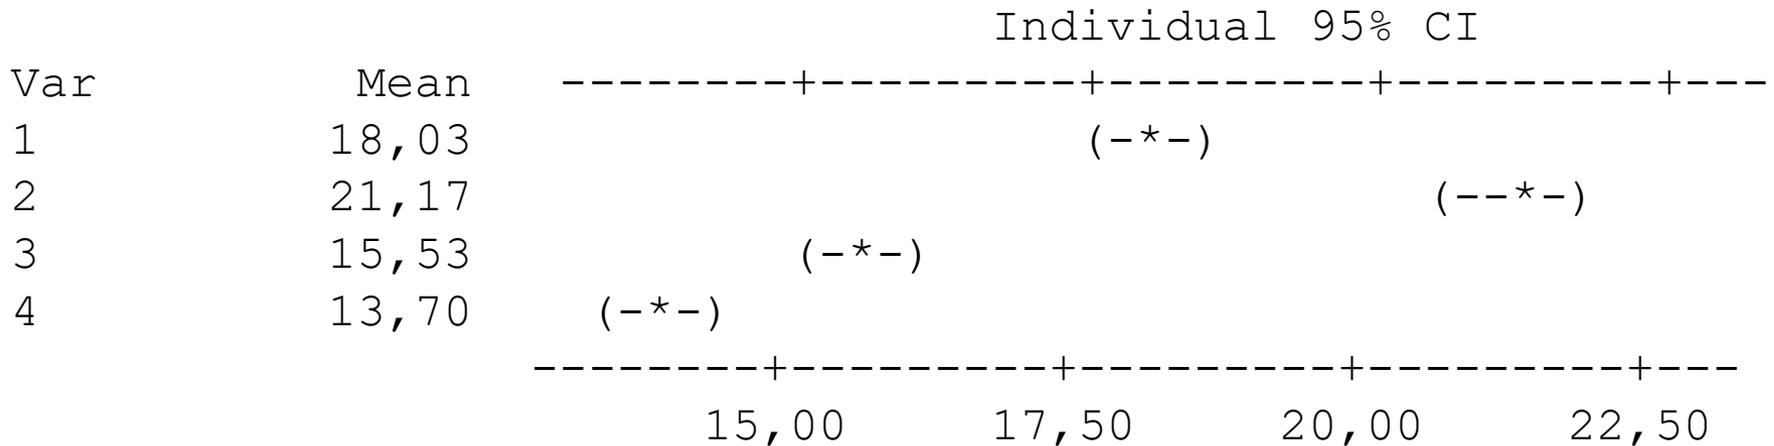
	Var1	Var2	Var3	Var4
Média	18.03	21.17	15.53	13.70
Desvio Padrão	1.82	0.84	0.77	0.81

Hipóteses ?
Suposições ?

Analysis of Variance Table

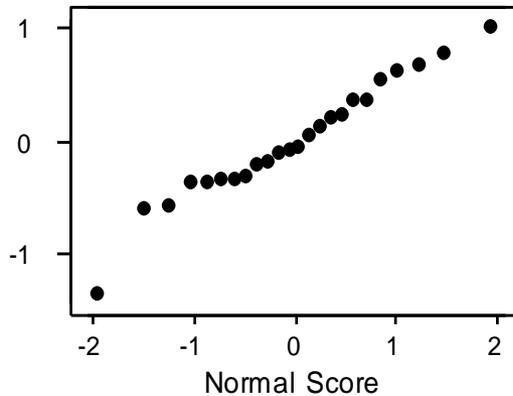
	Df	Sum Sq	Mean Sq	F value	Pr (>F)
factor (Var)	3	188.538	62.846	144.4369	2.742e-11
factor (Bloco)	5	19.793	3.959	9.0981	0.0003857
Residuals	15	6.527	0.435		
Total	23	214.858			

Concl. ?

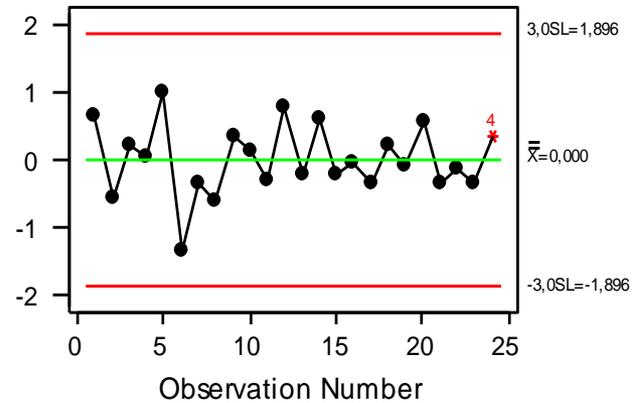


Residual Model Diagnostics

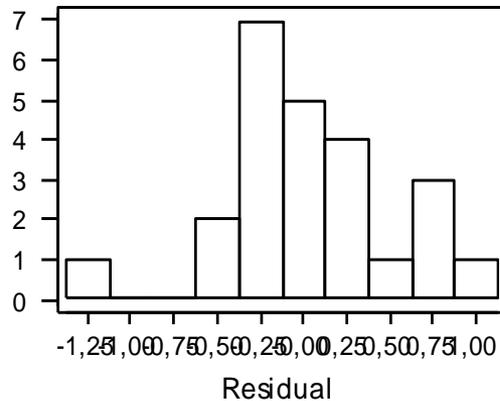
Normal Plot of Residuals



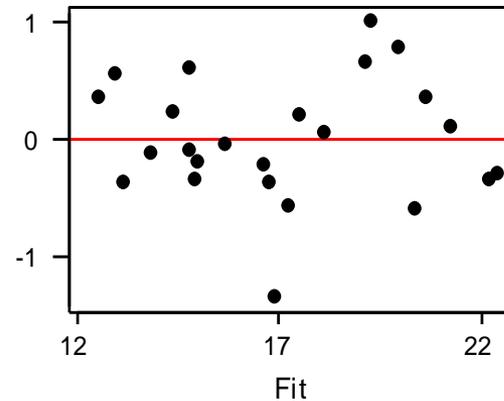
I Chart of Residuals



Histogram of Residuals



Residuals vs. Fits



As suposições do modelo estão satisfeitas ?

Modelos ANOVA – DCA e DABC

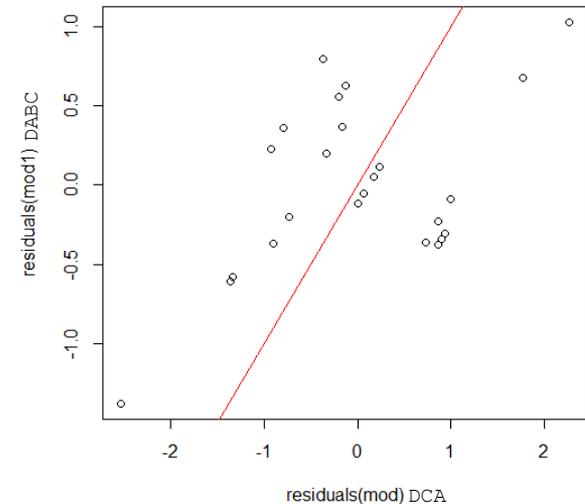
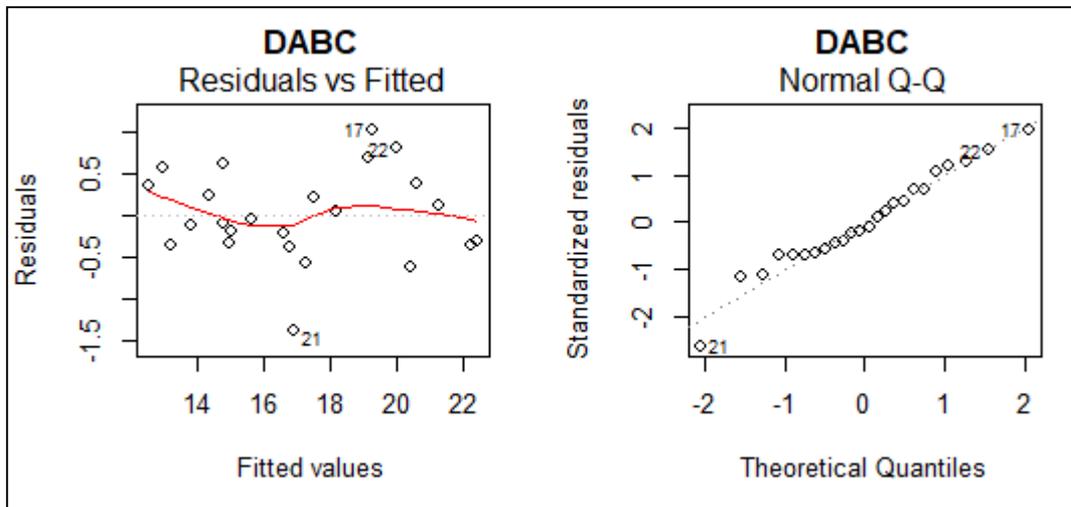
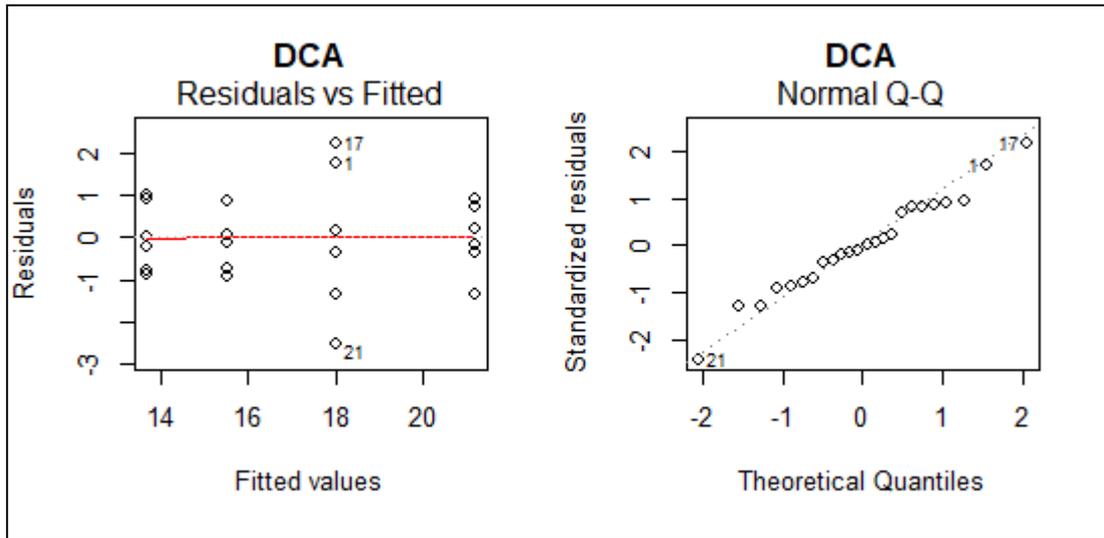
Delimitação Completamente Aleatorizado - DCA

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
factor (Var)	3	188.54	62.846	47.755	2.654e-09	***
Residuals	20	26.32	1.316			

Delimitação Aleatorizado em Blocos Completos - DABC

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
factor (Var)	3	188.538	62.846	144.4369	2.742e-11	***
factor (Bloco)	5	19.793	3.959	9.0981	0.0003857	***
Residuals	15	6.527	0.435			

Modelos ANOVA – DCA e DABC



Maiores variâncias dos resíduos sob o DCA (QMRes=1,316) relativamente ao DABC (QMRes=0,435)

DABC - Tukey Simultaneous Tests (efeito do fator Variedade)

Response Variable resp

All Pairwise Comparisons among Levels of var

Hipóteses ?

var = 1 subtracted from:

Level	Difference	SE of	Adjusted
var	of Means	Difference	P-Value
2	3,133	0,3808	8,23 ← (21,17-18,03)/(√2*0.435/6)
3	-2,500	0,3808	-6,56
4	-4,333	0,3808	-11,38

var = 2 subtracted from:

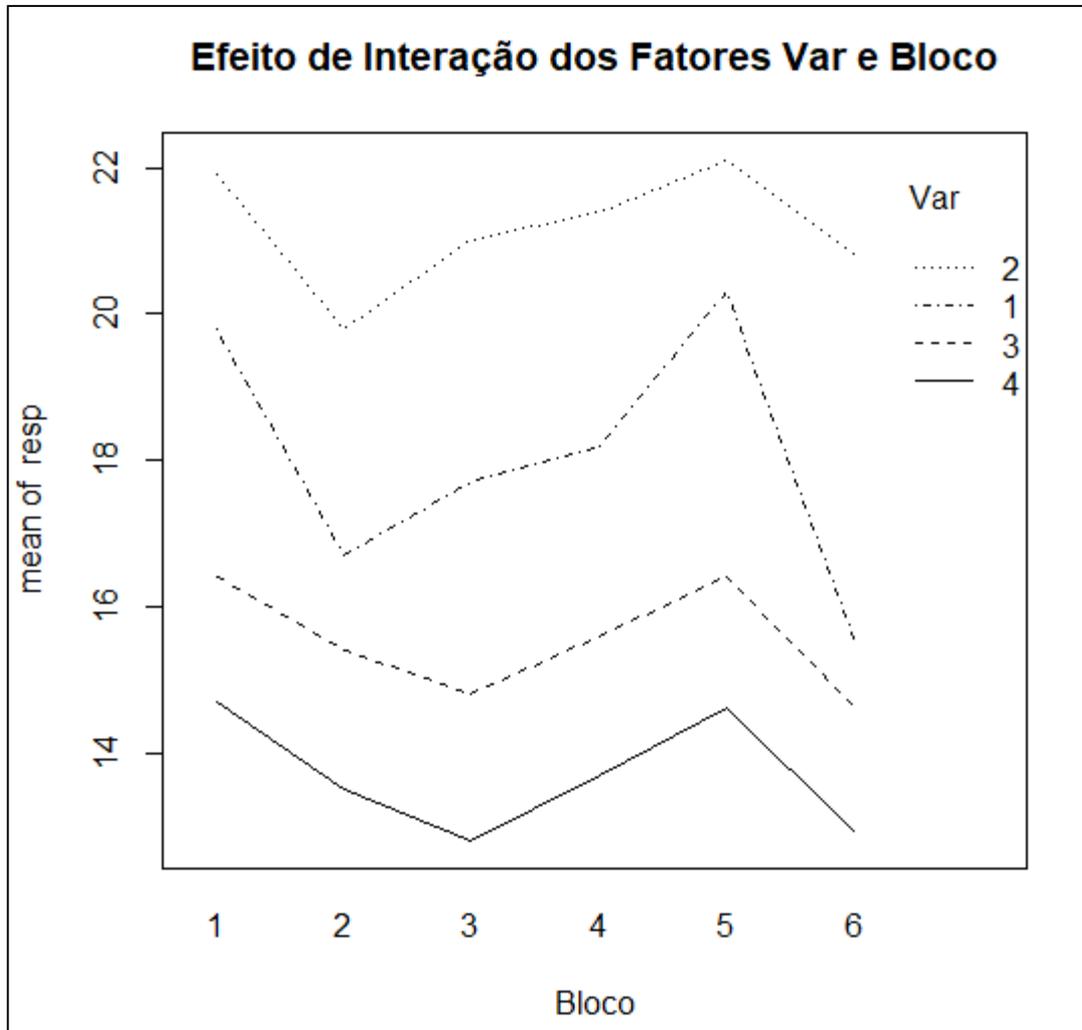
Level	Difference	SE of	Adjusted
var	of Means	Difference	P-Value
3	-5,633	0,3808	-14,79
4	-7,467	0,3808	-19,61

Conclusão?

var = 3 subtracted from:

Level	Difference	SE of	Adjusted
var	of Means	Difference	P-Value
4	-1,833	0,3808	-4,814

Modelo ANOVA - DABC



No Delineamento Aleatorizado em Blocos Completos (DABC) o resíduo é o Efeito de Interação entre os fatores Tratamento e Bloco.

Pelo gráfico de perfis individuais há indicação de efeito de interação?

Note que o paralelismo dos perfis é uma indicação de ausência de interação!