EXPERIMENTAÇÃO AGRÍCOLA E FLORESTAL

Alberto Cargnelutti Filho

Alessandro Dal'Col Lúcio

Sidinei José Lopes

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
DEPARTAMENTO DE FITOTECNIA

Autores:
Alberto Cargnelutti Filho
Alessandro Dal'Col Lúcio
Sidinei José Lopes

	Cargnelutti Filho, Alberto
C276a	
	Experimentação agrícola e florestal / por Alberto Cargnelutti Filho, Alessandro Dal'Col Lúcio, Sidinei José Lopes. - Santa Maria: UFSM / CCR / Departamento de Fitotecnia, 2009.
	204 p. : il., tabs.
	1. Estatística experimental 2. Delineamentos experimentais 3. Análise de variância 4. Testes de hipóteses 5. Análise de regressão 6. Testes de comparação múltipla de médias. I. Lúcio, Alessandro Dal'Col II. Lopes, Sidinei José III. Título
	CDU: 631/635:519.22

Ficha catalográfica elaborada por Luiz Marchiotti Fernandes CRB-10/1160 Biblioteca Setorial do CCR - UFSM

DEPARTAMENTO DE FITOTECNIA
CENTRO DE CIÊNCIAS RURAIS
UNIVERSIDADE FEDERAL DE SANTA MARIA
97105-900 Santa Maria, RS
Fone: 0xx55 32208179 ramal 231 32209499/ Fax 3220 8899
Email: cargnelutti@pq.cnpq.br

APRESENTAÇÃO

Este texto aborda conteúdos, normalmente, ministrados em disciplinas de experimentação para alunos de graduação em Agronomia e Engenharia Florestal. Os exemplos, ao longo do texto, serão divididos: ora mais aplicados à Agronomia e ora mais aplicados à Engenharia Florestal e foram planejados no sentido de facilitar o entendimento por ambos os alunos.

Partiu-se do princípio, que os leitores dominem alguns fundamentos estatísticos, normalmente, desenvolvidos em disciplinas de estatística básica, que são normalmente pré-requisitos para os alunos que cursam uma disciplina de experimentação. Esses tópicos seriam basicamente: análise descritiva, probabilidade, amostragem, estimação, testes de hipótese e correlação e regressão. Mesmo assim, como forma de revisão, no início do texto é apresentado alguns tópicos gerais de estatística, com ênfase a estatística descritiva.

Após é abordada a parte teórica do assunto da disciplina de Experimentação e alguns exemplos práticos. Ao longo do texto é importante que o leitor (aluno) resolva os exercícios sobre os assuntos, cujos gabaritos podem ser acessados em www.ufsm.br/cargnelutti.

O texto é direcionado aos alunos de graduação, dispostos a adquirir conhecimento básico na área de análise estatística de dados experimentais, com fins de aprimoramento e aplicação em experimentação e pesquisa científica. A abordagem de alguns itens é superficial, ficando os detalhes para serem apresentados durante as aulas da disciplina. Assim, a presença do aluno em aula é essencial para um entendimento melhor dos assuntos abordados.

Sugestões, para melhorar o conteúdo e a apresentação, dessa primeira versão, são bem vindas.

OS AUTORES

SUMÁRIO

1 Introdução

Tópicos gerais de estatística

Nesse tópico faremos uma breve revisão da estatística básica (pré-requisito para essa disciplina de experimentação). Abordaremos, basicamente, a estatística descritiva. Para isso, usaremos o seguinte exemplo (dados fictícios):

Exemplo 1: Foram semeadas dez sementes de milho, da mesma cultivar, uma próxima a outra, em um mesmo solo. As sementes deram origem a dez plantas. A adubação do solo e a irrigação foram iguais para todas as plantas e todos os demais tratos culturais foram os mesmos. As plantas cresceram e após algum tempo anotou-se a altura de plantas, em cm, em cinco plantas escolhidas aleatoriamente, que foram as seguintes:

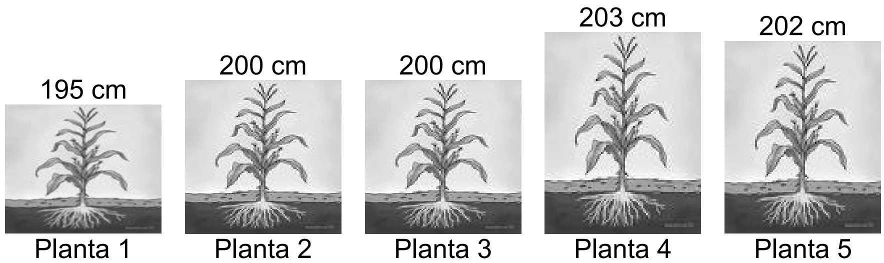

Figura 1. Representação da altura de cinco plantas de milho.

A variável medida foi a altura de plantas. Denominamos essa variável de Y, por exemplo. Normalmente em livros de estatística essa variável é denominada de X. No entanto, nesse texto, sempre as variáveis respostas serão representadas por “Y”.

Percebe-se que, mesmo com todos os cuidados, não foi possível obter todas as plantas com a mesma altura, ou seja, ocorreu uma variação. Essa variação é atribuída ao acaso.

Nesse exemplo, estamos trabalhando com uma amostra, ou seja, cinco plantas (n = 5) escolhidas aleatoriamente de uma população de dez plantas (N = 10).

Vamos calcular as medidas de tendência central e de variabilidade.

Medidas de tendência central

a) Média

Em livros normalmente é representada por $\overline{X}$ (lê-se x-barra), mas nesse texto usaremos $\overline{Y}$. A média nada mais é do que a soma de todos os dados dividido pelo número de dados somados. Essa média é a aritmética. Existem outras (geométrica, harmônica) que não serão tratadas aqui, pelo fato de nesse material trabalharmos sempre com a média aritmética, ou simplesmente média.

$$\overline{Y} = \frac{\sum_{i=1}^{n} Y_i}{n} = \frac{195+200+200+203+202}{5} = 200\,\text{cm}$$

Observe o seguinte quadro:

Representação de Y_i	Y_i	$\overline{Y}$	$(Y_i - \overline{Y})$	$(Y_i - \overline{Y})^2$
Y_1	195	200	-5	25
Y_2	200	200	0	0
Y_3	200	200	0	0
Y_4	203	200	3	9
Y_5 (Y_n)	202	200	2	4
Soma	$\sum_{i=1}^{n} Y_i = 1000$		$\sum_{i=1}^{n}(Y_i - \overline{Y}) = 0$	$\sum_{i=1}^{n}(Y_i - \overline{Y})^2 = 38$

Os valores de $(Y_i - \overline{Y})$ são os desvios ou erros (em experimentação será o erro experimental ou variação ao acaso ou ainda variação não controlada pelo pesquisador).

Observe que, uma das propriedades da média é que a soma dos desvios deve ser nula, ou seja, $\sum_{i=1}^{n}(Y_i - \overline{Y}) = 0$ **.**

b) Mediana

Como n=5 (ímpar) a mediana é o valor central de um conjunto de dados ordenado (195, 200, ***200***, 202, 203). Portanto é o terceiro elemento da série de dados, no caso, mediana = 200 cm. Se fosse par a mediana seria a média dos dois valores centrais.

c) Moda

É o valor que mais se repete. Então moda = 200 cm, pois aparece duas vezes na série de dados enquanto os demais dados aparecem uma única vez.

Nesse exemplo a média, a mediana e a moda foram iguais, mas isso nem sempre acontece. Aliás, em um grande conjunto de dados isso é raro de acontecer.

Medidas de variabilidade ou dispersão

a) Amplitude

É o valor máximo menos o valor mínimo. Logo amplitude (h) = 203 – 195 = 8 cm.

b) Variância

$$s^2 = \frac{\sum_{i=1}^{n}(Y_i - \overline{Y})^2}{n-1}$$

$$s^2 = \frac{(195-200)^2 + (200-200)^2 + (200-200)^2 + (203-200)^2 + (202-200)^2}{5-1} = \frac{38}{4} = 9{,}5\,\text{cm}^2$$

c) Desvio padrão

$$s = \sqrt{\frac{\sum_{i=1}^{n}(Y_i - \overline{Y})^2}{n-1}}$$

$$s = \sqrt{\frac{(195-200)^2 + (200-200)^2 + (200-200)^2 + (203-200)^2 + (202-200)^2}{5-1}} = \sqrt{\frac{38}{4}} = \sqrt{9{,}5\text{cm}^2} = 3{,}08\text{cm}$$

d) Erro padrão da média

$$EP = \frac{s}{\sqrt{n}} = \frac{3{,}08}{\sqrt{5}} = 1{,}377\,\text{cm}$$

e) Coeficiente de variação

$$CV = \frac{s}{\overline{Y}} * 100 = \frac{3{,}08}{200} * 100 = 1{,}541\%$$

O coeficiente de variação é uma estatística utilizada para avaliar a precisão experimental. Quanto menor o valor do CV melhor é a precisão experimental, ou seja, maior confiabilidade das informações.

Observe o seguinte: As medidas de tendência central fornecem um valor central do conjunto de dados e que seria representativo desse conjunto. Já as medidas de variabilidade fornecem uma idéia da variação dos dados em torno do ponto central, no caso, a média. Veja que quanto maiores os desvios dos dados em relação à media maior vai ser a amplitude, a variância, o desvio padrão, o erro padrão e o coeficiente de variação indicando menor precisão da estimativa da média.

Cálculos no Excel

OBS.: Todos os valores apresentados em planilhas do excel, nesse material, terão o ponto (".") como separador decimal.

	A	B	C	D	E	F	G
1		Altura (cm)					
2	Planta 1	195					
3	Planta 2	200					
4	Planta 3	200					
5	Planta 4	203					
6	Planta 5	202					
7	Média	200					
8	Mediana	200					
9	Moda	200					
10	Amplitude	8.00					
11	Variância	9.50					
12	Desvio padrão	3.08					
13	Erro padrão	1.38					
14	Coef. Variação	1.54					
15							

Janela de inspeção

Adicionar inspeção de variáveis...

Excluir inspeção de variáveis

Célula	Valor	Fórmula
B7	200	=MÉDIA(B2:B6)
B8	200	=MED(B2:B6)
B9	200	=MODO(B2:B6)
B10	8.00	=B5-B2
B11	9.50	=VAR(B2:B6)
B12	3.08	=DESVPAD(B2:B6)
B13	1.38	=B12/RAIZ(5)
B14	1.54	=B12/B7*100

Observe que se todas as plantas tivessem a mesma altura, por exemplo, 200 cm, teríamos o seguinte: as medidas de tendência central (média, mediana e moda) seriam iguais a 200 cm e as medidas de variabilidade (amplitude, variância, desvio padrão, erro padrão e coeficiente de variação) seriam todas iguais a zero, ou seja, não existiria variabilidade alguma entre as observações. Portanto se todas as plantas tivessem a mesma altura (o que não é comum), as informações teriam maior precisão.

Em nosso exemplo, trabalhamos com uma amostra, ou seja, cinco plantas (n = 5) escolhidas aleatoriamente de uma população de dez plantas (N = 10). Portanto, os valores que calculamos, por meio dos estimadores (fórmulas) são chamados de estimativas, ou seja, são estimativas dos verdadeiros valores (parâmetros) que só seriam obtidos se tivéssemos os dados de toda a população (no caso, as 10 plantas).

A seguir um quadro comparativo entre as fórmulas para a amostra e para a população:

	Amostra (estimador)	População (parâmetro)
Média	$\overline{Y} = \frac{\sum_{i=1}^{n} Y_i}{n}$	$\mu = \frac{\sum_{i=1}^{N} Y_i}{N}$
Variância	$s^2 = \frac{\sum_{i=1}^{n} (Y_i - \overline{Y})^2}{n-1}$	$\sigma^2 = \frac{\sum_{i=1}^{N} (Y_i - \mu)^2}{N}$
Desvio padrão	$s = \sqrt{\frac{\sum_{i=1}^{n} (Y_i - \overline{Y})^2}{n-1}}$	$\sigma = \sqrt{\frac{\sum_{i=1}^{N} (Y_i - \mu)^2}{N}}$
Coeficiente de variação	$CV = \frac{s}{\overline{Y}} * 100$	$CV = \frac{\sigma}{\mu} * 100$

Exemplo 2: Vamos calcular as medidas de tendência central e de variabilidade, no excel, considerando os seguintes dados da altura das 10 plantas (N = 10). Nesse exemplo didático, consideramos as 10 plantas como sendo a população.

	A	B
1		Altura (cm)
2	Planta 1	195
3	Planta 2	200
4	Planta 3	200
5	Planta 4	203
6	Planta 5	202
7	Planta 6	198
8	Planta 7	203
9	Planta 8	198
10	Planta 9	208
11	Planta 10	198
12	Média	200.50
13	Mediana	200.00
14	Moda	198.00
15	Amplitude	13.00
16	Variância	12.05
17	Desvio padrão	3.47
18	Coef. Variação	1.73
19		

Janela de inspeção

Adicionar inspeção de variáveis... Excluir inspeção de variáveis

Célula	Valor	Fórmula
B12	200.50	=MÉDIA(B2:B11)
B13	200.00	=MED(B2:B11)
B14	198.00	=MODO(B2:B11)
B15	13.00	=MÁXIMO(B2:B11)-MÍNIMO(B2:B11)
B16	12.05	=VARP(B2:B11)
B17	3.47	=DESVPADP(B2:B11)
B18	1.73	=B17/B12*100

Veja o seguinte quadro comparativo:

Medida	Amostra (n=5 plantas)	População (N = 10 plantas)
Média	200,00	200,50
Mediana	200,00	200,00
Moda	200,00	198,00
Amplitude	8,00	13,00
Variância	9,50	12,05
Desvio padrão	3,08	3,47
Erro padrão	1,38	-
Coeficiente de variação	1,54	1,73

Os valores na coluna referente à amostra são estimativas dos parâmetros. Na experimentação, de maneira geral, busca-se, por meio de amostras fazer inferências para os parâmetros (população), com uma margem de erro conhecida.

Além das medidas de posição e de variabilidade existem as medidas de assimetria (forma da distribuição dos dados) e curtose (grau de achatamento da distribuição).

Algumas distribuições de probabilidade são simétricas como a distribuição normal a t de Student e outras são assimétricas como a distribuição F, qui-quadrado, gama.

Exemplo da distribuição normal padrão, ou seja, média zero e variância um (0,1). Essa curva da distribuição normal deve ter coeficiente de assimetria igual a zero e curtose igual a 3.

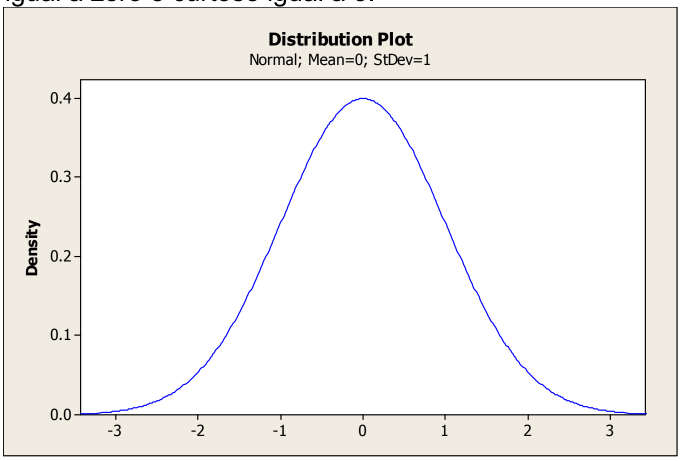

Figura 2. Curva da distribuição normal padrão (0,1).

Nesse texto o termo “Experimentação” refere-se à Experimentação Agrícola e à Experimentação Florestal. Então vamos, inicialmente, localizar a Experimentação dentro da Estatística. Para isso veja no seguinte esquema, de uma maneira bem geral, as etapas de uma pesquisa estatística.

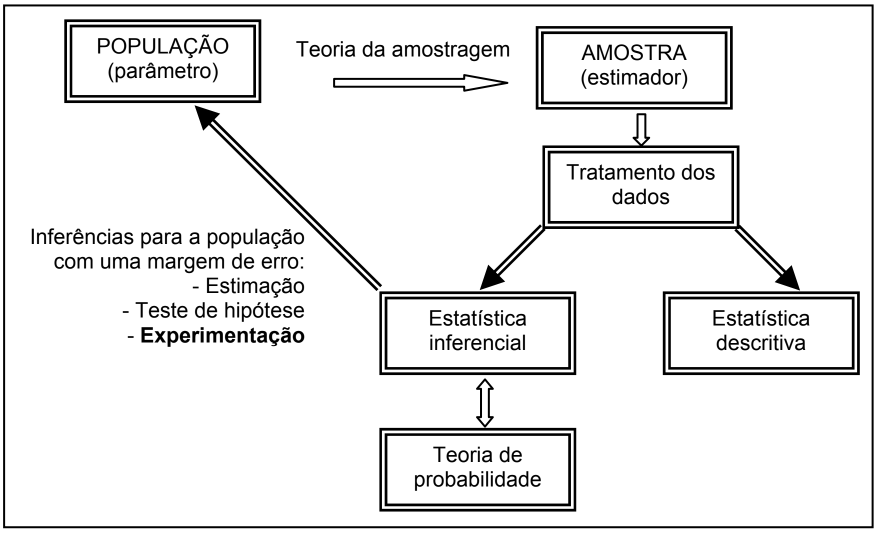

Figura 3. Esquema com as etapas de uma pesquisa estatística.

Vamos agora fazer uma ligação entre essas fórmulas com algumas que aparecerão na experimentação. Quando iniciarmos o assunto da disciplina de Experimentação e fizermos a análise de variância (ANOVA) de qualquer delineamento experimental aparecerão os seguintes termos:

Graus de Liberdade (GL)
Soma de quadrados (SQ)
Quadrado Médio (QM)

Onde: $\mathrm{QM} = \dfrac{\mathrm{SQ}}{\mathrm{GL}}$, e o valor do quadrado médio é uma estimativa da variância.

Vejamos que a fórmula da variância (s^2) de uma amostra relaciona-se com o QM da seguinte maneira:

$$s^2 = \frac{\sum_{i=1}^{n}(Y_i - \overline{Y})^2}{n-1} \Leftrightarrow QM = \frac{SQ}{GL}$$

Normalmente, há um questionamento, por parte dos alunos em relação ao **que são Graus de Liberdade (GL)?**

Conceituamos como sendo o número de valores independentes de uma estatística. Para entender vamos utilizar os dados do exemplo 1 onde foram observadas em cinco plantas (n = 5) a variável “altura de planta”.

Representação de Y_i	Y_i	$\overline{Y}$	$(Y_i - \overline{Y})$	$(Y_i - \overline{Y})^2$
Y_1	195	200	-5	25
Y_2	200	200	0	0
Y_3	200	200	0	0
Y_4	203	200	3	9
Y_5 (Y_n)	202	200	2	4
Soma	$\sum_{i=1}^{n} Y_i = 1000$		$\sum_{i=1}^{n}(Y_i - \overline{Y}) = 0$	$\sum_{i=1}^{n}(Y_i - \overline{Y})^2 = 38$

A soma dos desvios $(Y_i - \overline{Y})$ em relação à média deve ser zero, ou seja, $\sum_{i=1}^{n}(Y_i - \overline{Y}) = 0$. Então, conhecendo os quatro primeiros desvios (destacados no quadro = valores independentes) achamos o quinto desvio por diferença, ou seja, o quinto desvio depende dos anteriores. Então, o número de valores independentes (graus de liberdade) nesse caso é quatro, isto é, n-1 = 4.

Há uma fórmula alternativa para o cálculo da variância amostral (s^2) que está relacionada com fórmulas que aparecerão na experimentação que é a seguinte:

$$s^2 = \frac{\sum_{i=1}^{n}(Y_i - \overline{Y})^2}{n-1} = \overbrace{s^2}^{\text{Quadrado Médio}} = \frac{\overbrace{\sum_{i=1}^{n} Y_i^2 - \frac{\overbrace{\left(\sum_{i=1}^{n} Y_i\right)^2}^{\text{Fator de correção}}}{n}}^{\text{Soma de Quadrados}}}{\underbrace{n-1}_{\text{Graus de Liberdade}}}$$

O cálculo com a fórmula alternativa é o seguinte:

$$s^2 = \frac{(195)^2 + (200)^2 + (200)^2 + (203)^2 + (202)^2 - \frac{(195 + 200 + 200 + 203 + 202)^2}{5}}{5 - 1}$$

$$s^2 = \frac{200038 - \frac{(1000)^2}{5}}{5 - 1} = \frac{38}{4} = 9{,}5\,\text{cm}^2$$

A expressão do numerador da fórmula alternativa $\left[\sum_{i=1}^{n} Y_i^2 - \frac{\left(\sum_{i=1}^{n} Y_i\right)^2}{n}\right]$ fornece a SQ e será muito usual nas fórmulas da análise de variância.

Parte dessa expressão $\left[\frac{\left(\sum_{i=1}^{n} Y_i\right)^2}{n}\right]$ será comumente chamada de fator de correção e corresponde ao seguinte: somar todos os dados e elevar o valor ao quadrado e depois dividir pelo número de dados somados.

Várias fórmulas apresentadas até aqui poderiam ser representadas de forma diferente. Apenas para exemplificar a expressão $\left[\frac{\left(\sum_{i=1}^{n} Y_i\right)^2}{n}\right]$ poderia ser representada por $\left[\frac{\left(\sum_i Y_i\right)^2}{n}\right]$. A partir desse momento, a representação das fórmulas passará a ser de acordo com esta nova forma de apresentação.

1.1 Importância da Experimentação

1. Introdução

1.1. Importância da Experimentação

Experimentação é uma parte da estatística probabilística que estuda o planejamento, execução, coleta dos dados, análise e interpretação dos resultados dos experimentos.

Este estudo é importante para **todo** profissional pesquisador e/ou usuário dos resultados da pesquisa.

Slide nº 2

1. Introdução

1.1. Importância da Experimentação

A técnica da experimentação é uma ciência que oferece suporte probabilístico ao pesquisador e permite fazer inferências sobre o comportamento de diferentes fenômenos da natureza, com grau de incerteza (margem de erro) conhecido.

Slide nº 3

1. Introdução

1.1. Importância da Experimentação

O **pesquisador** necessita dos conhecimentos da técnica experimental para: planejar, executar, avaliar, analisar e interpretar os resultados dos experimentos. Por outro lado, o **técnico**, usuário dos resultados da pesquisa, deve conhecer a experimentação para entender o experimento e avaliar a confiabilidade dos resultados bem como, permitir melhorias na troca de idéias com os pesquisadores, pelo uso de uma linguagem técnica adequada.

Assim, **a experimentação é importante para todo o profissional, ligado direta ou indiretamente à pesquisa**.

Slide nº 4

1. Introdução

1.1. Importância da Experimentação

Diversos fatores do manejo das culturas interferem na quantidade e qualidade do produto final. Para se comprovar na prática um hipótese formulada sobre a superioridade de algum fator de produção, deve-se utilizar a experimentação. Logo, somente através da experimentação uma nova técnica poderá ser divulgada aos produtores, com embasamento científico e sem desperdício de tempo e recursos financeiros, sem comprometimento da credibilidade do pesquisador junto aos produtores.

Slide nº 5

1.2 Conceitos de experimento, tratamento, unidade experimental, delineamento experimental

1. Introdução

1.2. Conceitos de **experimento**, tratamento, unidade experimental, delineamento experimental

Experimento é um procedimento **planejado** à partir de uma hipótese, que visa **provocar fenômenos em condições controladas,** observar e analisar os seus resultados e/ou efeitos.

Slide nº 6

1. Introdução

1.2. Conceitos de **experimento**, tratamento, unidade experimental, delineamento experimental

O termo **provocar fenômenos** equivale a escolher diferentes maneiras, procedimentos, técnicas etc., ou simplesmente tratamentos, para se resolver um problema.

Exemplo: Pode-se "escolher quatro diferentes formas de adubação" de uma cultura (fenômeno provocado = formas de adubação) para verificar com qual destas formas se obtêm maior produtividade (supondo que o problema é a baixa produção desta cultura).

Slide nº 7

1. Introdução

1.2. Conceitos de **experimento**, tratamento, unidade experimental, delineamento experimental

O termo **condições controladas** se refere a que somente as diferentes alternativas do fator ou fatores em estudo (tratamentos) podem variar, sendo as demais condições mantidos constantes, salvo erros não controláveis. Assim, no exemplo anterior, ficam constantes ou controlados a cultura escolhida, a época e a profundidade de semeadura, o método de preparo do solo, de irrigação, ou seja, o manejo em geral.

Slide nº 8

1. Introdução

1.2. Conceitos de **experimento**, tratamento, unidade experimental, delineamento experimental

O termo **planejado** indica que o pesquisador mantêm o controle do experimento, registrado em um projeto, sobre as variáveis em estudo. Todas as ações devem ser pré-definidas ou previstas. Deste modo, permite-se que o experimento seja repetido essencialmente sob as mesmas condições, salvo fatores não controláveis, também chamados aleatórios, os quais originam o erro experimental.

Slide nº 9

1. Introdução

1.2. Conceitos de **experimento**, tratamento, unidade experimental, delineamento experimental

Um experimento é constituído basicamente por um conjunto de unidades experimentais sobre as quais são aplicados os tratamentos, de forma casualizada, das quais se obtêm os dados experimentais.

Slide nº 10

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Tratamento - Em experimentação, a denominação “tratamento” se refere a cada uma das alternativas de um fator em estudo para resolver um dado problema.

- São os diferentes níveis ou variáveis independentes de um modelo matemático.

- É a variável que expressa o problema a ser resolvido. Se, por exemplo, o problema do pesquisador é comparar quatro métodos de preparo do solo (métodos M1, M2, M3 e M4) com o tradicional (método MT), o pesquisador tem cinco tratamentos (MT, M1, M2, M3 e M4) que deverão ser avaliados para a comparação.

Slide nº 14

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Tratamentos:

-Qualitativos

-Quantitativos

Slide nº 15

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Qualitativos

- quando se diferenciam por suas qualidades (fomas, marcas, métodos, tipos, espécies, cultivares, etc.)

Slide nº 16

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Quantitativos

- quando podem ser ordenados segundo algum critério numérico, como por exemplo: doses de um fertilizante (0, 10, 20, ... kg/ha); doses de defensivos; espaçamentos entre plantas; densidade de semeadura; idade ou tempo; etc.

Slide nº 18

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Como estudar o efeito dos tratamentos?

Mede-se uma ou mais variáveis denominadas de variáveis resposta, como, por exemplo, altura da planta, diâmetro do caule, produtividade de grãos, incidência de pragas ou moléstias, diâmetro da altura do peito.

As variáveis resposta são quase sempre quantitativas, isto é, obtidas por medição ou contagem, que não devem ser confundidas com os tratamentos que são as variáveis que estão sendo comparadas.

Slide nº 21

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Tratamentos de efeito:

-Fixo

-Aleatório

Slide nº 22

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Efeito fixo:

Quando os tratamentos são escolhidos pelo pesquisador (de forma que o experimento possa ser repetido com os mesmos tratamentos) estes são denominados fixos (de efeito fixo).

Exemplo: métodos de irrigação, doses de fertilizantes, cultivares, etc.

- conclusões válidas somente para os tratamentos estudados

Slide nº 23

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Efeito aleatório:

Quando os tratamentos são obtidos como uma amostra aleatória de uma população de tratamentos (como nos casos em que os tratamentos são destruídos durante o experimento), não se pode repetir o experimento com os mesmos tratamentos e estes são denominados de "efeito aleatório".

Exemplo: Uma amostra de várias linhagens de milho

- conclusões são para todas as linhagens (população)

Slide nº 24

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Exemplo: Experimento que avalia quatro métodos de irrigação (M1, M2, M3 e M4).
Tem-se quatro tratamentos qualitativos.

O Experimento é realizado sob condições controladas, isto é, para uma espécie, um tipo de solo, uma época, um nível de adubação, etc. No experimento todos os materiais utilizados e todos os tratos culturais aplicados devem ser uniformes, menos os métodos de irrigação que são os tratamentos de efeito fixo. Assim, os resultados serão válidos para as condições constantes (ou controladas) no experimento.

Slide nº 25

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Este tipo de experimento que estuda somente um fator (método de irrigação) é denominado **monofatorial** e tem sua amplitude de inferência limitada às condições mantidas uniformes ou constantes.

Se, por exemplo, variar o nível de adubação então, os resultados dos métodos de irrigação poderão não ser os mesmos.

Slide nº 26

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Para aumentar a amplitude de inferência dos resultados dos experimentos são usados os tratamentos fatoriais, nos quais dois ou mais fatores, cada um com dois ou mais níveis, são estudados simultaneamente no experimento.

Neste caso, os tratamentos são formados pela combinação dos diferentes níveis de cada fator, onde cada fator pode ser de efeito fixo ou aleatório.

Slide nº 27

1. Introdução

1.2. Conceitos de experimento, **tratamento**, unidade experimental, delineamento experimental

Exemplo: Experimento **bifatorial**, isto é, com dois fatores:

Fator A = métodos de irrigação (3 níveis)
(A_1 = Método 1; A_2 = Método 2, A_3 = Método 3)

Fator B = tipos de preparo do solo (2 níveis)
(B_1 = Tipo 1; B_2 =Tipo 2)

–Temos então 3 x 2 = 6 tratamentos
A_1B_1; A_1B_2; A_2B_1; A_2B_2; A_3B_1 e A_3B_2.

Slide nº 28

1. Introdução

1.2. Conceitos de experimento, tratamento, **unidade experimental**, delineamento experimental

Unidade Experimental - é a menor unidade de um experimento na qual é aplicado um tratamento.

Slide nº 29

1. Introdução

1.2. Conceitos de experimento, tratamento, **unidade experimental**, delineamento experimental

Experimentos de campo:
unidades experimentais = parcelas

A unidade experimental (UE) poderá ser uma área de campo, um vaso com solo, um animal ou um grupo de animais, uma sementeira, uma "placa de Petri", um tubo de ensaio, uma planta, uma folha da planta, uma máquina, etc.

Slide nº 30

1. Introdução

1.2. Conceitos de experimento, tratamento, **unidade experimental**, delineamento experimental

Exemplos:

Para avaliar diferentes produtos no combate ao cupim em madeira, as UE deverão ser pedaços regulares (uniformes) de madeira;

Para avaliar diferentes tipos de máquina no preparo do solo, as UE deverão ser áreas de campo;

Para avaliar a fitotoxidade de herbicidas ou fungicidas usamos folhas em plantas vivas;

Para avaliar tipos de adubos para sementeiras de *Pinus,* as UE devem ser sementeiras com mudas de *Pinus* com determinada área.

Slide nº 31

1. Introdução

1.2. Conceitos de experimento, tratamento, **unidade experimental**, delineamento experimental

O número de unidades experimentais de um experimento depende do número de tratamentos (I) e do número de repetições (J).

Número de UE = I * J

em experimentos de campo, o número de UE seja no **mínimo igual a 20** para se obter uma precisão razoável

Slide nº 32

1.3 Princípios básicos da experimentação

1. Introdução

1.3. Princípios básicos da experimentação

Todo trabalho denominado de "experimento", que tem por objetivo comparar tratamentos e concluir sobre o comportamento dos mesmos com margem de erro conhecida, deve seguir os seguintes princípios básicos:

Repetição
Casualização

A maneira de se proceder a casualização resulta, segundo alguns autores, num terceiro princípio, o **Controle Local**.

Slide nº 34

1. Introdução

1.3. Princípios básicos da experimentação

Assim, somente teremos um experimento estatisticamente válido se houver **repetição e casualização** dos tratamentos sobre as **UE.**

Slide nº 35

1. Introdução

1.3. Princípios básicos da experimentação

O princípio da repetição refere-se à aplicação do mesmo tratamento sobre duas ou mais UE e, o princípio da casualização é a aplicação destes tratamentos aleatoriamente sobre as UE, isto é, sorteando qual a UE que receberá um determinado tratamento em cada repetição.

Não só a indicação de qual tratamento vai receber cada UE, mas também a ordem de execução de qualquer trato cultural ou avaliação a ser realizada no experimento requer casualização.

Slide nº 36

1. Introdução

1.3. Princípios básicos da experimentação

Exemplo:

Comparar o crescimento de duas progênies de Figueira (PA = progênie A e PB = progênie B).

Se plantarmos duas parcelas de mesma área (10 x 50 m), próximas ou não, sendo uma com PA e outra com PB, o fato de PA produzir mais do que PB pouco significa pois, além do fator progênie, outros fatores podem justificar a maior produção da PA (por exemplo, a PA pode ter sido cultivada em solo de maior fertilidade).

Slide nº 37

1. Introdução

1.3. Princípios básicos da experimentação

Pessoas não ligadas à experimentação acreditam que não há diferenças de ambiente entre **UE** contíguas. A prática tem demonstrado, entretanto, que, embora uma área pareça homogênea, as culturas se desenvolvem de forma diferente de um ponto para outro, mesmo sendo muito próximos.

Slide nº 38

1. Introdução

1.3. Princípios básicos da experimentação

Podemos contornar esse problema, cultivando várias parcelas com PA e várias parcelas com PB e, considerar a média de produção de cada progênie. Neste caso, usamos o princípio da **repetição**.

Este, por si só, não contorna o problema pois, se todas as parcelas cultivadas com a PA estiverem agrupadas propositalmente num local com melhores condições ambientais para a produção do que as parcelas da PB, as diferenças entre as médias de produção das progênies ainda estão confundidas com outros fatores.

Slide nº 39

1. Introdução

1.3. Princípios básicos da experimentação

Assim, torna-se necessário usar, além do princípio da repetição, um segundo princípio, o da **casualização** ou **aleatorização**.

Slide nº 40

1. Introdução

1.3. Princípios básicos da experimentação

Alguém pode argumentar que uma distribuição sistemática seguindo, por exemplo, as casas de um tabuleiro de xadrez traria uma melhor distribuição do que aquela obtida por sorteio.

A casualização é usada para obter a independência dos erros que é uma exigência dos modelos matemáticos usados pela Estatística na interpretação probabilística dos resultados obtidos no experimento, e deve ser satisfeita caso se pretenda fazer qualquer inferência estatística sobre o comportamento dos tratamentos com base nos dados obtidos.

Slide nº 41

1. Introdução

1.3. Princípios básicos da experimentação

Admitindo-se que temos quatro parcelas com PA e cinco parcelas com PB e que a distribuição das progênies nas parcelas tenha sido realizada por sorteio. Neste caso, a probabilidade de que a média de PA seja maior do que a média de PB somente devido ao acaso é: P = 4! 5!/ 9! = 1/126 = 0,8 %.

Slide nº 42

1. Introdução

1.3. Princípios básicos da experimentação

O resultado obtido para as progênies pode de fato provir de simples acaso, isto é, que as duas progênies sejam realmente equivalentes e que a diferença a favor de PA provenha de causas aleatórias, por exemplo, parcelas com PA foram cultivadas em solo de maior fertilidade.

Porem, a probabilidade disto acontecer é de 1/126. Logo há uma probabilidade de 125/126 de que o resultado obtido não tenha sido casual e se deva a um fator sistemático como o maior potencial genético da PA.

Slide nº 43

1. Introdução

1.3. Princípios básicos da experimentação

As repetições são necessárias para **estimar o erro experimental** e para avaliar de forma mais precisa o efeito de cada tratamento.

A casualização leva a obtenção de estimativas imparciais das médias dos tratamentos e do erro experimental.

Erro experimental é a variância entre os valores observados nas unidades experimentais que receberam o mesmo tratamento.

Slide nº 44

1. Introdução

1.3. Princípios básicos da experimentação

Consideramos, agora, que todo experimento tem **I** tratamentos e **J** repetições e, com isto, **I.J = N** unidades experimentais.

Além disso, **I**≥**2** e **J**≥**2** e, em geral N≥20

Slide nº 45

1. Introdução

Delineamentos experimentais

A casualização dos **I** tratamentos sobre as **N** unidades experimentais pode ser feita sem restrições ou com uma ou mais restrições.

Da maneira de fazer a casualização dos tratamentos nas unidades experimentais decorrem os "delineamentos experimentais" (**experimental designs** - em inglês; **diseños experimentales** - em espanhol e **dispositifs experimentales** - em francês).

Consideramos três situações:

Slide nº 46

1. Introdução

Delineamentos experimentais

a) Sem restrição - resulta no delineamento experimental **Inteiramente Casualizado** (DIC) no qual, qualquer uma das **N** unidades experimentais pode receber (por sorteio) qualquer um dos **I** tratamentos em qualquer uma das **J** repetições, pressupondo-se que estas sejam uniformes.

Slide nº 47

1. Introdução

Delineamentos experimentais

b) Uma restrição - ocorre no caso em que não se dispõe de N **UE** uniformes. Neste caso, devemos organizar J blocos (bloco = conjunto de I **UE** uniformes), onde cada bloco recebe uma vez todos os **I** tratamentos. Os **J** blocos se equivalem às J repetições. Os **I** tratamentos são casualizados dentro de cada bloco. Neste caso temos o delineamento experimental denominado de **Blocos Completos ao Acaso** ou simplesmente **Blocos ao Acaso**, ou ainda, **Blocos Casualizados (DBA)**.

Slide nº 48

1. Introdução

Delineamentos experimentais

Neste delineamento, os blocos podem estar em condições diferentes ou sofrer manejos diferentes, só não podem ocorrer diferenças dentro de cada bloco, ou seja, entre as **UE** que receberam os diferentes tratamentos.

As diferenças entre blocos podem existir antes do início do experimento (a priori), devido a área experimental desuniforme, ou podem ocorrer durante a execução do experimento (a posteriori), por manejo diferenciado devido, muitas vezes, ao tamanho do experimento (Ex: capina-se ou colhe-se um bloco cada dia ou cada semana).

Slide nº 49

1. Introdução

Delineamentos experimentais

c) Duas restrições - as **UE** são agrupadas segundo dois critérios de desuniformidade. Há formação de blocos em dois sentidos, denominados de filas e colunas. Fila é um conjunto de **UE** uniformes pelo critério **F** e coluna é um conjunto de **UE** uniformes pelo critério **C**. Cada fila recebe uma vez cada tratamento, o mesmo ocorrendo para coluna. Assim, o número de filas, colunas e tratamentos serão iguais. Este modo de casualização resulta no delineamento experimental denominado de **Quadrado Latino**.

Slide nº 50

1. Introdução

Delineamentos experimentais

Os três delineamentos acima (**Inteiramente Casualizado, Blocos ao Acaso e Quadrado Latino**) constituem os delineamentos básicos. Outras formas de casualização com duas ou mais restrições levam a outros delineamentos, tais como: **blocos incompletos** (equilibrados ou não), **parcelas subdivididas, reticulados**, etc.

Slide nº 51

1. Introdução

Delineamentos experimentais

De modo geral, quanto maior o número de restrições na casualização menor será o número de graus de liberdade associados ao erro experimental e, se esta restrição não é eficiente no sentido de reduzir a variância do erro experimental, pode haver perda de eficiência do experimento. Portanto, a restrição (conhecida como **controle local**) só deve ser usada quando efetivamente necessária.

Slide nº 52

1. Introdução

Exercícios:

1) Diferencie tratamentos qualitativos e quantitativos e exemplifique cada um deles.

2) Quais são os três princípios básicos da experimentação?

3) Qual o delineamento adequado quando as unidades experimentais são homogêneas, isto é, a variação entre as unidades experimentais é irrelevante e não existe procedimento lógico para se obter grupos de unidades experimentais semelhantes?

Slide nº 53

1. Introdução

Exercícios:

4) Seja um experimento em que foram avaliados os efeitos de quatro substratos (casca de arroz, húmus, areia e mistura de 50% húmus + 50% areia) para produção de mudas de eucalipto, no delineamento blocos ao acaso com seis repetições. Foram medidas a altura de planta (em cm) e o diâmetro do caule (em mm). Pergunta-se:

a) Número de unidades experimentais por tratamento = ...
b) Número de unidades experimentais do experimento = ...
c) Número de variáveis avaliadas = ...
d) Número de repetições = ...
e) Número de blocos = ...
f) Número de tratamentos = ...
g) Os tratamentos são quantitativos? ....
h) Os tratamentos são de efeito fixo? ....

Slide nº 54

2 Delineamentos experimentais básicos

2. Delineamentos experimentais básicos

2.1. Inteiramente casualizado

2.2. Blocos completos ao acaso

2.3. Quadrado latino

Slide nº 55

2.1 Inteiramente casualizado

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Este delineamento é utilizado quando as unidades experimentais (UE) são essencialmente uniformes ou homogêneas, isto é, a variação entre as UE é irrelevante e não existe procedimento lógico para se obter em grupos de UE semelhantes.

Slide nº 56

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

A homogeneidade é exigida no tocante ao material, ao ambiente, aos tratos culturais, enfim, a qualquer operação realizada no experimento. O único componente que pode variar, deliberadamente, de uma UE para outra são os tratamentos.

Slide nº 57

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

A maior dificuldade reside em decidir se as UE são uniformes ou não uniformes. Em geral, quando não há um critério suficientemente objetivo de classificação das UE em grupos distintos, isto é, que tenha maior uniformidade (menor variância) entre as UE <u>dentro</u> do grupo do que <u>entre</u> grupos, usam-se o delineamento inteiramente casualizado.

Resultados de anos anteriores e/ou de experimentos em branco (sem tratamentos) são úteis para avaliar a homogeneidade das UE.

Slide nº 58

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

A necessidade de UE uniformes implica na utilização deste delineamento em experimentos de laboratório e em casas de vegetação onde o material experimental (solo, substrato, etc.) é inicialmente homogeneizado e posteriormente dividido em porções para formar as UEs (vasos, bandejas, placas de Petri, etc.) sobre as quais são aplicados os I tratamentos em J repetições.

Slide nº 59

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

No caso de experimentos em casas de vegetação as UE devem ser periodicamente trocadas de lugar de maneira aleatória. Caso isto não seja feito, possíveis variações no ambiente, como a proximidade de janelas, localização no interior ou no exterior da mesa (bordadura), atuariam durante todo o experimento sobre as mesmas UE, aumentando o erro experimental.

Slide nº 60

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Experimentação com animais - para usar o DIC deve ter: condição ambiental homogênea, utilizar animais homogêneos quanto ao peso, idade, sexo e raça, o que não é fácil de conseguir com animais de grande porte. Por isso, este delineamento é mais utilizado com pequenos animais.

Slide nº 61

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Comparado com delineamentos mais complexos, o delineamento inteiramente casualizado apresenta **algumas vantagens, tais como**:

Slide nº 62

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

a) Qualquer número de tratamentos ou de repetições pode ser usado. O número de repetições também pode variar de um tratamento para outro, intencionalmente (pela falta de UE ou de material) ou por acidente (morte de animal, planta = perda de parcela), sem que isso dificulte a análise. No entanto, deve-se preferir usar o mesmo número de repetições para todos os tratamentos.

Slide nº 63

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

b) O número de graus de liberdade do erro experimental (resíduo) é o maior possível. Este fato implica em maior precisão do experimento quando as UE são uniformes.

Slide nº 64

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Organização de um experimento no DIC:

Em resumo, temos I tratamentos e J repetições e, por conseguinte, necessitamos de IJ=N UE identificadas de 1 a N.

A distribuição dos I tratamentos J vezes nas N UE é feita aleatoriamente de modo que cada UE tenha a mesma probabilidade (p=J/N) de receber um dado tratamento.

Slide nº 65

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Exemplo:

Experimento para avaliar 4 tipos de cobertura para sementeira de Eucalyptus sp. (ou seja, 4 tratamentos), assim definidos: A = Sem cobertura (apenas solo), B = Solo + casca de arroz, C = Solo + acículas de Pinus trituradas, e D = Solo + matéria orgânica.

Usando 5 repetições teremos 20 UE. A UE neste caso é constituída por uma bandeja (30 x 30 x 10 cm) preenchida com solo homogeneizado e semeada com certa quantidade de sementes. As UEs, todas homogêneas, são colocadas sobre uma mesa dentro de uma casa de vegetação devidamente numeradas conforme o esquema a seguir:

Slide nº 66

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

1 B	2 C	3 A	4 B	5 A	6 B	7 D	8 C
9 B	10 C	11 A	12 A	13 D	14 A	15 D	16 B
17 C	18 D	19 C	20 D				

SORTEIO:

Agora deve-se aplicar os tratamentos, ou seja, as coberturas definidas acima. Existem diversas maneiras práticas de fazer esta distribuição (sorteio).

Slide nº 67

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

- usar uma tabela de números aleatórios existente em livros de estatística. Nesse caso abre-se ao acaso uma página que contenha números aleatórios e, olhando para o lado, coloca-se o dedo num local qualquer da página. A partir do ponto assinalado examinam-se duas colunas de algarismos e anota-se a ordem dos números de 1 a 20 encontrados. Os números repetidos e aqueles maiores que 20 são ignorados. Ao chegar ao fim da coluna reinicia-se no topo da página examinando as duas colunas seguintes até que todos os números tenham sido encontrados.

Slide nº 68

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

TABELA DE NÚMEROS ALEATÓRIOS*

NIIPS – CSEO

LC	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
01	4	5	0	5	8	7	4	4	6	4	2	4	6	3	9	3	3	5	5	1	8	7	3	6	5	7	3	2	8	3
02	9	8	0	6	4	4	2	1	8	0	3	4	9	8	1	2	8	8	3	0	7	8	2	2	7	5	4	7	3	6
03	4	1	4	1	0	1	6	7	4	1	8	6	4	9	4	2	4	4	0	7	8	0	0	5	4	8	5	3	2	6
04	7	4	4	9	5	1	0	6	7	3	9	3	2	5	4	2	8	8	5	3	8	7	8	1	1	8	7	5	9	4
05	7	3	0	3	3	6	2	0	4	2	8	1	9	8	2	7	5	8	6	0	7	1	8	3	0	7	6	3	9	5
06	6	6	6	4	8	6	3	2	8	4	0	8	9	7	4	5	6	0	7	6	0	9	2	9	3	9	6	9	7	6
07	8	5	3	8	1	6	6	7	8	1	3	3	7	1	5	3	1	6	2	8	8	7	2	1	3	6	9	0	8	1
08	3	5	5	0	7	2	1	3	3	3	0	7	1	5	3	7	2	3	1	4	9	2	3	4	5	1	4	9	3	9
09	2	9	6	3	8	1	2	1	0	8	5	7	1	4	9	5	6	3	7	6	2	4	7	4	0	5	6	1	7	5
10	6	6	8	4	4	7	4	8	4	6	9	7	2	7	4	5	1	7	5	2	0	2	5	8	1	1	6	2	0	3
11	6	2	2	7	8	8	8	2	0	3	9	9	3	5	1	5	0	5	9	5	9	2	2	3	2	8	4	4	2	0
12	6	8	8	7	9	6	7	3	9	3	5	3	2	3	9	3	8	8	0	9	7	0	9	9	5	4	5	5	1	8
13	7	8	2	8	9	3	2	0	7	5	9	0	6	7	0	6	6	2	5	3	4	5	2	2	0	9	7	4	7	1
14	6	4	3	8	8	5	0	0	0	5	1	4	7	3	7	4	6	7	9	5	1	3	5	3	2	4	7	2	3	2
15	3	6	1	1	7	8	3	9	6	3	2	6	1	8	8	3	7	8	9	2	9	3	8	7	3	5	8	7	2	6
16	7	5	5	1	5	3	2	7	8	1	7	1	2	2	0	6	8	6	5	8	7	1	0	2	8	8	0	5	6	6
17	8	8	8	1	5	9	7	6	2	5	5	2	8	8	1	9	0	0	5	9	2	0	1	3	9	8	6	3	2	5
18	4	6	3	9	8	2	7	3	2	8	0	2	1	2	9	2	2	6	9	5	3	1	2	5	0	0	0	5	9	6
19	4	0	6	5	1	7	6	7	1	0	3	1	9	3	7	7	0	0	9	2	9	3	8	1	6	5	5	5	0	9
20	5	8	0	9	3	4	7	7	0	5	4	1	5	1	8	3	4	3	8	3	9	6	6	7	7	2	3	2	5	7
21	0	5	8	1	2	0	4	5	5	8	0	6	4	8	4	4	1	9	2	5	6	1	3	0	3	1	2	1	2	3
22	7	7	6	4	9	4	6	6	6	7	1	5	0	3	2	8	4	4	5	0	6	8	6	7	5	2	8	3	6	5
23	2	1	4	5	2	2	4	2	5	7	0	0	5	1	7	6	2	9	8	8	4	9	0	0	1	8	2	8	1	1

nº 69

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Suponha-se que tenha sido obtida a seguinte seqüência:

12 5 14 11 3 4 16 1 6 9 10 8 19 17 2 13 20 15 18 7

As UE com os 5 primeiros números (12, 5, 14, 11 e 3) receberão o tratamento A, aquelas com os 5 números seguintes (4, 16, 1, 6 e 9) receberão o tratamento B e assim por diante.

Slide nº 70

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

O mesmo procedimento pode ser feito usando computador ou mesmo máquinas de calcular que tenham a função RAND.

Slide nº 71

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Outra maneira de fazer o sorteio é com o uso de papéis. Nesse caso os papéis devem ter o mesmo tamanho, a mesma cor e não devem ter sinais especiais que possam influenciar a pessoa que está procedendo ao sorteio. Coloca-se numa urna 5 papéis com a letra A, 5 papéis com a letra B, 5 com a letra C e 5 com a letra D. Mistura-se bem e retira-se um papel de cada vez anotando a letra obtida. Suponha-se que tenha sido obtida a seguinte seqüência:

B C A B A B D C B C A A D A D B C D C D

A letra indica o tratamento que será aplicado na UE. Assim a UE número 1 receberá o tratamento B, a UE número 2 receberá o tratamento C, a UE número 3 receberá o tratamento A e assim sucessivamente.

Slide nº 72

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Examinando o sorteio, alguns podem concluir que a distribuição não foi de todo satisfatória. Certamente haverá parcelas contíguas com o mesmo tratamento. Um pesquisador desavisado será compelido a fazer uma melhor distribuição dos tratamentos, mas esta prática é tecnicamente desaprovada.

A matemática pode prever qual a probabilidade de ocorrer qualquer das disposições obtidas pelo sorteio, mas não pode prever qual é a probabilidade do pesquisador obter qualquer disposição por sua própria vontade.

Slide nº 73

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

1 B	2 C	3 A	4 B	5 A	6 B	7 D	8 C
9 B	10 C	11 A	12 A	13 D	14 A	15 D	16 B
17 C	18 D	19 C	20 D				

Tabela necessária para cada experimento.

U E	Trat.	Y1	Y2	Y3...
1	B	...	...	...
2	C	...	...	...
....	....	....	....	....
20	D	...	...	...

Y1, Y2, Y3, ... - são as variáveis a serem medidas (variáveis respostas).

Slide nº 74

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Aplicam-se, então os tratamentos sobre as UE, conforme a casualização constante no croqui. Após, inicia-se o processo de avaliação dos efeitos dos tratamentos que, no exemplo, poderiam ser a velocidade de germinação (Y1), a percentagem final de germinação (Y2), a altura (Y3), o diâmetro (Y4) e o peso da planta (Y5) quando estas atingirem certa idade. Estes dados deverão ser analisados para concluirmos sobre os efeitos dos tratamentos, isto é, se ocorrem diferenças ou não.

Slide nº 75

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Porque usar análise estatística?

Seja Y a variável que representa o peso das mudas aos 30 dias após a semeadura.

	Repetições					$Y_{i.}$	$\overline{Y}_{i.}$	$S_i^2 = \hat{\sigma}_i^2$
Tratamento	1	2	3	4	5	(Soma)	(Média)	(Variância)
A	31	23	22	45	29	150	30,0	85,0
B	24	19	42	33	33	151	30,2	79,7
C	59	74	43	42	57	275	55,0	173,5
D	54	46	61	37	52	250	50,0	81,5
Média							41,3	104,9

$$s^2 = \frac{\sum (X_i - \overline{X})^2}{n-1} = \frac{\sum (Y_{ij} - \overline{Y}_{i.})^2}{n-1} = \frac{(31-30)^2 + (23-30)^2 + (22-30)^2 + (45-30)^2 + (29-30)^2}{5-1} = \frac{340}{4} = 85,0$$

Slide nº 76

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Observa-se que, numericamente, os tratamentos apresentam médias diferentes. Entretanto, nem toda a variação existente nos dados é devida ao efeito dos tratamentos pois, se assim fosse, os valores obtidos em todas as repetições do mesmo tratamento seriam iguais e na verdade não o são. Além do efeito dos tratamentos, manifesta-se a variação aleatória ou ao acaso, que é devida a causas não controladas de variação que incidem no experimento, embora o pesquisador tenha procurado propiciar as condições mais uniformes possíveis.

Slide nº 77

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Variância do acaso = 104,9 (média das variâncias).

Variância entre as médias dos tratamentos:

$$J\left[\frac{\Sigma_i\left(\overline{Y}_{i.}-41{,}3\right)^2}{I-1}\right]=5(171{,}4)=857{,}0$$

Slide nº 78

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

Logo a variância entre as médias dos tratamentos (857,0) (que inclui a variância do acaso) é maior que a variância do erro (variância do acaso = 104,9).

Resta saber se é significativa em nível α de significância (erro tipo I), isto é, saber se as diferenças entre as médias são casuais ou se um fator sistemático (efeito de tratamentos) é o responsável pelas diferenças.

Slide nº 79

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.1 Caracterização e uso

É necessário então definir o modelo matemático e suas pressuposições para efetuar uma análise probabilística dos dados observados.

Slide nº 80

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.2 Modelo matemático e pressuposições

Vamos supor que foram observadas em cinco plantas (n = 5) a variável Y "Número de insetos por planta".

Variável Y_i	Média (m)	Erros ou desvios ou resíduos ($e_i = Y_i$ - m)
2	6	-4
4	6	-2
6	6	0
8	6	2
10	6	4
soma	-	0

Podemos escrever o modelo matemático dessa variável como sendo $Y_i = m + e_i$, ou seja, o valor observado é função de uma constante (m) mais o efeito de um erro (e_i). No DIC, acrescentamos o efeito de tratamento (t_i).

Slide nº 81

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.2 Modelo matemático e pressuposições

$$\mathbf{Y_{ij} = m + t_i + e_{ij}}$$

$\mathbf{Y_{ij}}$ = valor observado referente à variável Y na unidade experimental que recebeu o tratamento **i (i=1,2,...,I)** na repetição **j (j=1,2, ..., J)**;

m = constante;

$\mathbf{t_i}$ = efeito do tratamento **i** (pode ser fixo ou aleatório);

$\mathbf{e_{ij}}$ = contribuição da variação não controlada referente à observação Y_{ij}.

Slide nº 82

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.2 Modelo matemático e pressuposições

a) **Aditividade** - os diversos efeitos são aditivos, isto é, tem-se uma soma de efeitos e estes efeitos são independentes;
b) **Aleatoriedade** - os erros ou desvios $\mathbf{e_{ij}}$ são conjuntamente independentes, isto é, não são correlacionados;
c) **Homogeneidade de variâncias** - todos os erros $\mathbf{e_{ij}}$ tem a mesma variância σ^2;
d) **Normalidade dos erros** - os erros $\mathbf{e_{ij}}$ tem distribuição normal.

Slide nº 83

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.3 Estimação dos parâmetros do modelo

Resultados de um experimento no DIC

	repetições					Total	Média
Tratamento	1	2	3	..	J	$Y_{i.}$	$\bar{Y}_{i.}$
1	Y_{11}	Y_{12}	Y_{13}	...	Y_{1J}	$Y_{1.}$	$\bar{Y}_{1.}$
2	Y_{21}	Y_{22}	Y_{23}	...	Y_{2J}	$Y_{2.}$	$\bar{Y}_{2.}$
3	Y_{31}	Y_{32}	Y_{33}	...	Y_{3J}	$Y_{3.}$	$\bar{Y}_{3.}$
...	...	...	...	...	...	...	...
I	Y_{I1}	Y_{I2}	Y_{I3}	...	Y_{IJ}	$Y_{I.}$	$\bar{Y}_{i.}$

Média geral do experimento = Y../IJ

Slide nº 84

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.3 Estimação dos parâmetros do modelo

As estimativas de m, ti e eij podem ser obtidas por:

$$\hat{m} = Y_{..} / IJ$$

$$\hat{t}_i = Y_{i.} / J - \hat{m}$$

$$\hat{e}_{ij} = Y_{ij} - \hat{m} - \hat{t}_i$$

Slide nº 85

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Usamos o método dos mínimos quadrados e o princípio de que a Soma de Quadrados do Erro (SQ_E) seja mínima. $SQ_E = \sum_{ij} \hat{e}_{ij}^2$

Em uma ANOVA a variação total (SQ_{TOTAL}) é decomposta em variação devida ao erro (SQ_E) e variação devida às estimativas dos parâmetros (SQ_{TRAT}).

A variação entre tratamentos também pode ser expressa por entre grupos e variação dentro de tratamentos ou dentro de grupos corresponde ao erro ou resíduo.

Slide nº 86

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Quadro de análise de variância para o delineamento inteiramente casualisado.

Causas ou fontes de Variação	Graus de Liberdade (GL)	Soma de Quadrados (SQ)	Quadrado Médio (QM)	Fcal
Tratamentos (entre grupos)	$GL_{TRAT} = I\text{-}1$	SQ_{TRAT}	QM_{TRAT}	QM_{TRAT}/QM_E
Erro ou resíduo (dentro de grupos)	$GL_E = I(J\text{-}1)$	SQ_E	QM_E	-
Total	$GL_{TOTAL} = IJ\text{-}1$	SQ_{TOTAL}	-	-

I = número de tratamentos (grupos).
J = número de repetições, ou elementos de cada grupo.

Quadrado Médio = Soma de Quadrados/Graus de Liberdade.

Logo: $QM_{TRAT} = SQ_{TRAT}/GL_{TRAT}$ e $QM_E = SQ_E/GL_E$

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

As expressões para o cálculo das somas de quadrados são as seguintes:

$$SQ_{TOTAL} = \sum_{ij} Y_{ij}^2 - \frac{Y_{..}^2}{IJ}$$ com IJ-1 graus de liberdade.

$$SQ_{TRAT} = \frac{1}{J}\sum_{i} Y_{i.}^2 - \frac{Y_{..}^2}{IJ}$$ com I-1 graus de liberdade.

$SQ_E = SQ_{TOTAL} - SQ_{TRAT}$ com IJ-1-(I-1) = I(J-1) graus de liberdade.

O termo $\frac{Y_{..}^2}{IJ}$ é denominado de fator de correção (FC).

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Até agora preenchemos o quadro de análise de variância. Agora precisamos interpretar o efeito de tratamento, ou seja, fazer um teste de hipótese (teste F da análise de variância) para verificar se há ou não diferença significativa entre as médias de tratamento:

Slide nº 89

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Interpretação para Tratamentos de efeito fixo (Teste de Hipótese - ti de efeito fixo)

a) Estabelecer as hipóteses:

H_0: ti = 0 (para todo e qualquer i), ou seja, as médias de tratamentos não diferem.
H_1: ti ≠ 0, (para algum i), ou seja, pelo menos um contraste de médias de tratamento difere.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

Slide nº 90

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

c) Calcular o valor de Fcal entre tratamentos (grupos) ➔ Fcalc = QM_{TRAT}/QM_E.

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_{TRAT};\ GL_E)$;

Veja tabela F a seguir (5%)

Slide nº 91

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

GL_{TRAT}: n = graus de liberdade do numerador

GL_E: m

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 92

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

e) Decisão e conclusão

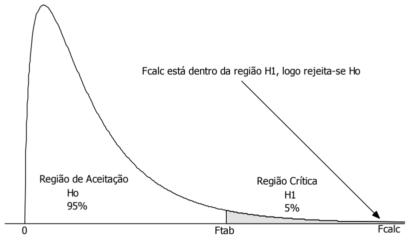

- se Fcalc ≥ Ftab, rejeitamos H_0 e concluímos que as médias dos tratamentos (grupos) diferem entre si, em nível de 5% de probabilidade de erro ou de significância. Ou ainda, concluímos que $t_i \neq 0$ para algum i, ou melhor, no mínimo duas médias de tratamentos diferem entre si e, a diferença existente não pode ser atribuída à variação do acaso.

Slide nº 93

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

e) Decisão e conclusão

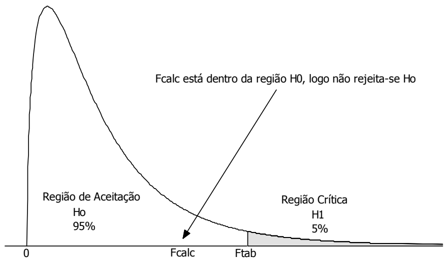

- se Fcalc < Ftab, não rejeitamos H_0 e concluímos que as médias dos tratamentos (grupos) não diferem entre si, ou seja, a diferença entre as médias dos grupos pode ser atribuída ao acaso.

Slide nº 94

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Avaliação da precisão experimental

A precisão experimental pode ser avaliada pela magnitude do erro experimental. Quanto menor o erro experimental, mais preciso é o experimento. A estatística coeficiente de variação (CV) serve para avaliar a precisão experimental.

O CV é calculado pela seguinte expressão:

$$CV = \frac{\sqrt{QME}}{\text{média}} x100$$

O autor Pimentel Gomes sugeriu a seguinte classificação da precisão experimental de acordo com o CV.

CV (%)	Classificação do CV	Classificação da Precisão Experimental
< 10	Baixo	Alta
≥ 10 e < 20	Médio	Média
≥ 20 e < 30	Alto	Baixa
≥ 30	Muito Alto	Muito Baixa

Slide nº 95

2.1 Delineamento Inteiramente Casualizado (DIC)
2.1.4 Análise de Variância (ANOVA)

Após o teste de hipótese para interpretarmos o efeito de tratamento salientamos o seguinte: Se concluirmos que não há diferença entre as médias de tratamento, ou seja, as diferenças existentes podem ser atribuídas ao acaso, ou ainda, não rejeitamos H_0 não precisamos fazer mais nada. No entanto, se concluirmos que há diferença significativa entre as médias de tratamentos, ou seja, rejeitamos H_0, o que sabemos é que no mínimo duas médias (a maior e a menor média) diferem. Precisamos comparar as demais médias de tratamento e para isso quando os tratamentos são qualitativos usamos testes de comparação múltipla de médias (Tukey, Duncan, Scott Knott, DMS, e outros) e quando os tratamentos são quantitativos, com mais de dois níveis usa-se, mais apropriadamente, a análise de regressão, que estabelece uma função entre a variável dependente (medida no experimento) e a variável independente (tratamento aplicado).

Slide nº 96

2.1 Delineamento Inteiramente Casualizado (DIC)

Exemplo:

Considere os dados de altura de planta na tabela abaixo de um experimento onde foram avaliados 4 substratos (areia, húmus, plantimax e palha) no crescimento de mudas de eucalipto. O experimento foi conduzido no DIC com 5 repetições.

Trat	Repetições					$Y_{i.}$	$\overline{Y}_{i.}$	S_i^2
	1	2	3	4	5	(Soma)	(Média)	(Variância)
Areia	48	40	43	41	48	220	44	14,5
Húmus	53	47	52	47	56	255	51	15,5
Plantimax	53	61	54	59	53	280	56	14,0
Palha	47	45	50	48	55	245	49	14,5
						$Y_{..}$ = 1000	$\overline{Y}_{..}$ = 50	

Slide nº 97

2.1 Delineamento Inteiramente Casualizado (DIC)

Pede-se:

a) Faça a análise de variância e teste de hipótese (teste F) para o efeito de tratamento a 5% de significância.

b) Estime os efeitos de t_i e e_{ij} e demonstre o seguinte:

$$\sum_{ij} \hat{e}_{ij} = 0 \qquad \sum_{ij} \hat{e}_{ij}^2 = SQ_E$$

$$\sum_i \hat{t}_i = 0 \qquad J\sum_i \hat{t}_i^2 = SQ_{TRAT}$$

Slide nº 98

2.1 Delineamento Inteiramente Casualizado (DIC)

a) Análise de variância e teste de hipótese (teste F) para o efeito de tratamento a 5% de significância.

Total geral ➔ Y.. = 1000
Média geral = 1000/20 = 50

Inicialmente calcula-se somas de quadrados.
I = 4 (tratamentos)
J = 5 (repetições)
IJ = número de unidades experimentais = 4 tratamentos x 5 repetições = 20 unidades experimentais

Slide nº 99

2.1 Delineamento Inteiramente Casualizado (DIC)

Somas de quadrados

$$SQ_{TOTAL} = \sum_{ij} Y_{ij}^2 - \frac{Y_{..}^2}{IJ}$$

$$SQ_{TOTAL} = (48^2 + 40^2 + \ldots + 48^2 + 55^2) - \frac{1000^2}{4 * 5} = 50604 - 50000 = 604$$

$$SQ_{TRAT} = \frac{1}{J}\sum_{i} Y_{i.}^2 - \frac{Y_{..}^2}{IJ}$$

$$SQ_{TRAT} = \frac{(220^2 + 255^2 + 280^2 + 245^2)}{5} - \frac{1000^2}{4 * 5}$$

$$SQ_{TRAT} = 50370 - 50000 = 370$$

Slide nº 100

2.1 Delineamento Inteiramente Casualizado (DIC)

Somas de quadrados

$$SQ_E = SQ_{TOTAL} - SQ_{TRAT}$$
$$SQ_E = 604 - 370 = 234$$

Slide nº 101

2.1 Delineamento Inteiramente Casualizado (DIC)

Quadro de análise de variância para o delineamento inteiramente casualisado.

Causas ou fontes de Variação	Graus de Liberdade (GL)	Soma de Quadrados (SQ)	Quadrado Médio (QM)	Fcal
Tratamentos (entre grupos)	$GL_{TRAT} = I-1$	SQ_{TRAT}	QM_{TRAT}	QM_{TRAT}/QM_E
Erro ou resíduo (dentro de grupos)	$GL_E = I(J-1)$	SQ_E	QM_E	-
Total	$GL_{TOTAL} = IJ-1$	SQ_{TOTAL}	-	-

Obtemos o seguinte:

Fonte de Variação	Graus de Liberdade	Soma de Quadrados	Quadrado Médio	F_{CALC}
Tratamentos	3	370	123,333	8,433
Erro	16	234	14,625	-
Total	19	604	-	-

Slide nº 102

2.1 Delineamento Inteiramente Casualizado (DIC)

Interpretação para Tratamentos de efeito fixo (Teste de Hipótese - ti de efeito fixo)

a) Estabelecer as hipóteses:

H_0: ti = 0 (para todo e qualquer i), ou seja, as médias de tratamentos não diferem.
H_1: ti ≠ 0, (para algum i), ou seja, pelo menos um contraste de médias de tratamento difere.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α). = 5%

Slide nº 103

2.1 Delineamento Inteiramente Casualizado (DIC)

c) Calcular o valor de Fcalc entre tratamentos (grupos) ➔ Fcalc = QM_{TRAT}/QM_E.
Fcalc = 123,333/14,625 = 8,433

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_{TRAT};\ GL_E)$;

Conforme tabela a seguir o valor de $F_{tabelado}$ é:

Ftab = $F_{5\%}$ (3; 16) = 3,24

Slide nº 104

2.1 Delineamento Inteiramente Casualizado (DIC)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador → GL_{TRAT}

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	$\boxed{3,24}$	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 105

2.1 Delineamento Inteiramente Casualizado (DIC)

e) Decisão e conclusão

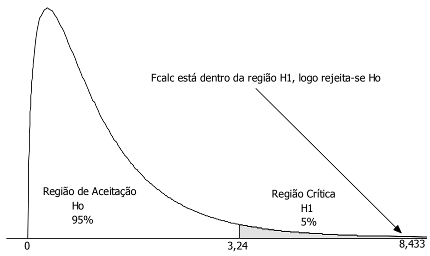

Fcalc (8,433) > Ftab (3,24), logo rejeitamos H_0 e concluímos que as médias dos tratamentos (substratos) diferem entre si, em nível de 5% de probabilidade de erro ou de significância. Ou ainda, concluímos que ti≠0 para algum i, ou melhor, no mínimo duas médias de substratos diferem entre si e, a diferença existente não pode ser atribuída à variação do acaso.

Slide nº 106

2.1 Delineamento Inteiramente Casualizado (DIC)

Avaliação da precisão experimental

$$CV = \frac{\sqrt{QME}}{\text{média}} x100$$

$$CV = \frac{\sqrt{14{,}625}}{50} x100 = 7{,}65\%$$

CV (%)	Classificação do CV	Classificação da Precisão Experimental
< 10	Baixo	Alta

Slide nº 107

2.1 Delineamento Inteiramente Casualizado (DIC)

b) Estime os efeitos de t_i e e_{ij} e demonstre o seguinte:

$$\sum_{ij} \hat{e}_{ij} = 0 \qquad \sum_{ij} \hat{e}_{ij}^2 = SQ_E$$

$$\sum_i \hat{t}_i = 0 \qquad J\sum_i \hat{t}_i^2 = SQ_{TRAT}$$

As estimativas de m, ti e eij podem ser obtidas por:

$$\begin{cases} \hat{m} = Y../IJ \\ \hat{t}_i = Y_i./J - \hat{m} \\ \hat{e}_{ij} = Y_{ij} - \hat{m} - \hat{t}_i \end{cases}$$

Slide nº 108

2.1 Delineamento Inteiramente Casualizado (DIC)

TRAT (I)	REP (J)	ALTURA (Yij)	m	Média trat	ti	eij	ti^2	eij^2
Areia	1	48	50	44	-6	4	36	16
Areia	2	40	50	44	-6	-4	36	16
Areia	3	43	50	44	-6	-1	36	1
Areia	4	41	50	44	-6	-3	36	9
Areia	5	48	50	44	-6	4	36	16
Húmus	1	53	50	51	1	2	1	4
Húmus	2	47	50	51	1	-4	1	16
Húmus	3	52	50	51	1	1	1	1
Húmus	4	47	50	51	1	-4	1	16
Húmus	5	56	50	51	1	5	1	25
Plantimax	1	53	50	56	6	-3	36	9
Plantimax	2	61	50	56	6	5	36	25
Plantimax	3	54	50	56	6	-2	36	4
Plantimax	4	59	50	56	6	3	36	9
Plantimax	5	53	50	56	6	-3	36	9
Palha	1	47	50	49	-1	-2	1	4
Palha	2	45	50	49	-1	-4	1	16
Palha	3	50	50	49	-1	1	1	1
Palha	4	48	50	49	-1	-1	1	1
Palha	5	55	50	49	-1	6	1	36
				soma	0	0	370	234

Soma = 1000
Média = 50

$\sum_i \hat{t}_i = 0$ $\quad \sum_{ij} \hat{e}_{ij} = 0$ $\quad J\sum_i \hat{t}_i^2 = SQ_{TRAT}$ $\quad \sum_{ij} \hat{e}_{ij}^2 = SQ_E$

Slide nº 109

Exercício

Prática 1 - Delineamento inteiramente casualizado (DIC)

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 110

2.2 Blocos completos ao acaso

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.1 Caracterização e uso

Este delineamento se caracteriza por possuir blocos e é o mais utilizado.

Bloco é um conjunto de unidades experimentais (UE) homogêneas, como por exemplo, parcelas numa mesma altitude (curva de nível), árvores de mesma altura, espécie e diâmetro; animais de uma mesma ninhada; tacos de madeira de uma mesma árvore; etc. Cada bloco recebe uma vez (repetição) cada tratamento e, desta forma o número de UE por bloco é igual ao número de tratamentos.

Os tratamentos são casualizados sobre as UE dentro de cada bloco.

Slide nº 112

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.1 Caracterização e uso

Os blocos podem diferir entre si a priori (antes da instalação do experimento) ou a posteriori (após a execução do experimento), devido as diferenças nos tratos culturais, coleta de dados, etc., feitos em cada bloco.

Não se deve utilizar blocos indiscriminadamente quando não há necessidade, pois este fato, pode resultar apenas numa redução dos graus de liberdade do erro experimental, sem a conseqüente redução da soma de quadrados e, com isto, a variância do erro será maior.

Slide nº 113

2.2 Delineamento Blocos ao Acaso (DBA)

2.2.1 Caracterização e uso

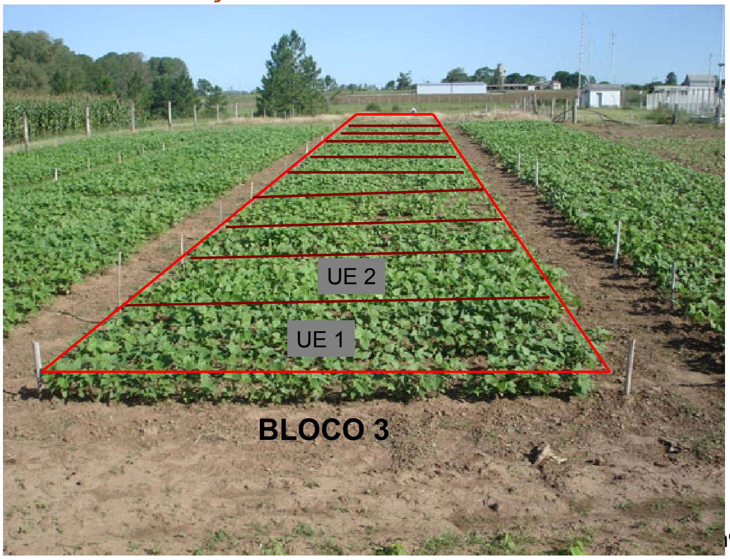

º 114

2.2 Delineamento Blocos ao Acaso (DBA)

2.2.1 Caracterização e uso

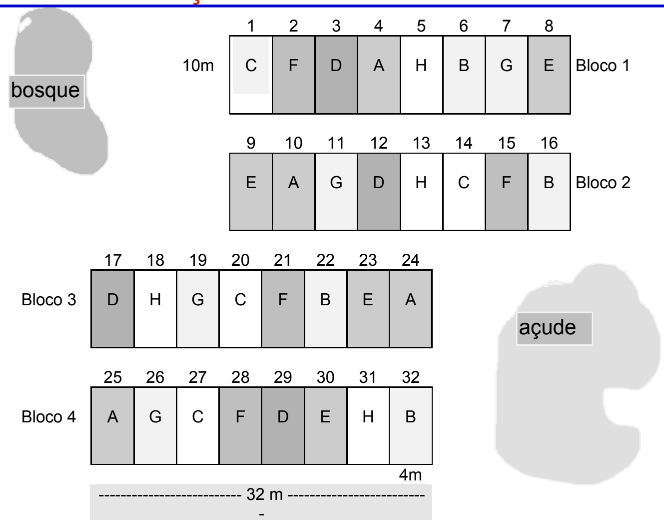

Slide nº 115

Figura 3.1 Esquema de um experimento no delineamento blocos casualizados.

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.1 Caracterização e uso

Esquema para as anotações dos resultados de um experimento no DBA

UE nº	Bloco (j)	Tratamento (i)	Variável (Y_{ij})
1	1	C	Y_{C1}
2	1	F	Y_{F1}
3	1	D	Y_{D1}
4	1	A	Y_{A1}
5	1	H	Y_{H1}
6	1	B	Y_{B1}
7	1	G	Y_{G1}
8	1	E	Y_{E1}
...	...	...	....
32=IJ	4=J	B	Y_{B4}

Y_{ij} é a resposta observada na **UE** que recebeu o tratamento **i (i = 1, 2, ..., 8 = H)** no bloco **j (j = 1, 2, 3, 4)**, o mesmo ocorrendo para as outras variáveis.

Slide nº 116

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.1 Caracterização e uso

Média do trat 1

Organização dos dados de um experimento no DBA, para uma variável (Y).

Tratamento	Blocos 1	2	3	4	Total ($Y_{i\cdot}$)	Média $\bar{Y}_{i\cdot}$
1	Y_{11}	Y_{12}	Y_{13}	Y_{14}	$Y_{1\cdot}$	$\bar{Y}_{1\cdot}$
2	Y_{21}	Y_{22}	Y_{23}	Y_{24}	$Y_{2\cdot}$	$\bar{Y}_{2\cdot}$
3	Y_{31}	Y_{32}	Y_{33}	Y_{34}	$Y_{3\cdot}$	$\bar{Y}_{3\cdot}$
4	Y_{41}	Y_{42}	Y_{43}	Y_{44}	$Y_{4\cdot}$	$\bar{Y}_{4\cdot}$
5	Y_{51}	Y_{52}	Y_{53}	Y_{54}	$Y_{5\cdot}$	$\bar{Y}_{5\cdot}$
Total $Y_{\cdot j}$	$Y_{\cdot 1}$	$Y_{\cdot 2}$	$Y_{\cdot 3}$	$Y_{\cdot 4}$	$Y_{\cdot\cdot}$	$\bar{Y}_{\cdot\cdot}$

Total do bloco 1

Total do tratamento 1

Total geral do experimento

Total de tratamento == > $Y_{i\cdot} = \sum_j Y_{ij}$

Total de bloco == > $Y_{\cdot j} = \sum_i Y_{ij}$

Total geral do experimento == > $Y_{\cdot\cdot} = \sum_{ij} Y_{ij}$

Média do tratamento i == > $\bar{Y}_{i\cdot} = Y_{i\cdot}/J$

Slide nº 117

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.2 Modelo matemático e pressuposições

$$Y_{ij} = m + t_i + b_j + e_{ij}$$

$\mathbf{Y_{ij}}$ = valor observado referente à variável Y na unidade experimental que recebeu o tratamento **i (i=1,2,...,I)** no bloco **j (j=1,2, ..., J)**;

m = constante;

$\mathbf{t_i}$ = efeito do tratamento **i** (pode ser fixo ou aleatório);

$\mathbf{b_j}$ = efeito do bloco j;

$\mathbf{e_{ij}}$ = contribuição da variação não controlada referente à observação Y_{ij} (erro experimental)

Slide nº 118

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.2 Modelo matemático e pressuposições

a) **Aditividade** - os diversos efeitos são aditivos, isto é, tem-se uma soma de efeitos e estes efeitos são independentes;
b) **Aleatoriedade** - os erros ou desvios $\mathbf{e_{ij}}$ são conjuntamente independentes, isto é, não são correlacionados;
c) **Homogeneidade de variâncias** - todos os erros $\mathbf{e_{ij}}$ tem a mesma variância σ^2;
d) **Normalidade dos erros** - os erros $\mathbf{e_{ij}}$ tem distribuição normal.

Slide nº 119

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.3 Estimação dos parâmetros do modelo

As estimativas de m, t_i, b_j e e_{ij} podem ser obtidas por:

- Média geral do experimento == > $\hat{m} = Y../IJ$ ou $\overline{Y}.. = Y../IJ$

- Efeito do tratamento i == > $\hat{t}_i = Y_i./J - \hat{m}$ (média do tratamento i menos a média geral)

A soma dos efeitos de todos os tratamentos deve ser zero. $\sum_i \hat{t}_i = 0$

- Efeito do bloco j == > $\hat{b}_j = Y._j/I - \hat{m}$ (média do bloco j menos a média geral)

A soma dos efeitos de todos os blocos deve ser zero. $\sum_j \hat{b}_j = 0$

- Erro experimental de cada observação Yij

$\hat{e}_{ij} = Y_{ij} - \hat{m} - \hat{t}_i - \hat{b}_j$ (a soma de todos os erros deve ser zero) $\sum_{ij} \hat{e}_{ij} = 0$

Slide nº 120

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Quadro de análise de variância para o delineamento blocos ao acaso

Fontes ou Causas de Variação	Graus de Liberdade (GL)	Soma de Quadrados (SQ)	Quadrado Médio (QM)	F_{CAL}
Blocos	J-1	SQ_{BLOCO}	QM_{BLOCO}	QM_{BLOCO}/QM_E
Tratamentos	I-1	SQ_{TRAT}	QM_{TRAT}	QM_{TRAT}/QM_E
Erro	(I-1)(J-1)	SQ_E	QM_E	
Total	IJ-1	SQ_{TOTAL}		

I = número de tratamentos

J = número de blocos (repetições)

Quadrado Médio = Soma de Quadrados/Graus de Liberdade, logo:

$QM_{BLOCO} = SQ_{BLOCO}/GL_{BLOCO}$

$QM_{TRAT} = SQ_{TRAT}/GL_{TRAT}$

$QM_E = SQ_E/GL_E$

Slide nº 121

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

As expressões para o cálculo das somas de quadrados são as seguintes:

$$SQ_{TOTAL} = \sum_{ij} Y_{ij}^2 - \frac{Y_{..}^2}{IJ}$$

$$SQ_{TRAT} = \frac{1}{J}\sum_{i} Y_{i.}^2 - \frac{Y_{..}^2}{IJ}$$

$$SQ_{BLOCO} = \frac{1}{I}\sum_{j} Y_{.j}^2 - \frac{Y_{..}^2}{IJ}$$

$SQE = SQ_{TOTAL} - SQ_{TRAT} - SQ_{BLOCO}$

O termo $\frac{Y_{..}^2}{IJ}$ é chamado fator de correção (FC)

Slide nº 122

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Interpretação para Blocos - teste de hipótese

a) Estabelecer as hipóteses:

H_0: $\sigma_b^2 = 0$ (blocos não heterogêneos)
H_1: $\sigma_b^2 \neq 0$ (blocos heterogêneos)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

Slide nº 123

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

c) Calcular o valor de Fcal entre blocos ➔ Fcalc = QM_{BLOCO}/QM_E.

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_{BLOCO};\ GL_E)$;

Veja tabela F a seguir (5%)

Slide nº 124

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{BLOCO}

GL_E (m)

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 125

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

e) Decisão e conclusão

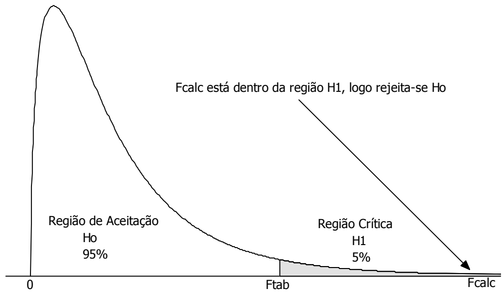

- se Fcalc ≥ Ftab, rejeitamos H_0 e concluímos que os blocos são heterogêneos, em nível α de probabilidade de erro ou de significância, ou seja, o uso de blocos foi eficiente.

Slide nº 126

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

e) Decisão e conclusão

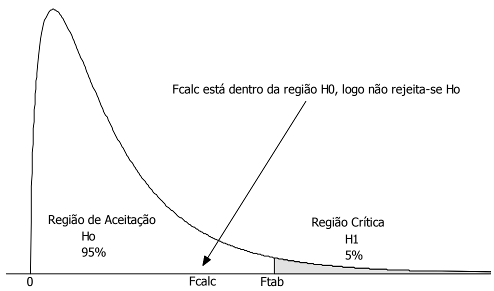

- se Fcalc < Ftab, não rejeitamos H_0 e concluímos que os blocos não são heterogêneos, ou seja, o uso de blocos não foi eficiente. Em próximos experimentos podemos utilizar o DIC, pois o bloqueamento não foi eficiente.

Slide nº 127

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Quando rejeitamos H_0, ou seja, concluímos que uso de blocos foi eficiente, faz sentido calcular a eficiência relativa (ER) do Delineamento Blocos ao Acaso (DBA) em relação ao Delineamento Inteiramente Casualizado (DIC):

$$ER\% = 100x\frac{QM_E(DIC)}{QM_E(DBA)} = 100x\frac{[SQ_E(DBA) + SQ_{Bloco}]/I(J-1)}{QM_E(DBA)} = \frac{100}{QM_E}x\frac{SQ_E + SQ_{Bloco}}{I(J-1)}$$

Slide nº 128

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Interpretação para Tratamentos de efeito fixo (Teste de Hipótese - ti de efeito fixo)

a) Estabelecer as hipóteses:

H_0: ti = 0 (para todo e qualquer i), ou seja, as médias de tratamentos não diferem.
H_1: ti ≠ 0, (para algum i), ou seja, pelo menos um contraste de médias de tratamento difere.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

Slide nº 129

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

c) Calcular o valor de Fcal entre tratamentos (grupos) ➔ Fcalc = QM_{TRAT}/QM_E.

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_{TRAT}; GL_E)$;

Veja tabela F a seguir (5%)

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{TRAT}

m (GL_E)	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

e) Decisão e conclusão

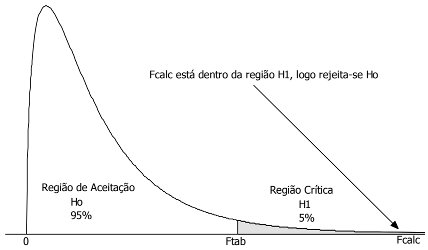

- se Fcalc ≥ Ftab, rejeitamos H_0 e concluímos que as médias dos tratamentos (grupos) diferem entre si, em nível de 5% de probabilidade de erro ou de significância. Ou ainda, concluímos que ti≠0 para algum i, ou melhor, no mínimo duas médias de tratamentos diferem entre si e, a diferença existente não pode ser atribuída à variação do acaso.

Slide nº 132

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

e) Decisão e conclusão

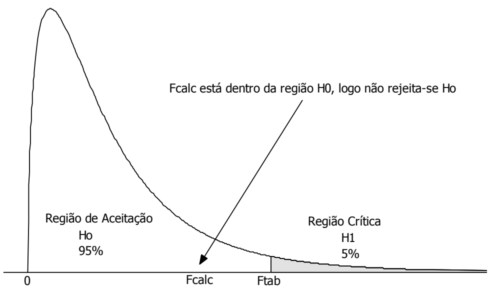

- se Fcalc < Ftab, não rejeitamos H_0 e concluímos que as médias dos tratamentos (grupos) não diferem entre si, ou seja, a diferença entre as médias dos tratamentos pode ser atribuída ao acaso.

Slide nº 133

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Avaliação da precisão experimental

A precisão experimental pode ser avaliada pela magnitude do erro experimental. Quanto menor o erro experimental, mais preciso é o experimento. A estatística coeficiente de variação (CV) serve para avaliar a precisão experimental.

O CV é calculado pela seguinte expressão:

$$CV = \frac{\sqrt{QME}}{\text{média}} x100$$

O autor Pimentel Gomes sugeriu a seguinte classificação da precisão experimental de acordo com o CV.

CV (%)	Classificação do CV	Classificação da Precisão Experimental
< 10	Baixo	Alta
≥ 10 e < 20	Médio	Média
≥ 20 e < 30	Alto	Baixa
≥ 30	Muito Alto	Muito Baixa

Slide nº 134

2.2 Delineamento Blocos ao Acaso (DBA)
2.2.4 Análise de Variância (ANOVA)

Após o teste de hipótese para interpretarmos o efeito de tratamento salientamos o seguinte: Se concluirmos que não há diferença entre as médias de tratamento, ou seja, as diferenças existentes podem ser atribuídas ao acaso, ou ainda, não rejeitamos H_0 não precisamos fazer mais nada. No entanto, se concluirmos que há diferença significativa entre as médias de tratamentos, ou seja, rejeitamos H_0, o que sabemos é que no mínimo duas médias (a maior e a menor média) diferem. Precisamos comparar as demais médias de tratamento e para isso quando os tratamentos são qualitativos usamos testes de comparação múltipla de médias (Tukey, Duncan, Scott Knott, DMS, e outros) e quando os tratamentos são quantitativos, com mais de dois níveis usa-se, mais apropriadamente, a análise de regressão, que estabelece uma função entre a variável dependente (medida no experimento) e a variável independente (tratamento aplicado).

Slide nº 135

Exercício

Prática 2 - Delineamento blocos ao acaso (DBA)

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 136

2.3 Quadrado latino

2.3 Delineamento Quadrado Latino (DQL)

2.3.1 Caracterização e uso

Este delineamento permite o controle da heterogeneidade entre as unidades experimentais (**UE**) quanto a dois fatores (ou dupla classificação) de variação.

É como se as **UE** fossem agrupadas segundo uma tabela de dupla entrada, onde uma entrada classifica as **UE** quanto aos níveis do fator **C** (coluna) de heterogeneidade e outra classifica as mesmas **UE** quanto aos níveis do fator **F** (fila) de heterogeneidade.

Slide nº 138

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

Exemplo:
Experimento em que cada **UE** é constituída por uma planta de *Citrus sp.*, e as plantas variam quanto à forma de poda (fator C = coluna) e Idade (fator F = fila).

Forma de poda →

Idade ↓	1	2	3	4	5
1	1 A_5	2 A_2	3 A_3	4 A_4	5 A_1
2	6 A_1	7 A_3	8 A_4	9 A_5	10 A_2
3	11 A_3	12 A_5	13 A_1	14 A_2	15 A_4
4	16 A_2	17 A_4	18 A_5	19 A_1	20 A_3
5	21 A_4	22 A_1	23 A_2	24 A_3	25 A_5

Exemplo: Tratamentos == > 5 adubos (A_1, A_2, A_3, A_4 e A_5)

Slide nº 139

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

Tabela para organização dos dados.

UE	Idade	Forma de poda	Tratamento	Variáveis respostas	
				Y_1	Y_2
1	1	1	A_5	.	.
2	1	2	A_2	.	.
3	1	3	A_3	.	.
4	1	4	A_4	.	.
5	1	5	A_1	.	.
6	2	1	A_1	.	.
. . . .	. . . . .	. . . . .	. . . .	....	......
25	5	5	A_5	.	.

Slide nº 140

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

Cada classe de idade aplica-se uma vez cada tratamento e, cada classe de forma de poda, também contém uma vez cada tratamento, ou seja, cada idade e cada tamanho constitui um bloco.

Há, neste caso, um duplo bloqueamento ou duplo controle local e, portanto, duas restrições na casualização dos tratamentos nas **UE**.

Slide nº 141

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

O termo **quadrado latino** provém do fato de que os dois fatores de heterogeneidade têm o mesmo número de níveis.

Este número de níveis (no exemplo é 5) é igual ao número de tratamentos e repetições e, assim sendo, o número de **UE** é igual ao **quadrado** do número de tratamentos.

O fato do número de tratamentos ser igual ao número de repetições é uma limitação ao uso deste delineamento pois, ao usar 8 ou mais tratamentos teremos um número exagerado de repetições.

Slide nº 142

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

Sorteio dos tratamentos

1) Distribuir os tratamentos em ordem sistemática, iniciando em cada linha na diagonal. Obtêm-se a distribuição apresentada na figura abaixo, chamado de **quadrado latino cavalo de pau**.

Forma de poda →

Idade ↓	1	2	3	4	5
1	1 A_1	2 A_2	3 A_3	4 A_4	5 A_5
2	6 A_5	7 A_1	8 A_2	9 A_3	10 A_4
3	11 A_4	12 A_5	13 A_1	14 A_2	15 A_3
4	16 A_3	17 A_4	18 A_5	19 A_1	20 A_2
5	21 A_2	22 A_3	23 A_4	24 A_5	25 A_1

Slide nº 143

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

2) Fazer o sorteio da ordem das seqüência de adubos para cada idade, isto é, sorteamos as linhas ou filas. Vamos supor que a seqüência resultante foi 4→3→1→2→5. Transcrevemos o resultado para o esquema abaixo, copiando em primeiro lugar a linha número 4, em seguida a linha 3, ... até a linha 5, em último lugar.

Forma de poda →

Idade ↓	1	2	3	4	5
1	1 A_3	2 A_4	3 A_5	4 A_1	5 A_2
2	6 A_4	7 A_5	8 A_1	9 A_2	10 A_3
3	11 A_1	12 A_2	13 A_3	14 A_4	15 A_5
4	16 A_5	17 A_1	18 A_2	19 A_3	20 A_4
5	21 A_2	22 A_3	23 A_4	24 A_5	25 A_1

Slide nº 144

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

3) Sobre o esquema anterior, que já possui um sorteio (primeira restrição), fazemos um novo sorteio (segunda restrição) para colunas. Um resultado possível seria $3 \rightarrow 5 \rightarrow 1 \rightarrow 2 \rightarrow 4$. Organizamos, o esquema definitivo (abaixo) transcrevendo em primeiro lugar a coluna 3, seguida da coluna 5, e assim sucessivamente até a coluna 4.

Forma de poda

Idade	1	2	3	4	5
1	1 A_5	2 A_2	3 A_3	4 A_4	5 A_1
2	6 A_1	7 A_3	8 A_4	9 A_5	10 A_2
3	11 A_3	12 A_5	13 A_1	14 A_2	15 A_4
4	16 A_2	17 A_4	18 A_5	19 A_1	20 A_3
5	21 A_4	22 A_1	23 A_2	24 A_3	25 A_5

Slide nº 145

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

Variável resposta $Y_{(i)jk}$

Denotamos $Y_{(i)jk}$ como sendo a resposta (desempenho) referente ao tratamento (tipo de adubo) i, (i=1, 2, ..., 5) avaliado no nível j do fator **C** de variação (forma de poda) e no nível k do fator **F** de variação (idade).

O índice $_{(i)jk}$ aparece com parênteses porque o tratamento i não ocorre em todas as combinações de j e k, ou melhor, o índice i varia dentro das combinações de j e de k.

Slide nº 146

2.3 Delineamento Quadrado Latino (DQL)
2.3.1 Caracterização e uso

Caderneta de campo do experimento em quadrado latino para estudar o desempenho de 5 tipos de adubo.

Nº da **UE**	Idade (k)	Forma de poda (j)	Adubo (i)	Variável resposta ($Y_{(i)jk}$)
1	1	1	A_5	$Y_{(5)11}$
2	1	2	A_2	$Y_{(2)12}$
3	1	3	A_3	$Y_{(3)13}$
4	1	4	A_4	$Y_{(4)14}$
5	1	5	A_1	$Y_{(1)15}$
6	2	1	A_1	$Y_{(1)21}$
7	2	2	A_3	$Y_{(3)22}$
8	2	3	A_4	$Y_{(4)23}$
9	2	4	A_5	$Y_{(5)24}$
10	2	5	A_2	$Y_{(2)25}$
11	3	1	A_3	$Y_{(3)31}$
12	3	2	A_5	$Y_{(5)32}$
13	3	3	A_1	$Y_{(1)33}$
14	3	4	A_2	$Y_{(2)34}$
15	3	5	A_4	$Y_{(4)35}$
16	4	1	A_2	$Y_{(2)41}$
17	4	2	A_4	$Y_{(4)42}$
18	4	3	A_5	$Y_{(5)43}$
19	4	4	A_1	$Y_{(1)44}$
20	4	5	A_3	$Y_{(3)45}$
21	5	1	A_4	$Y_{(4)51}$
22	5	2	A_1	$Y_{(1)52}$
23	5	3	A_2	$Y_{(2)53}$
24	5	4	A_3	$Y_{(3)54}$
25	5	5	A_5	$Y_{(5)55}$

Slide nº 147

2.3 Delineamento Quadrado Latino (DQL)
2.3.2 Modelo matemático e pressuposições

$$\mathbf{Y_{(i)jk} = m + t_{(i)jk} + C_j + F_k + e_{(i)jk}}$$

$Y_{(i)jk}$ = valor observado do tratamento i no nível j do fator C e no nível k do fator F de variação.

m = constante (média);

$t_{(i)jk}$ = efeito do tratamento i (pode ser fixo ou aleatório);

C_j = efeito do nível j do fator C de variação (coluna);

F_k = é o efeito do nível k do fator F de variação (fila);

e_{ij} = contribuição da variação não controlada referente à observação $Y_{(i)jk}$ (erro experimental)

Slide nº 148

2.3 Delineamento Quadrado Latino (DQL)
2.3.2 Modelo matemático e pressuposições

a) **Aditividade** - os diversos efeitos são aditivos, isto é, tem-se uma soma de efeitos e estes efeitos são independentes;
b) **Aleatoriedade** - os erros ou desvios $\mathbf{e_{ij}}$ são conjuntamente independentes, isto é, não são correlacionados;
c) **Homogeneidade de variâncias** - todos os erros $\mathbf{e_{ij}}$ tem a mesma variância σ^2;
d) **Normalidade dos erros** - os erros $\mathbf{e_{ij}}$ tem distribuição normal.

Slide nº 149

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Para os cálculos da ANOVA, no exemplo acima, necessitamos de alguns somatórios, como os que seguem:

Forma de poda → $Y_{(.).k}$ = total de fila

Idade	1	2	3	4	5
1	1 A_5	2 A_2	3 A_3	4 A_4	5 A_1
2	6 A_1	7 A_3	8 A_4	9 A_5	10 A_2
3	11 A_3	12 A_5	13 A_1	14 A_2	15 A_4
4	16 A_2	17 A_4	18 A_5	19 A_1	20 A_3
5	21 A_4	22 A_1	23 A_2	24 A_3	25 A_5

$Y_{(.)j.}$ = total de coluna

$Y_{(i)..}$ = total de tratamento

Total do tratamento 1 (A_1) ➔ $Y_{(1)..} = Y_{(1)51} + Y_{(1)12} + Y_{(1)33} + Y_{(1)44} + Y_{(1)25}$

Slide nº 150

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Quadro de análise de variância do delineamento quadrado latino

Fontes ou Causas de Variação	Graus de Liberdade (GL)	Soma de Quadrados (SQ)	Quadrado Médio (QM)	F_{CALC}
Colunas	I-1	SQ_C	QM_C	QM_C/QM_E
Filas	I-1	SQ_F	QM_F	QM_F/QM_E
Tratamentos	I-1	SQ_{TRAT}	QM_{TRAT}	QM_{TRAT}/QM_E
Erro	GL_E	SQ_E	QM_E	-
Total	IJ-1	SQ_{Total}	-	-

$GL_E=(I-1)(I-2)=GL_{TOTAL} - GL_C - GL_F - GL_{TRAT}$

I = Número de tratamentos; J = número de colunas; K = número de filas e I = J = K = número de repetições.

Quadrado Médio = Soma de Quadrados/Graus de Liberdade, logo:

$QM_C = SQ_C/GL_C$;

$QM_F = SQ_F/GL_F$;

$QM_{TRAT} = SQ_{TRAT}/GL_{TRAT}$;

$QM_E = SQ_E/GL_E$;

Slide nº 151

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

As expressões para o cálculo das somas de quadrados são

$$SQ_{TOTAL} = \sum_{jk} Y^2_{(i)jk} - \frac{Y^2_{(.)..}}{JK}$$

$$SQ_C = \frac{1}{J}\sum_j Y^2_{(.)j.} - \frac{Y^2_{(.)..}}{JK}$$

$$SQ_F = \frac{1}{J}\sum_k Y^2_{(.).k} - \frac{Y^2_{(.)..}}{JK}$$

$$SQ_{TRAT} = \frac{1}{J}\sum_i Y^2_{(i)..} - \frac{Y^2_{(.)..}}{JK}$$

$SQ_E = SQ_{TOTAL} - SQ_{TRAT} - SQ_C - SQ_F$

O termo $\frac{Y^2_{(.)..}}{JK}$ é chamado fator de correção (FC)

Slide nº 152

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Interpretação para Colunas - teste de hipótese

a) Estabelecer as hipóteses:

H_0: $\sigma_c^2 = 0$ (colunas não heterogêneas)
H_1: $\sigma_c^2 \neq 0$ (colunas heterogêneas)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

Slide nº 153

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

c) Calcular o valor de Fcal entre colunas ➔ Fcalc = QM_C/QM_E.

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_C;\ GL_E)$;

Veja tabela F a seguir (5%)

Slide nº 154

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{COLUNA}

GL_E (m)

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 155

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

e) Decisão e conclusão

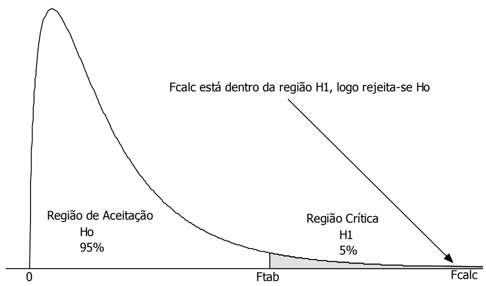

- se Fcalc $\geq$ Ftab, rejeitamos H_0 e concluímos que as colunas são heterogêneas, em nível α de probabilidade de erro ou de significância, ou seja, o uso de colunas foi eficiente. A variância entre colunas é significativa.

Slide nº 156

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

e) Decisão e conclusão

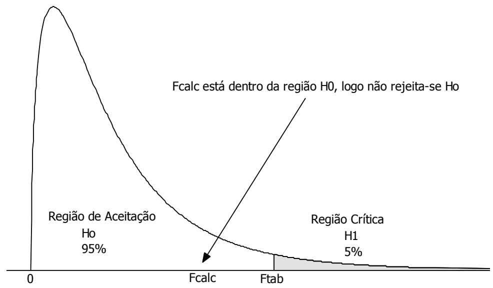

- se Fcalc < Ftab, não rejeitamos H_0 e concluímos que as colunas não são heterogêneas, ou seja, o uso de colunas não foi eficiente. Em próximos experimentos não precisamos fazer esse bloqueamento. A variação existente entre colunas deve-se ao acaso.

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Interpretação para Filas - teste de hipótese

a) Estabelecer as hipóteses:

H_0: $\sigma_F^2 = 0$ (filas não heterogêneas)
H_1: $\sigma_F^2 \neq 0$ (filas heterogêneas)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

c) Calcular o valor de Fcal entre filas ➔ Fcalc = QM_F/QM_E.

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_F;\ GL_E)$;

Veja tabela F a seguir (5%)

Slide nº 159

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟵⟶ GL_{FILA}

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 160

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

e) Decisão e conclusão

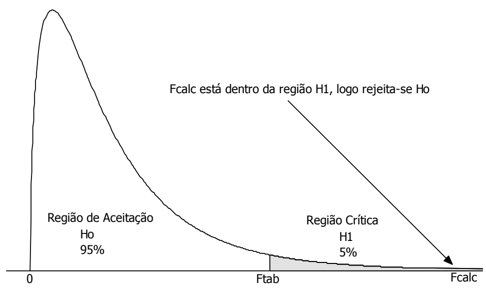

- se Fcalc ≥ Ftab, rejeitamos H_0 e concluímos que as filas são heterogêneas, em nível α de probabilidade de erro ou de significância, ou seja, o uso de filas foi eficiente. A variância entre filas é significativa.

Slide nº 161

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

e) Decisão e conclusão

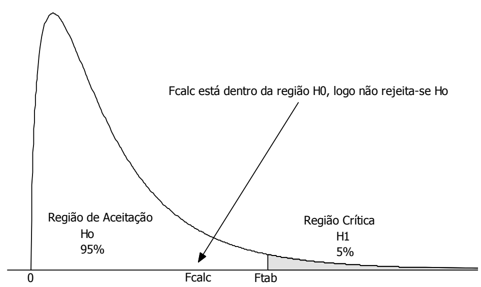

- se Fcalc < Ftab, não rejeitamos H_0 e concluímos que as filas não são heterogêneas, ou seja, o uso de colunas não foi eficiente. Em próximos experimentos não precisamos fazer esse bloqueamento. A variação existente entre filas deve-se ao acaso.

Slide nº 162

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Interpretação para Tratamentos de efeito fixo (Teste de Hipótese - ti de efeito fixo)

a) Estabelecer as hipóteses:

H_0: ti = 0 (para todo e qualquer i), ou seja, as médias de tratamentos não diferem.
H_1: ti ≠ 0, (para algum i), ou seja, pelo menos um contraste de médias de tratamento difere.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

Slide nº 163

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

c) Calcular o valor de Fcalc entre tratamentos (grupos) ➔ Fcalc = QM_{TRAT}/QM_E.

d) Ver o valor de $F_{tabelado}$ ➔ $F_{tab} = F\alpha\ (GL_{TRAT}; GL_E)$;

Veja tabela F a seguir (5%)

Slide nº 164

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador → GL_{TRAT}

m: GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 165

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

e) Decisão e conclusão

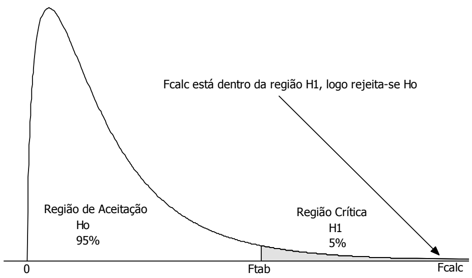

- se Fcalc ≥ Ftab, rejeitamos H_0 e concluímos que as médias dos tratamentos (grupos) diferem entre si, em nível α de probabilidade de erro ou de significância. Ou ainda, concluímos que ti≠0 para algum i, ou melhor, no mínimo duas médias de tratamentos diferem entre si e, a diferença existente não pode ser atribuída à variação do acaso.

Slide nº 166

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

e) Decisão e conclusão

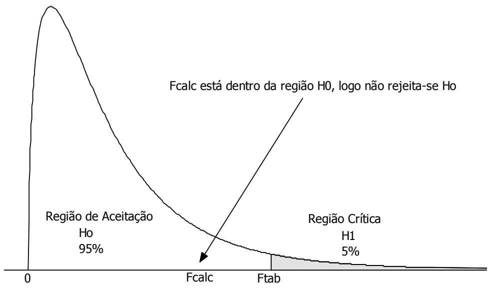

- se Fcalc < Ftab, não rejeitamos H_0 e concluímos que as médias dos tratamentos (grupos) não diferem entre si, ou seja, a diferença entre as médias dos tratamentos pode ser atribuída ao acaso.

Slide nº 167

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Avaliação da precisão experimental

A precisão experimental pode ser avaliada pela magnitude do erro experimental. Quanto menor o erro experimental, mais preciso é o experimento. A estatística coeficiente de variação (CV) serve para avaliar a precisão experimental.

O CV é calculado pela seguinte expressão:

$$CV = \frac{\sqrt{QME}}{\text{média}} x100$$

O autor Pimentel Gomes sugeriu a seguinte classificação da precisão experimental de acordo com o CV.

CV (%)	Classificação do CV	Classificação da Precisão Experimental
< 10	Baixo	Alta
≥ 10 e < 20	Médio	Média
≥ 20 e < 30	Alto	Baixa
≥ 30	Muito Alto	Muito Baixa

Slide nº 168

2.3 Delineamento Quadrado Latino (DQL)
2.3.3 Análise de Variância (ANOVA)

Após o teste de hipótese para interpretarmos o efeito de tratamento salientamos o seguinte: Se concluirmos que não há diferença entre as médias de tratamento, ou seja, as diferenças existentes podem ser atribuídas ao acaso, ou ainda, não rejeitamos H_0 não precisamos fazer mais nada. No entanto, se concluirmos que há diferença significativa entre as médias de tratamentos, ou seja, rejeitamos H_0, o que sabemos é que no mínimo duas médias (a maior e a menor média) diferem. Precisamos comparar as demais médias de tratamento e para isso quando os tratamentos são qualitativos usamos testes de comparação múltipla de médias (Tukey, Duncan, Scott Knott, DMS, e outros) e quando os tratamentos são quantitativos, com mais de dois níveis usa-se, mais apropriadamente, a análise de regressão, que estabelece uma função entre a variável dependente (medida no experimento) e a variável independente (tratamento aplicado).

Slide nº 169

3 Procedimentos para comparações múltiplas de médias de tratamentos

3.1 Introdução

Análise complementar de experimentos independente do delineamento (DIC, DBA, DQL)

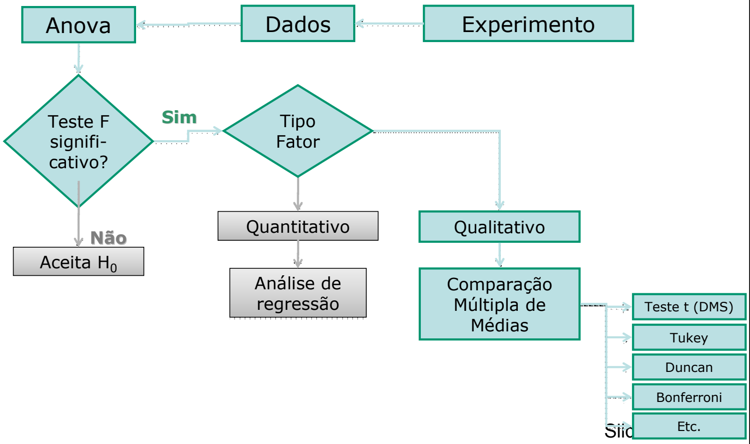

Qual teste utilizar para comparar as médias?

- Existem diversos procedimentos de comparação múltipla de médias, cada um com as suas particularidades. Como exemplo: Scott Knott – indicado quando o número de tratamentos é elevado, evitando ambigüidades; Dunnett – quando tem-se um tratamento testemunha (grupo controle), etc.

- Veremos a seguir dois testes:

Tukey e Duncan.

Slide nº 173

3.2 Teste de Tukey

3.2 TUKEY

Exemplo: Os dados da tabela abaixo se referem à altura de plantas, em cm, de um experimento no delineamento completamente casualizado (DIC) de quatro espécies de eucalipto.

Espécie	REP						Soma	Média
	1	2	3	4	5	6		
A	64	72	68	77	56	95	432	72
B	78	91	97	82	85	77	510	85
C	75	93	78	71	63	76	456	76
D	55	66	49	64	70	68	372	62

OBS: O fator espécie é qualitativo, logo após a análise de variância, caso o teste F para o efeito de espécie for significativo, é adequado proceder a um teste de comparação múltipla de médias.

Slide nº 174

3.2 TUKEY

- Resultado da anova
- $F_{tab5\%}$ (3;20) para espécie = 3,10

Quadro de análise da variância

Fonte da variação	GL	SQ	QM	Fcalc	Ftab 5%
Espécie	3	1636,50	545,50	5,41	3,10
Erro	20	2018,00	100,90		
Total	23	3654,50			

Coeficiente de variação ➔ $CV = \frac{\sqrt{QME}}{\text{média}} * 100 = \frac{\sqrt{100,90}}{73,75} * 100 = 13,62\%$

Concluímos que as médias de espécies diferem a 5% de probabilidade de erro. Assim, é necessário fazer um procedimento complementar da anova, ou seja, um teste de comparação múltipla de médias, pois o fator espécie é qualitativo.

Slide nº 175

3.2 TUKEY

Como temos quatro médias poderíamos ter seis contrastes envolvendo duas médias. Então precisamos saber quais os contrastes de médias diferem.

Os contrastes de médias duas a duas seriam:

A vs B; A vs C; A vs D; B vs C; **B vs D** e C vs D.

O teste F da ANOVA informou que pelo menos um contraste de médias difere. No caso, refere-se ao tratamento com maior e menor média. Nesse exemplo foi o contraste **B vs D**, pois B (maior média = 85) e D (menor média = 62). Os demais contrastes vamos verificar se são significativos (diferem) por meio do teste de Tukey, ou seja, precisamos fazer uma análise complementar ao teste F da ANOVA.

Slide nº 176

3.2 TUKEY

Calculamos a seguinte estatística para o teste:

$$\Delta = q_{\alpha(I,GLE)}\sqrt{\frac{QME}{J}}$$

Onde:

Δ = Diferença mínima Significativa.
α = nível de significância do teste (erro tipo I).
I = número de tratamentos
GLE = Graus de Liberdade do Erro.
$S_{\bar{y}} = \sqrt{\frac{QME}{J}}$ = Erro Padrão da média de um tratamento
J = número de repetições
$q_{\alpha(I,GLE)}$ = Amplitude Total Studentizada (Valor tabelado)

Qualquer diferença entre médias de tratamentos ≥ Δ é considerada significativa.

Slide nº 177

Tabela **Tukey** - Contém os valores da amplitude total estudentizada (**q**) para uso no teste de Tukey em nível de **5%** de erro e GL_E graus de liberdade do erro.

	Número de tratamentos											
GL_E	2	3	4	5	6	7	8	9	10	11	12	13
1	18,0	27,0	32,8	37,1	40,4	43,1	45,4	47,4	49,1	50,6	51,9	53,2
2	6,09	8,33	9,80	10,9	11,7	12,4	13,0	13,5	14,0	14,4	14,7	15,1
3	4,50	5,91	6,83	7,50	8,04	8,48	8,85	9,18	9,46	9,72	9,95	10,1
4	3,93	5,04	5,76	6,29	6,71	7,05	7,35	7,60	7,83	8,03	8,21	8,37
5	3,64	4,60	5,22	5,67	6,03	6,33	6,58	6,80	7,00	7,17	7,32	7,47
6	3,46	4,34	4,90	5,31	5,63	5,90	6,12	6,32	6,49	6,65	6,79	6,92
7	3,34	4,17	4,68	5,06	5,36	5,61	5,82	6,00	6,16	6,30	6,43	6,55
8	3,26	4,04	4,53	4,89	5,15	5,40	5,60	5,77	5,92	6,05	6,18	6,29
9	3,20	3,95	4,42	4,76	5,02	5,24	5,43	5,60	5,74	5,87	5,98	6,09
10	3,15	3,88	4,33	4,65	4,91	5,12	5,31	5,46	5,60	5,72	5,83	5,94
11	3,11	3,82	4,26	4,57	4,82	5,03	5,20	5,35	5,49	5,61	5,71	5,81
12	3,08	3,77	4,20	4,51	4,75	4,95	5,12	5,27	5,40	5,51	5,62	5,71
13	3,06	3,74	4,15	4,45	4,69	4,89	5,05	5,19	5,32	5,43	5,53	5,63
14	3,03	3,70	4,11	4,41	4,64	4,83	4,99	5,13	5,25	5,36	5,46	5,55
15	3,01	3,67	4,08	4,37	4,60	4,78	4,94	5,08	5,20	5,31	5,40	5,49
16	3,00	3,65	4,05	4,33	4,56	4,74	4,90	5,03	5,15	5,26	5,35	5,44
17	2,98	3,63	4,02	4,30	4,52	4,71	4,86	4,99	5,11	5,21	5,31	5,39
18	2,97	3,61	4,00	4,28	4,50	4,67	4,82	4,96	5,07	5,17	5,27	5,35
19	2,96	3,59	3,98	4,25	4,47	4,65	4,79	4,92	5,04	5,14	5,23	5,32
20	2,95	3,58	3,96	4,23	4,45	4,62	4,77	4,90	5,01	5,11	5,20	5,28
24	2,92	3,53	3,90	4,17	4,37	4,54	4,68	4,81	4,92	5,01	5,10	5,18
30	2,89	3,49	3,85	4,10	4,30	4,46	4,60	4,72	4,82	4,92	5,00	5,08
40	2,86	3,44	3,79	4,04	4,23	4,39	4,52	4,64	4,74	4,82	4,90	4,98
60	2,83	3,40	3,74	3,98	4,16	4,31	4,44	4,55	4,65	4,73	4,81	4,88
120	2,80	3,36	3,69	3,92	4,10	4,24	4,36	4,47	4,56	4,64	4,71	4,78
∞	2,77	3,31	3,63	3,86	4,03	4,17	4,29	4,39	4,47	4,55	4,62	4,69

Slide nº 178

3.2 TUKEY

- Para o nosso exemplo:

$$\Delta = q_{\alpha(I,GLE)}\sqrt{\frac{QME}{J}}$$

$$q_{5\%(4,20)} = 3{,}96 \quad \text{(valor tabelado)}$$

$$\Delta = 3{,}96\sqrt{\frac{100{,}9}{6}} = 16{,}2392$$

Essa é a diferença mínima entre duas médias para ser considerada significativa.

Slide nº 179

3.2 TUKEY

Organizar as médias de forma decrescente para aplicar o teste:

Espécie	Média	Tukey
B	85	a
C	76	ab
A	72	ab
D	62	b

Médias não seguidas de mesma letra diferem ao nível de 5% de significância, pelo teste de Tukey.

➔ Iniciamos calculando a diferença da maior e da menor média:
85 – 62 = 23 ➔ 23 é maior que Δ (16,2392) ➔ logo essas médias diferem e poderíamos afirmar ao nível de 5% de significância, pelo teste Tukey, que a espécie B é mais alta que a espécie D. A diferença de altura entre as espécies não pode ser atribuída ao acaso.

➔ Depois:
85 – 72 = 13 ➔ 13 é menor que Δ (16,2392) (logo as médias não diferem) – representamos por "ns" (não significativo) e colocamos letra "a" ao lado das médias, para simbolizar que elas não diferem.

➔ Fazemos o mesmo procedimento com a segunda maior média:
76 – 62= 14 ➔ 14 menor que Δ (16,2392) (ns) colocamos a letra "b".

E assim terminamos o teste.

Slide nº 180

3.2 TUKEY

As conclusões sobre os tratamento são feitas observando-se as médias identificadas ou não por mesma letra.

Em geral, quando não há um tratamento padrão (testemunha) convém responder as seguintes perguntas: qual é o melhor tratamento? quais são os tratamentos que não diferem significativamente do melhor? qual é o pior tratamento? e, quais são os tratamentos que não diferem significativamente do pior tratamento.

Por outro lado, quando um dos tratamentos é testemunha (tratamento padrão) as conclusões são feitas em relação a este tratamento e, em geral, procura-se responder às seguintes perguntas: quais são os tratamentos melhores do que a testemunha? quais são os tratamentos que não diferem significativamente da testemunha? e, quais são os tratamentos piores do que a testemunha?

Slide nº 181

3.3 Teste Duncan

3.3 DUNCAN

A aplicação do teste de Duncan é semelhante à aplicação do teste de Tukey. A diferença é que em vez de ter apenas um valor Δ (delta) calculamos I-1 valores de Di.

Calculamos a seguinte estatística para o teste:

$$Di = Zi\sqrt{\frac{QME}{J}}$$

Onde: i = 2, 3, 4, ... I médias contidas no contraste
Zi = Tabela de Duncan (em função de α, número de médias abrangidas no contraste e GLE)
QME = Quadrado Médio do erro
J = n° de repetições

Qualquer diferença entre médias de tratamentos ≥ Di é considerada significativa.

Slide nº 182

Tabela **Duncan** - Contém os valores da amplitude total estudentizada (**Zi**) para uso no teste de Duncan em nível de **5%** de erro e GL_E graus de liberdade do erro.

	Número de médias abrangidas pelo contraste											
GL_E	2	3	4	5	6	7	8	9	10	12	14	16
1	18,0	18,0	18,0	18,0	18,0	18,0	18,0	18,0	18,0	18,0	18,0	18,0
2	6,09	6,09	6,09	6,09	6,09	6,09	6,09	6,09	6,09	6,09	6,09	6,09
3	4,50	4,50	4,50	4,50	4,50	4,50	4,50	4,50	4,50	4,50	4,50	4,50
4	3,93	4,01	4,02	4,02	4,02	4,02	4,02	4,02	4,02	4,02	4,02	4,02
5	3,64	3,74	3,79	3,83	3,83	3,83	3,83	3,83	3,83	3,83	3,83	3,83
6	3,46	3,58	3,64	3,68	3,68	3,68	3,68	3,68	3,68	3,68	3,68	3,68
7	3,35	3,47	3,54	3,58	3,60	3,61	3,61	3,61	3,61	3,61	3,61	3,61
8	3,26	3,39	3,47	3,52	3,55	3,56	3,56	3,56	3,56	3,56	3,56	3,56
9	3,20	3,34	3,41	3,47	3,50	3,52	3,52	3,52	3,52	3,52	3,52	3,52
10	3,15	3,30	3,37	3,43	3,46	3,47	3,47	3,47	3,47	3,47	3,47	3,47
11	3,11	3,27	3,35	3,39	3,43	3,44	3,45	3,46	3,46	3,46	3,46	3,46
12	3,08	3,23	3,33	3,36	3,40	3,42	3,44	3,44	3,46	3,46	3,46	3,46
13	3,06	3,21	3,30	3,35	3,38	3,41	3,42	3,44	3,45	3,45	3,46	3,46
14	3,03	3,18	3,27	3,33	3,37	3.39	3,41	3,42	3,44	3,45	3,46	3,46
15	3,01	3,16	3,25	3,31	3,36	3,38	3,40	3,42	3,43	3,44	3,45	3,46
16	3,00	3,15	3,23	3,30	3,34	3,37	3,39	3,41	3,43	3,44	3,45	3,46
17	2,98	3,13	3,22	3,28	3,33	3,36	3,38	3,40	3,42	3,44	3,45	3,46
18	2,97	3,12	3,21	3,27	3,32	3,35	3,37	3,39	3,41	3,43	3,45	3,46
19	2,96	3,11	3,19	3,26	3,31	3,35	3,37	3,39	3,41	3,43	3,44	3,46
20	2,95	3,10	3,18	3,25	3,30	3,34	3,36	3,38	3,40	3,43	3,44	3,46
22	2,93	3,08	3,17	3,24	3,29	3,32	3,35	3,37	3,39	3,42	3,44	3,45
24	2,92	3,07	3,15	3,22	3,28	3,31	3,34	3,37	3,38	3,41	3,44	3,45
26	2,91	3,06	3,14	3,21	3,27	3,30	3,34	3,36	3,38	3,41	3,43	3,45
28	2,90	3,04	3,13	3,20	3,26	3,30	3,33	3,35	3,37	3,40	3,43	3,45
30	2,89	3,04	3,12	3,20	3,25	3,29	3,32	3,35	3,37	3,40	3,43	3,44
40	2,86	3,01	3,10	3,17	3,22	3,27	3,30	3,33	3,35	3,39	3,42	3,44
60	2,83	2,98	3,08	3,14	3,20	3,24	3,28	3,31	3,33	3,37	3,40	3,43
100	2,80	2,95	3,05	3,12	3,18	3,22	3,26	3,29	3,32	3,36	3,40	3,42
∞	2,77	2,92	3,02	3,09	3,15	3,19	3,23	3,26	3,29	3,34	3,38	3,41

Slide nº 183

3.3 DUNCAN

- Cálculos dos Di conforme o número de médias abrangidas no contraste (nesse exemplo, D2, D3 e D4)

	Número de médias abrangidas pelo contraste		
GL_E	2	3	4
:	:	:	:
:	:	:	:
20	Z_2 = 2,95	Z_3 = 3,10	Z_4 = 3,18

Duas médias ➔ $D2 = Z2\sqrt{\frac{QME}{J}} = 2{,}95\sqrt{\frac{100{,}9}{6}} = 12{,}0974$

Três médias ➔ $D3 = Z3\sqrt{\frac{QME}{J}} = 3{,}10\sqrt{\frac{100{,}9}{6}} = 12{,}7125$

Quatro médias ➔ $D4 = Z4\sqrt{\frac{QME}{J}} = 3{,}18\sqrt{\frac{100{,}9}{6}} = 13{,}0406$

Slide nº 184

3.3 DUNCAN

Organizar as médias de forma decrescente para aplicar o teste:

Espécie	Média	Duncan
B	85	a
C	76	ab
A	72	bc
D	62	c

Médias não seguidas de mesma letra diferem ao nível de 5% de significância, pelo teste Duncan.

➔ Iniciamos calculando a diferença da maior e da menor média:
85 – 62 = 23 ➔ 23 é maior que D4 (13,0406) (comparamos com D4, pois envolve quatro médias) ➔ logo essas médias diferem e poderíamos afirmar ao nível de 5% de significância, pelo teste Duncan, que a espécie B é mais alta que a espécie D. A diferença de altura entre as espécies não pode ser atribuída ao acaso.

➔ Depois:
85 – 72 = 13 ➔ 13 é maior que D3 (12,7125) (comparamos com D3, pois envolve três médias) mesmo comentário acima.
85 – 76 = 9 ➔ 9 é menor que D2 (12,0974) (logo as médias não diferem) – representamos por "ns" (não significativo) e colocamos letra "a" ao lado das médias, para simbolizar que elas não diferem.

➔ Fazemos o mesmo procedimento com a segunda maior média:
76 – 62= 14 ➔ 14 é maior que D3 (12,7125) diferença significativa.
76 – 72 = 4 ➔ 4 é menor que D2 (12,0974) (ns) colocamos a letra "b".

➔ Terceira maior média
72 – 62 = 10 ➔ 10 é menor que D2 (12,0974) (ns) colocamos a letra "c".
E assim terminamos o teste.

Slide nº 185

TUKEY e DUNCAN – Resumo para o exemplo

Espécie	Média	Tukey	Duncan
B	85	a	a
C	76	ab	ab
A	72	ab	bc
D	62	b	c
Valor p/ o teste	2 médias 3 médias 4 médias	16,2392	12,0974 12,7125 13,0406
nº de ≠ significativas a 5%		1	3
Classificação do teste quanto à amplitude		simples	múltipla
Tabela a ser consultada		Tukey	Duncan
Erro padrão utilizado		$\sqrt{\frac{QME}{J}}$	$\sqrt{\frac{QME}{J}}$

Médias não seguidas de mesma letra diferem ao nível de 5% de significância.

Slide nº 186

Resultados de outros testes

Espécie	Média	DMS	Tukey	Duncan	Bonferroni	Dunnett	SNK	Scheffé
B	85	a	a	a	a	B ≠ D	a	a
C	76	ab	ab	ab	ab	C = D	ab	ab
A	72	bc	ab	bc	ab	A = D	ab	ab
D	62	c	b	c	b		b	b
Valor p/ o teste	2 médias 3 médias 4 médias	12,0975	16,2392	12,0974 12,7125 13,0406	16,9766	14,7305	12,0975 14,6809 16,2392	17,6859
nº de ≠ significativas a 5%		3	1	3	1	1	1	1
Classificação do teste quanto à amplitude		simples	simples	múltipla	simples	simples	múltipla	simples
Tabela a ser consultada		t de Student	Tukey	Duncan	t de Student	Dunnett	Tukey	F de Snedcor
Erro padrão utilizado		$\sqrt{\frac{2QME}{J}}$	$\sqrt{\frac{QME}{J}}$	$\sqrt{\frac{QME}{J}}$	$\sqrt{\frac{2QME}{J}}$	$\sqrt{\frac{2QME}{J}}$	$\sqrt{\frac{QME}{J}}$	$\sqrt{\frac{QME\left\{\sum_i C_i^2\right\}}{J}}$

Médias não seguidas de mesma letra diferem ao nível de 5% de significância.

Slide nº 187

Exercício

Prática 3 - Delineamento quadrado latino (DQL) +
Tukey e Duncan

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 188

4 Interpretação de experimentos com tratamentos quantitativos (Regressão)

4.1 Introdução

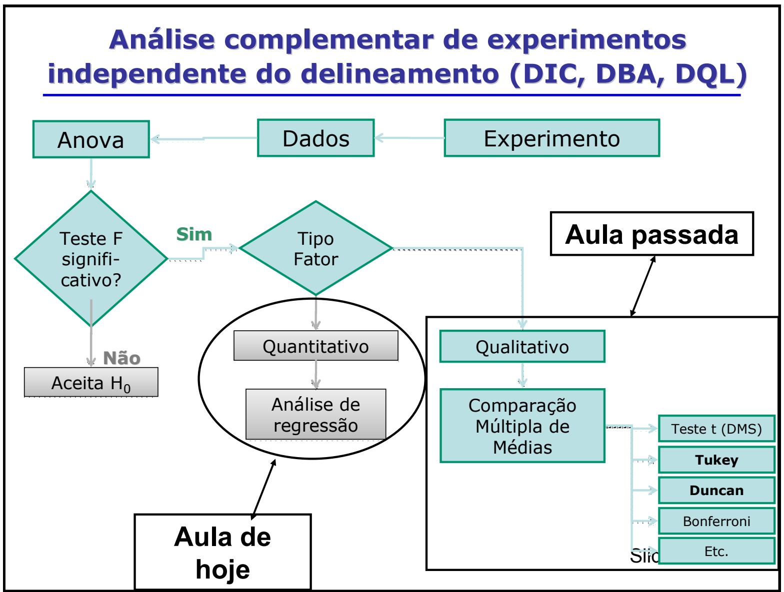

- Quando os tratamentos (variável independente - X) podem ser ordenados segundo um critério quantitativo deve-se usar a regressão e ajustar uma equação que expresse matematicamente o comportamento dos tratamentos.

- Se Xi é o valor do tratamento i e Yij é a observação (resposta) ao efeito do tratamento i na repetição j então, o problema é resolvido encontrando a função Y = "função de X".

- Serão abordadas somente as equações polinomiais de:
- primeiro grau ($\hat{Y}=a+bX$)
- segundo grau ($\hat{Y}=a+bX+cX^2$) e
- terceiro grau ($\hat{Y}=a+bX+cX^2+dX^3$).

Slide nº 192

- Para ter um ponto de referência na interpretação de experimentos com grupos quantitativos, deve-se incluir, sempre que possível, a quantidade zero (testemunha) na relação dos tratamentos a serem avaliados.

- Sendo **I** o número de tratamentos quantitativos (níveis da variável independente X) do experimento, deve-se ter em estudo no mínimo **I= 3** para aplicar a análise de regressão.

- Quando **I=2**, temos dois pontos e infinitas equações podem passar pelos dois pontos tornando impossível estudar a relação entre os tratamentos e seus efeitos. Neste caso, para concluir, testa-se a hipótese de igualdade das médias dos dois tratamentos e verifica-se qual dos dois tratamentos tem maior média – teste F da Anova.

Slide nº 193

Considerando a observação $\mathbf{Y_{ij}}$ como sendo o valor obtido na unidade experimental (UE) do tratamentoo $\mathbf{X_i}$ na repetição j. O modelo, neste caso, é:

$$Y_{ij} = b_o + b_1 X_i + b_2 X_i^2 + ... + b_k X_i^k + \delta_i + e_{ij}$$, em que:

b_0= constante ou valor esperado de Y se X_i=0;
b_1= coeficiente do primeiro grau (linear) do modelo;
b_2= coeficiente do segundo grau (quadrático) do modelo;
b_k= coeficiente de grau k;
δ_i = desvio da função com a média no ponto X; e,
e_{ij} =erro experimental referente à observação Y_{ij}.

Slide nº 194

- Estuda-se tantos graus de regressão quantos forem os graus de liberdade dos tratamentos e para cada grau da regressão é atribuído um grau de liberdade. No caso de experimentos com **I=4** tratamentos, a equação de terceiro grau é a de maior grau possível e, neste caso, a variância dos desvios é nula.

- Nesse texto, será abordada a obtenção das estimativas dos parâmetros para o modelo que melhor se ajuste aos dados observados, considerando o método dos **polinômios ortogonais** utilizado quando os tratamentos são eqüidistantes e com número igual de repetições para cada tratamento (experimento balanceado).

Slide nº 195

4.2 Métodos dos polinômios ortogonais

4.2 Método dos polinômios ortogonais

Exemplo: Os dados da tabela abaixo se referem à altura de plantas de eucalipto, em cm, de um experimento no delineamento completamente casualizado (DIC) de quatro doses de Nitrogênio (0, 10, 20 e 30).

Dose	Repetições					$Y_{i.}$	$\bar{Y}_{i.}$	S_i^2
	1	2	3	4	5	(Soma)	(Média)	(Variância)
0	48	40	43	41	48	220	44	14,5
10	53	47	52	47	56	255	51	15,5
20	53	61	54	59	53	280	56	14,0
30	47	45	50	48	55	245	49	14,5
						$Y_{..}$ = 1000	$\bar{Y}_{..}$ = 50	

OBS: O fator dose (tratamento) é quantitativo, logo após a análise de variância, caso o teste F para o efeito de dose for significativo, é adequado proceder a análise de regressão.

Slide nº 196

4.2 Método dos polinômios ortogonais

Quadro de análise de variância (anova)

Fonte de Variação	GL	SQ	QM	F_{CALC}	Ftab 5% (3, 16)
Dose	3	370	123,333	8,433	3,24
Erro	16	234	14,625	-	
Total	19	604	-	-	

CV = 7,65%

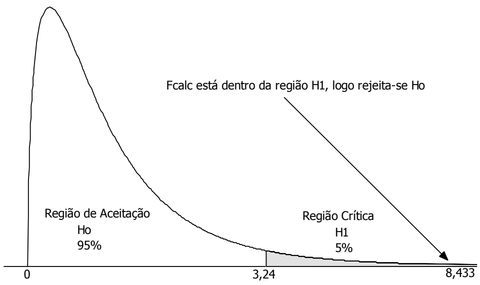

Concluímos que as médias de doses diferem a 5% de probabilidade de erro. Assim, é necessário fazer um procedimento complementar da anova, ou seja, fazer a análise de regressão.

4.2 Método dos polinômios ortogonais

Podemos a partir das médias de cada dose ou grupo (X) fazer um diagrama de dispersão, no EXCEL, para ter uma idéia "preliminar" do comportamento.

Dose (X)	Média de Y
0	44
10	51
20	56
30	49

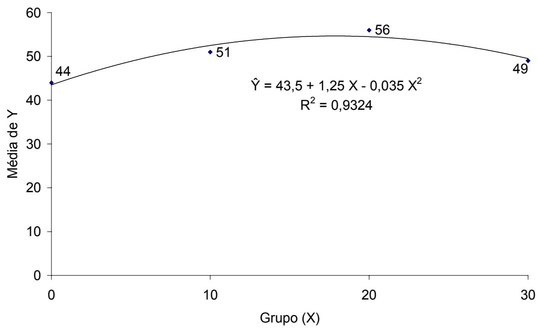

OBS.: O R^2 calculado no Excel é o não ajustado.

4.2 Método dos polinômios ortogonais

A dispersão dos pontos no gráfico sugere que o modelo quadrático, talvez, seja o mais adequado. Precisamos confirmar essa informação estatisticamente através da análise complementar da análise de variância por meio da análise de regressão.

Os coeficientes dos polinômios ortogonais de primeiro grau (contraste linear - $\mathbf{C_{i1}}$) segundo grau (contraste quadrático - $\mathbf{C_{i2}}$) e de terceiro grau (contraste cúbico - $\mathbf{C_{i3}}$) devem ser consultados na tabela seguinte para I = 3, 4, 5, 6, 7 e 8 grupos: Nessa tabela $K=\Sigma i\mathbf{C}ik^2$ (k=1,2,...) e **M** é um valor usado para o cálculo das estimativas dos parâmetros da equação.

Slide nº 199

4.2 Método dos polinômios ortogonais

I = 3		
I	C_{i1}	C_{i2}
1	-1	1
2	0	-2
3	1	1
K	2	6
M	1	3

I = 4			
i	C_{i1}	C_{i2}	C_{i3}
1	-3	1	-1
2	-1	-1	3
3	1	-1	-3
4	3	1	1
K	20	4	20
M	2	1	10/3

I = 5			
i	C_{i1}	C_{i2}	C_{i3}
1	-2	2	-1
2	-1	-1	2
3	0	-2	0
4	1	-1	-2
5	2	2	1
K	10	14	10
M	1	1	5/6

I = 6			
I	C_{i1}	C_{i2}	C_{i3}
1	-5	5	-5
2	-3	-1	7
3	-1	-4	4
4	1	-4	-4
5	3	-1	-7
6	5	5	5
K	70	84	180
M	2	3/2	5/3

I = 7			
i	C_{i1}	C_{i2}	C_{i3}
1	-3	5	-1
2	-2	0	1
3	-1	-3	1
4	0	-4	0
5	1	-3	-1
6	2	0	-1
7	3	5	1
K	28	84	6
M	1	1	1/6

I = 8			
i	C_{i1}	C_{i2}	C_{i3}
1	-7	7	-7
2	-5	1	5
3	-3	-3	7
4	-1	-5	3
5	1	-5	-3
6	3	-3	-7
7	5	1	-5
8	7	7	7
K	168	168	264
M	2	1	2/3

Fonte: Storck et al. (2006).

I = tratamentos ou grupos

Slide nº 200

4.2 Método dos polinômios ortogonais

Como temos I=4 tratamentos.

Montamos a seguinte tabela auxiliar para análise de regressão

220 x (-3) 220 x (1) 220 x (-1)

I	X_i	$Y_{i.}$	C_{i1}	C_{i2}	C_{i3}	$C_{i1}Y_{i.}$	$C_{i2}Y_{i.}$	$C_{i3}Y_{i.}$
1	0	220	-3	1	-1	-660	220	-220
2	10	255	-1	-1	3	-255	-255	765
3	20	280	1	-1	-3	280	-280	-840
4	30	245	3	1	1	735	245	245
$\Sigma_i \rightarrow$		1000				100	-70	-50
		K	20	4	20			
		M	2	1	10/3			

Doses Totais de doses

$\Sigma_i C_{i1} Y_{i.}$ $\Sigma_i C_{i2} Y_{i.}$ $\Sigma_i C_{i3} Y_{i.}$

Slide nº 201

4.2 Método dos polinômios ortogonais

Cálculo das somas de quadrados:

Soma de Quadrados da Regressão Linear

$$SQ_{RL} = \left(\sum_i C_{i1} Y_{i.}\right)^2 \Big/ J \sum_i C_{i1}^2$$

$$SQ_{RL} = \frac{\left[(-3*220)+(-1*255)+(1*280)+(3*245)\right]^2}{5*\left[(-3)^2+(-1)^2+(1)^2+(3)^2\right]}$$

$SQ_{RL} = (100)^2 / (5 \text{ x } 20) = 100{,}00$

É o valor de k tabelado

J = número de repetições

Slide nº 202

4.2 Método dos polinômios ortogonais

Cálculo das somas de quadrados:

Soma de Quadrados da Regressão Quadrática

$$SQ_{RQ} = \left(\sum_i C_{i2} Y_i.\right)^2 \Big/ J \sum_i C_{i2}^2$$

$$SQ_{RQ} = \frac{\left[(1*220)+(-1*255)+(-1*280)+(1*245)\right]^2}{5*\left[(1)^2+(-1)^2+(-1)^2+(1)^2\right]}$$

$SQ_{RQ} = (-70)^2 / (5 \text{ x } 4) = 245{,}00$

É o valor de k tabelado

J = número de repetições

Slide nº 203

4.2 Método dos polinômios ortogonais

Cálculo das somas de quadrados:

Soma de Quadrados da Regressão Cúbica

$$SQ_{RC} = \left(\sum_i C_{i3} Y_i.\right)^2 \Big/ J \sum_i C_{i3}^2$$

$$SQ_{RC} = \frac{\left[(-1*220)+(3*255)+(-3*280)+(1*245)\right]^2}{5*\left[(-1)^2+(3)^2+(-3)^2+(1)^2\right]}$$

$SQ_{RC} = (-50)^2 / (5 \text{ x } 20) = 25{,}00$

É o valor de k tabelado

J = número de repetições

Slide nº 204

4.2 Método dos polinômios ortogonais

Cálculo das somas de quadrados:

Na análise de regressão decompomos a soma de quadrados de tratamentos nas partes devido à Soma de Quadrados da regressão linear, quadrática, cúbica e desvios da regressão.

Então a Soma de Quadrados dos Desvios da Regressão pode ser obtida por diferença:

$SQ_{DESVIO} = 370 - 100{,}00 - 245{,}00 - 25{,}00 = 0{,}00$

Nesse caso como temos I = 4 e decompomos até o terceiro grau é esperado que a Soma de Quadrados dos Desvios da Regressão fosse zero.

Slide nº 205

4.2 Método dos polinômios ortogonais

Análise de variância com decomposição da soma de quadrados de tratamentos em regressões

FV	GL	SQ	QM	F_{CALC} (sob Ho)
Tratamentos	I-1	SQ_{TRAT}	QM_{TRAT}	QM_{TRAT}/QM_E
1º Grau (RL)	1	SQ_{RL}	QM_{RL}	QM_{RL}/QM_E
2º Grau (RQ)	1	SQ_{RQ}	QM_{RQ}	QM_{RQ}/QM_E
3º Grau (RC)	1	SQ_{RC}	QM_{RC}	QM_{RC}/QM_E
Desvios (D)	I-4	SQ_D	QM_D	QM_D/QM_E
Erro	I (J-1)	SQ_E	QM_E	-
Total	IJ - 1	SQ_{TOTAL}	-	-

QM = SQ/GL

Slide nº 206

4.2 Método dos polinômios ortogonais

Para o nosso exemplo temos:

FV	GL	SQ	QM	F_{CALC} (sob H_0)	F_{TAB} 5%
Doses	3	370	123,333	8,433	3,24
1º Grau	1	100	100	6,838	4,49
2º Grau	1	245	245	16,752	4,49
3º Grau	1	25	25	1,709	4,49
Desvios	0	0	0	-	-
Erro	16	234	14,625	-	-
Total	19	604	-	-	-

A soma desses valores é igual a SQ_{DOSES}
100 + 245 + 25 + 0 = 370

Vamos agora testar as hipóteses para escolher o grau de regressão adequado.
O grau da regressão a ser escolhido é o de maior grau significativo independentemente da significância dos graus que antecedem.

Slide nº 207

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

Para interpretação do efeito linear de X sobre Y

a) Estabelecer as hipóteses

H_0: $b_1=0$ (não há efeito linear)
H_1: $b_1 \neq 0$ ($b_1<0$ ou $b_1>0$) (há efeito linear)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α) ➔ $\alpha = 5\%$

c) Calcular o valor de F_{CALC} da regressão linear

$$F_{CALC} = \frac{QM_{RL}}{QM_E} = \frac{100}{14,625} = 6,838$$

d) Comparar com o valor de $F_{TAB} = F_\alpha (GL_{RL}; GL_E)$

Slide nº 208

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador → GL_{RL}

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 209

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

e) Decisão e conclusão

- se $F_{CALC} \geq F_{TAB}$, rejeita-se H_0 e conclui-se que o efeito linear (positivo ou negativo) de X sobre Y é significativo em nível α de probabilidade de erro.

- se $F_{CALC} < F_{TAB}$, não rejeita-se H_0 e conclui-se que o efeito linear (positivo ou negativo) de X sobre Y não é significativo, ou seja, o efeito pode ser atribuído ao acaso.

Slide nº 210

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE
Nosso exemplo

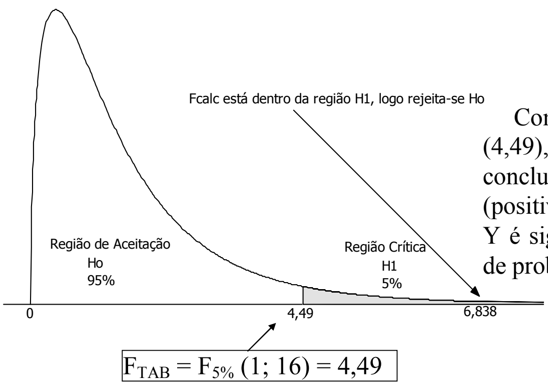

Como F_{CALC} (6,838) ≥ F_{TAB} (4,49), rejeitamos H_0 e concluímos que o efeito linear (positivo ou negativo) de X sobre Y é significativo em nível de 5% de probabilidade de erro.

Slide nº 211

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

Para interpretação do efeito quadrático de X sobre Y

a) Estabelecer as hipóteses

H_0: $b_2=0$ (não há efeito quadrático)
H_1: $b_2 \neq 0$ ($b_2<0$ ou $b_2>0$) (há efeito quadrático)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α) ➔ α = 5%

c) Calcular o valor de F_{CALC} da regressão quadrática

$$F_{CALC} = \frac{QM_{RQ}}{QM_E} = \frac{245}{14,625} = 16,752$$

d) Comparar com o valor de $F_{TAB} = F_\alpha (GL_{RQ}; GL_E)$

Slide nº 212

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{RQ}

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 213

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

e) Decisão e conclusão

- se $F_{CALC} \geq F_{TAB}$, rejeita-se H_0 e conclui-se que o efeito quadrático (positivo ou negativo) de X sobre Y é significativo em nível α de probabilidade de erro.

- se $F_{CALC} < F_{TAB}$, não rejeita-se H_0 e conclui-se que o efeito quadrático (positivo ou negativo) de X sobre Y não é significativo, ou seja, o efeito pode ser atribuído ao acaso.

Slide nº 214

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE
Nosso exemplo

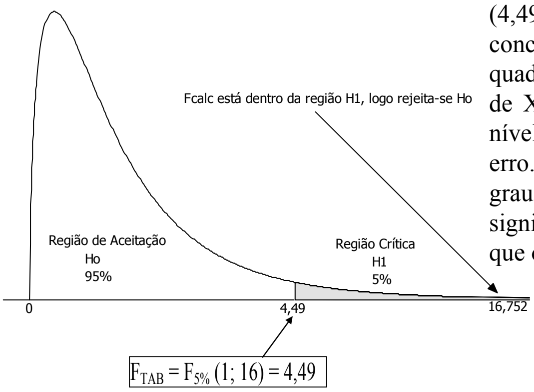

Como F_{CALC} (16,752) $\geq$ F_{TAB} (4,49), rejeitamos H_0 e concluímos que o efeito quadrático (positivo ou negativo) de X sobre Y é significativo em nível de 5% de probabilidade de erro. Em outras palavras, o 2º grau ajustou uma porção significativa de variação a mais que o 1º grau.

Slide nº 215

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

Para interpretação do efeito cúbico de X sobre Y

a) Estabelecer as hipóteses

H_0: $b_3=0$ (não há efeito cúbico)
H_1: $b_3 \neq 0$ ($b_3<0$ ou $b_3>0$) (há efeito cúbico)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α) ➔ $\alpha = 5\%$

c) Calcular o valor de F_{CALC} da regressão cúbica

$$F_{CALC} = \frac{QM_{RC}}{QM_E} = \frac{25}{14{,}625} = 1{,}709$$

d) Comparar com o valor de $F_{TAB} = F_\alpha\ (GL_{RC};\ GL_E)$

Slide nº 216

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟵⟶ GL_{RC}

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 217

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

e) Decisão e conclusão

- se $F_{CALC} \geq F_{TAB}$, rejeita-se H_0 e conclui-se que o efeito cúbico (positivo ou negativo) de X sobre Y é significativo em nível α probabilidade de erro. Ainda pode-se dizer que o 3º grau ajustou uma porção significativa de variação a mais daquela ajustada pelos 1º e 2º graus.

- se $F_{CALC} < F_{TAB}$, não rejeita-se H_0 e conclui-se que o efeito cúbico (positivo ou negativo) de X sobre Y não é significativo, ou seja, o efeito pode ser atribuído ao acaso.

Slide nº 218

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE
Nosso exemplo

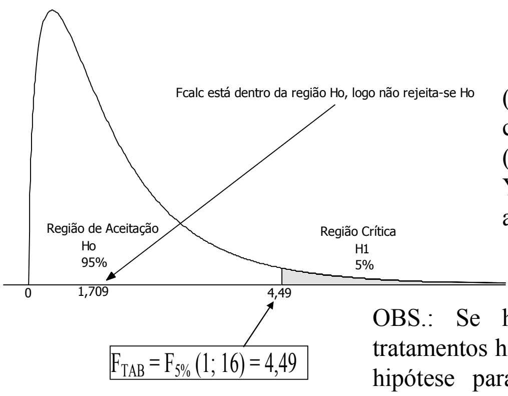

Como F_{CALC} (1,709) < F_{TAB} (4,49), não rejeitamos H_0 e e concluímos e que o efeito cúbico (positivo ou negativo) de X sobre Y é não significativo e pode ser atribuído ao acaso.

OBS.: Se houvesse mais que quatro tratamentos haveria necessidade de testar a hipótese para o efeito dos desvios da regressão.

Slide nº 219

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

Para interpretação do efeito dos desvios da regressão de X sobre Y

a) Estabelecer as hipóteses

H_0: $\delta_i^2 = 0$ (não há efeito dos desvios da regressão)

H1: $\delta_i^2 \neq 0$ (há efeito dos desvios da regressão)

b) Estabelecer o nível de significância do teste, ou erro tipo I (α) ➔ $\alpha = 5\%$

c) Calcular o valor de F_{CALC} dos desvios

$$F_{CALC} = \frac{QM_{DESVIOS}}{QM_E}$$

d) Comparar com o valor de $F_{TAB} = F_{\alpha}(GL_{DESVIOS}; GL_E)$

Slide nº 220

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ← → $GL_{Desvios}$

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 221

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

e) Decisão e conclusão

- se $F_{CALC} \geq F_{TAB}$, rejeita-se H_0 e conclui-se, em nível α de probabilidade de erro, que um efeito de grau superior ao terceiro é significativo e deveria ser incluído no modelo.

- se $F_{CALC} < F_{TAB}$, não rejeita-se H_0 e conclui-se que um efeito de grau superior ao terceiro é não significativo e não deve ser incluído no modelo.

Slide nº 222

4.2 Método dos polinômios ortogonais

Os testes de hipóteses das regressões determinam qual o grau da equação a ser ajustada. *Assim, o grau da equação a ser usado é o de maior grau significativo, não importando as significâncias dos graus que o antecedem.*

Assim temos os seguintes casos:

Casos	Hipóteses adotadas*			→	Equação a ser ajustada
	RL	RQ	RC	→	
1	H_1	H_1	H_1	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2 + \hat{b}_3 X^3$
2	H_0	H_1	H_1	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2 + \hat{b}_3 X^3$
3	H_0	H_0	H_1	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2 + \hat{b}_3 X^3$
4	H_1	H_0	H_1	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2 + \hat{b}_3 X^3$
5	H_1	H_1	H_0	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2$ → Nosso exemplo
6	H_0	H_1	H_0	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2$
7	H_1	H_0	H_0	→	$\hat{Y} = \hat{b}_0 + \hat{b}_1 X$
8	H_0	H_0	H_0	→	Nenhuma equação se ajusta

* H_1 = efeito significativo; H_0 = efeito não significativo.

Slide nº 223

4.2 Método dos polinômios ortogonais

TESTE DE HIPÓTESE

Nos casos em que a regressão de 1º grau for adequada, um novo experimento, com quantidades maiores ou menores, deve ser planejado e executado. Isto pode ser feito aumentando-se o número de tratamentos ou aumentando-se as diferenças entre os níveis dos tratamentos.

Nesse novo experimento, poderá ser atingido um ponto (resposta) que corresponde ao mínimo ou ao máximo da curva; o que irá melhorar a interpretação e a conclusão do efeito de tratamentos **(X) sobre a variável observada (Y).**

No nosso exemplo (caso 5 da tabela anterior), ou seja, como foram rejeitadas as hipóteses H_0: $b_1=0$ e H_0: $b_2=0$ em nível de 5% de significância, e não foi rejeitada a hipótese H_0: $b_3=0$ a equação a ser ajustada é a de 2º grau, ou seja $\hat{Y} = \hat{b}_0 + \hat{b}_1 X + \hat{b}_2 X^2$

Slide nº 224

4.2 Método dos polinômios ortogonais

O modelo geral para estimar uma equação quando se usa o método dos polinômios ortogonais, é:

$$Y = \overline{Y}.. + B_1M_1P_1 + B_2M_2P_2 + ... + B_kM_kP_k + e$$

Para estimar uma equação usa-se parte da equação geral, de acordo com o modelo determinado pelos testes de hipóteses das regressões. Considerando até o terceiro grau a determinação do grau da equação é feita segundo o esquema:

$$\hat{Y} = \underbrace{\underbrace{\underbrace{\overline{Y}.. + B_1M_1P_1}_{\text{equação linear}} + B_2M_2P_2}_{\text{equação quadrática}} + B_3M_3P_3}_{\text{equação cúbica}}$$

Slide nº 225

4.2 Método dos polinômios ortogonais

Então para o nosso exemplo usamos:

$$\hat{Y} = \overline{Y}.. + B_1M_1P_1 + B_2M_2P_2$$

Para estimar os parâmetros do modelo quadrático fazemos os seguintes cálculos:

$\overline{Y}..$ = média geral do experimento = 50,00

Slide nº 226

4.2 Método dos polinômios ortogonais

$$B_1 = \sum_i C_{i1} Y_{i.} / J \sum_i C_{i1}^2$$

$$B_1 = \frac{(-3*220)+(-1*255)+(1*280)+(3*245)}{5*\left[(-3)^2+(-1)^2+(1)^2+(3)^2\right]}$$

B_1 = (100) / (5 x 20) = 1,00

$$B_2 = \sum_i C_{i2} Y_{i.} / J \sum_i C_{i2}^2$$

$$B_2 = \frac{(1*220)+(-1*255)+(-1*280)+(1*245)}{5*\left[(1)^2+(-1)^2+(-1)^2+(1)^2\right]}$$

B_2 = (-70) / (5 x 4) = -3,50

Slide nº 227

4.2 Método dos polinômios ortogonais

Os valores de M_1 e M_2 são consultados nas tabelas dos polinômios ortogonais (ver tabela auxiliar anterior).

$M_1 = 2$
$M_2 = 1$

$P_1 = x$;
$P_2 = x^2 - \{(I^2\text{-}1)/12\} = x^2 - \{(4^2\text{-}1)/12\} = x^2 - 1{,}25$

Calculamos ainda: $x = \dfrac{X - \overline{X}}{h} = \dfrac{X - 15}{10}$ onde $\overline{X}$ é a média dos valores de X, ou seja, (0 + 10 + 20 + 30)/4 = 15, e h é a amplitude ou intervalo entre os valores de X, ou seja, 10 - 0 = 10, ou ainda 20 -10 = 10 e assim sucessivamente, pois os valores são eqüidistantes.

Slide nº 228

4.2 Método dos polinômios ortogonais

OBS.: Para o ajuste da equação de terceiro grau usa-se:

$$B_3 = \sum_i C_{i3} Y_i. / J \sum_i C_{i3}^2$$

M_3 obtido em tabelas dos polinômios ortogonais

P3 = $x3$ - x $\{(3I^2 - 7)/20\}$

Onde I = número de tratamentos

Slide nº 229

4.2 Método dos polinômios ortogonais

Substituindo os termos (B1, B2, M1, M2, P1, P2) na equação geral têm-se:

$$\hat{Y} = \overline{Y}.. + B_1 M_1 P_1 + B_2 M_2 P_2$$

$$\hat{Y} = 50{,}00 + (1{,}00)(2)x + (-3{,}50)(1)(x^2 - 1{,}25)$$

$$\hat{Y} = 50{,}00 + 2{,}00x + 4{,}375 - 3{,}50\,x^2$$

$$\hat{Y} = 54{,}375 + 2{,}00x - 3{,}50\,x^2$$

Precisamos agora substituir x por $x = \dfrac{X - 15}{10}$

$$\hat{Y} = 54{,}375 + 2{,}00\left(\frac{X-15}{10}\right) - 3{,}50\left(\frac{X-15}{10}\right)^2$$

$$\hat{Y} = 54{,}375 + 2{,}00\left(\frac{X-15}{10}\right) - 3{,}50\left(\frac{X^2 - 30X + 225}{100}\right)$$

$$\hat{Y} = 54{,}375 + 0{,}20(X - 15) - 0{,}035\,(X^2 - 30X + 225)$$

$$\hat{Y} = 54{,}375 + 0{,}20\,X - 3{,}00 - 0{,}035X^2 + 1{,}05\,X - 7{,}875$$

$$\hat{Y} = 43{,}5 + 1{,}25\,X - 0{,}035X^2$$

Slide nº 230

4.2 Método dos polinômios ortogonais

Assim, obtemos a equação válida para X (dose) pertencente ao intervalo entre 0 e 30. *Extrapolações são sempre perigosas, pois não avaliamos o comportamento de Y com outros valores de X.*

Calculamos o coeficiente de determinação (R^2) por meio de:

Para a regressão linear: $R^2 = \dfrac{SQ_{RL}}{SQ_{TRAT}}$

Para a regressão quadrática: $R^2 = \dfrac{SQ_{RL} + SQ_{RQ}}{SQ_{TRAT}}$

Para a regressão cúbica: $R^2 = \dfrac{SQ_{RL} + SQ_{RQ} + SQ_{RC}}{SQ_{TRAT}}$

Slide nº 231

4.2 Método dos polinômios ortogonais

Assim, para o nosso exemplo:

$$R^2 = \frac{SQ_{RL} + SQ_{RQ}}{SQ_{DOSE}} = \frac{100 + 245}{370} = 0{,}9324$$

Para que os $\mathbf{R^2}$ se tornem comparáveis, para diferentes situações, convém calcular o $\mathbf{R^2}$ ajustado ($R2_{aj}$) em função do número **I** de grupos. Este ajustamento é obtido por:

$R^2_{aj} = R^2 - \dfrac{p-1}{I-p}\left[1 - R^2\right]$ em que **p** é o número de parâmetros da equação (**p=2**, para equação do 1º grau; **p=3**, para equação do 2º grau; etc.).

Então temos:

$$R^2_{aj} = 0{,}9324 - \frac{3-1}{4-3}\left[1 - 0{,}9324\right] = 0{,}7972$$

Conclusão do $\mathbf{R^2}$: 79,72% da variação na resposta (Y) é explicada pela variação de X. O restante (20,28%) é explicado por outras variáveis (exemplo: X1, X2, X3, etc.) que não estão incluídas no modelo.

Slide nº 232

4.3 Estudo da máxima eficiência técnica e econômica

4.3 Ponto de Máxima Eficiência Técnica (PMET)

É interessante estimar o ponto de máxima eficiência técnica (PMET), pois esse é o valor de X que irá proporcionar a melhor resposta na variável observada (Y). Essa estimativa irá depender do grau ajustado para a equação de regressão:

Equação de 2º grau: PMET= $X = -\hat{b}_1/2\hat{b}_2$

Equação de 3º grau: PMET= $X = (-2 * \hat{b}_2 \pm \sqrt{4 * \hat{b}_2^2 - 12 * \hat{b}_1 * \hat{b}_3}\ ) / 6 * \hat{b}_3$

Slide nº 233

4.3 Ponto de Máxima Eficiência Técnica (PMET)

Como no nosso exemplo a equação obtida foi de 2º grau, têm-se:

PMET= -1,25/[2(-0,035)] = 17,86 ➔ essa é quantidade de X que proporciona maior valor de Y. No caso, com X = 17,86 o $\hat{Y}$ estimado por meio do modelo é:

$$\hat{Y} = 43{,}5 + 1{,}25\ X - 0{,}035 X^2$$

$$\hat{Y} = 43{,}5 + 1{,}25 * 17{,}86 - 0{,}035 * 17{,}86^2$$

$$\hat{Y} = 54{,}66$$

Slide nº 234

4.3 Ponto de Máxima Eficiência Técnica (PMET)

Para divulgação do resultado desse experimento apresentamos o seguinte gráfico:

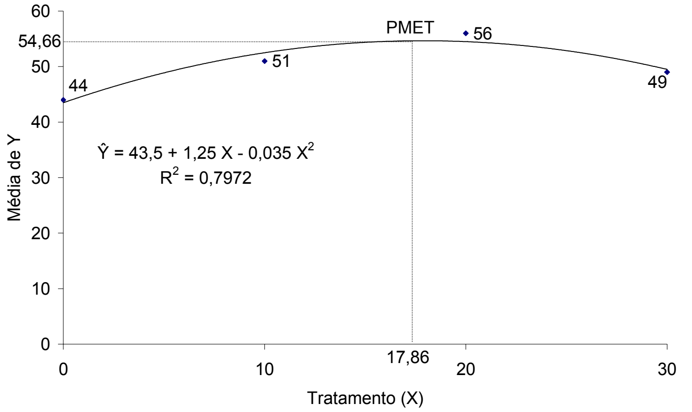

Concluímos para esse experimento que a quantidade X = 17,86 proporciona a maior resposta (máximo) de Y (54,66). Ou ainda que a dose de 17,86 de nitrogênio proporciona plantas de eucalipto com 54,66 cm de altura.

Slide nº 235

Exercício

Prática 4 – Análise de regressão

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 236

5 Experimentos fatoriais

5.1 Introdução

Estudamos os delineamentos DIC, DBA e DQL com apenas um fator (unifatorial)

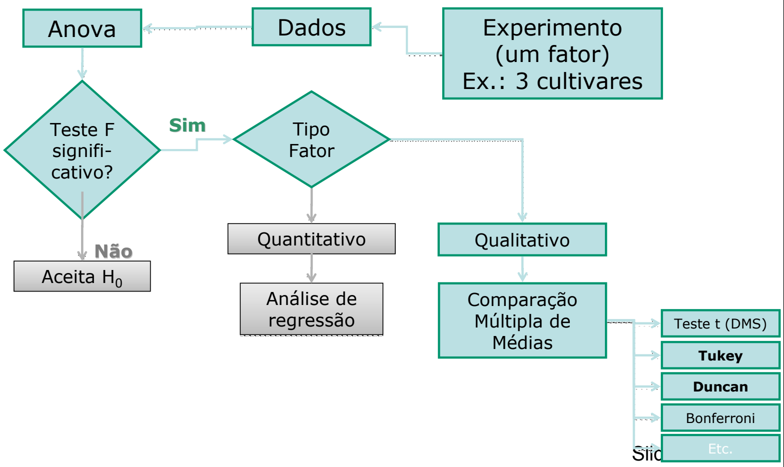

Estudamos os delineamentos DIC, DBA e DQL com apenas um fator (unifatorial)

Experimento
(um fator)
Ex.: 3 cultivares

Um fator = experimento unifatorial

⇩

O Fator CULTIVAR tem 3 níveis.

Temos então 3 tratamentos:
-Tratamento 1 = cultivar 1
-Tratamento 2 = cultivar 2
- Tratamento 3 = cultivar 3

A pergunta que pode ser formulada é ***"Qual seria o comportamento das cultivares se a semeadura fosse em outra época e se outro nível de adubação fosse utilizado?"***. Não se pode responder esta pergunta sem que estes fatores sejam estudados no mesmo experimento, ou seja, na forma de um experimento fatorial.

Slide nº 240

Estudaremos os delineamentos DIC, DBA e DQL com mais de um fator

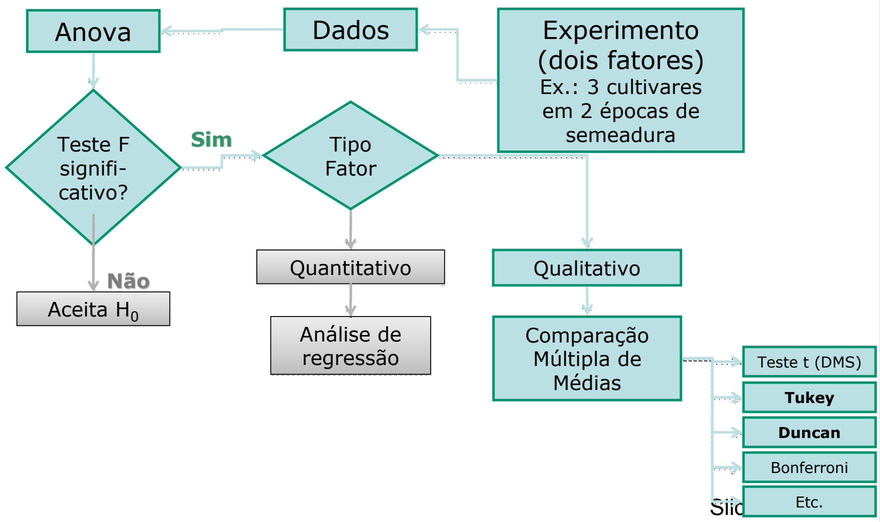

Estudaremos os delineamentos DIC, DBA e DQL com mais de um fator

Experimento (dois fatores) Ex.: 3 cultivares em 2 épocas de semeadura

Dois fatores = experimento bifatorial

⇩

O fator CULTIVAR tem 3 níveis.
O fator ÉPOCA tem 2 níveis.

Temos então 6 tratamentos:
Tratamento 1 - cultivar 1 na época 1
Tratamento 2 - cultivar 1 na época 2
Tratamento 3 - cultivar 2 na época 1
Tratamento 4 - cultivar 2 na época 2
Tratamento 5 - cultivar 3 na época 1
Tratamento 6 - cultivar 3 na época 2

Slide nº 242

Estudaremos os delineamentos DIC, DBA e DQL com mais de um fator

Experimento
(três fatores)
Ex.: 3 cultivares
em 2 épocas de semeadura
em dois níveis de adubação

⇩

O fator CULTIVAR tem 3 níveis.
O fator ÉPOCA tem 2 níveis.
O fator ADUBAÇÃO tem 2 níveis.

Temos então 12 tratamentos:
Tratamento 1 - cultivar 1 na época 1 na adubação 1
Tratamento 2 - cultivar 1 na época 1 na adubação 2
Tratamento 3 - cultivar 1 na época 2 na adubação 1
Tratamento 4 - cultivar 1 na época 2 na adubação 2
Tratamento 5 - cultivar 2 na época 1 na adubação 1
Tratamento 6 - cultivar 2 na época 1 na adubação 2
Tratamento 7 - cultivar 2 na época 2 na adubação 1
Tratamento 8 - cultivar 2 na época 2 na adubação 2
Tratamento 9 - cultivar 3 na época 1 na adubação 1
Tratamento 10 - cultivar 3 na época 1 na adubação 2
Tratamento 11 - cultivar 3 na época 2 na adubação 1
Tratamento 12 - cultivar 3 na época 2 na adubação 2

Três fatores = experimento trifatorial

Slide nº 243

5.2 Experimentos bifatoriais

Experimento bifatorial: Fator **A e** Fator **D.**

Os níveis de **A** são: A1, A2, ... , AI
e os níveis de **D** são: D1, D2, ...,DJ.

Exemplo, para I=3 e J=4

Temos IJ tratamentos (3x4 = 12 tratamentos).

Fator	Níveis
A	A_1, A_2 e A_3
D	D_1, D_2, D_3 e D_4

Número do Tratamento	Tratamento
1	A_1D_1
2	A_1D_2
3	A_1D_3
4	A_1D_4
5	A_2D_1
6	A_2D_2
7	A_2D_3
8	A_2D_4
9	A_3D_1
10	A_3D_2
11	A_3D_3
12	A_3D_4

Uma seqüência de **IJ** tratamentos pode ser avaliado em qualquer um dos delineamentos experimentais básicos (DIC, DBA e DQL), dependendo das condições de homogeneidade das UE, em K repetições.

Slide nº 245

Exemplo:
Experimento bifatorial 3x4 no Delineamento Inteiramente Casualizado (DIC) com 2 repetições.

Sorteio: Cada unidade experimental pode receber qualquer tratamento em qualquer uma das K repetições.

Fator	Níveis
A	A_1, A_2 e A_3
D	D_1, D_2, D_3 e D_4

A_3D_1	A_2D_2	A_1D_1	A_2D_3	A_1D_1	A_3D_4	A_2D_4	A_1D_2	A_3D_1	A_3D_3	A_1D_4	A_2D_4
A_3D_2	A_2D_3	A_1D_2	A_1D_3	A_1D_4	A_1D_3	A_3D_2	A_2D_1	A_3D_4	A_3D_3	A_2D_1	A_2D_2

DIC == > todas as unidades experimentais são homogêneas.

Slide nº 246

Exemplo:
Experimento bifatorial 3x4 no Delineamento Blocos ao Acaso (DBA) com 2 repetições.

Sorteio: Os 12 tratamentos são casualizados dentro de cada bloco. Um sorteio para cada bloco.

Fator	Níveis
A	A_1, A_2 e A_3
D	D_1, D_2, D_3 e D_4

A_1D_3	A_2D_1	A_2D_4	A_1D_1	A_3D_1	A_3D_4	A_1D_2	A_3D_3	A_2D_2	A_1D_4	A_3D_2	A_2D_3	} Bloco 1
A_1D_4	A_3D_3	A_2D_3	A_1D_1	A_3D_2	A_2D_2	A_3D_4	A_1D_3	A_2D_1	A_1D_2	A_2D_4	A_3D_1	} Bloco 2

DBA == > bloco = conjunto de unidades experimentais homogêneas.

Slide nº 247

INTERAÇÃO

Uma das principais informações que se pode obter nos experimentos fatoriais é o estudo da interação entre os fatores**, isto é, verificar se as diferenças nas respostas dos níveis de um fator são similares ou diferentes em todos os níveis do outro fator ou fatores.**

Slide nº 248

Organização dos dados para análise

Slide nº 249

Variável resposta Y é identificada por:

$\mathbf{Y_{ijk}}$ como sendo a observação obtida na unidade experimental que recebeu o nível i do fator A e o nível j do fator D, na repetição k.

A_1D_3	A_2D_1	A_2D_4	A_1D_1	A_3D_1	A_3D_4	A_1D_2	A_3D_3	A_2D_2	A_1D_4	A_3D_2	A_2D_3	Bloco 1
A_1D_4	A_3D_3	A_2D_3	A_1D_1	A_3D_2	A_2D_2	A_3D_4	A_1D_3	A_2D_1	A_1D_2	A_2D_4	A_3D_1	Bloco 2

Exemplo: Y_{111} = Essa unidade experimental recebeu o nível 1 do fator A e o nível 1 do fator D, na repetição 1 (bloco 1).

Slide nº 250

Resultados de um experimento bifatorial no delineamento blocos ao acaso com K repetições

Total de tratamento ij

Tratamento	Bloco 1	Bloco 2	. . .	Bloco K	$Y_{ij.}$
A_1D_1	Y_{111}	Y_{112}	. . .	Y_{11k}	$Y_{11.}$
A_1D_2	Y_{121}	Y_{122}	. . .	Y_{12k}	$Y_{12.}$
. . .					
A_1D_J	Y_{1J1}	Y_{1J2}	. . .	Y_{1Jk}	$Y_{1J.}$
A_2D_1	Y_{211}	Y_{212}	. . .	Y_{21k}	$Y_{21.}$
A_2D_2	Y_{221}	Y_{222}	. . .	Y_{22k}	$Y_{22.}$
. . .					
A_2D_J	Y_{2J1}	Y_{2J2}	. . .	Y_{2Jk}	$Y_{2J.}$
. . .					
A_ID_1	Y_{I11}	Y_{I12}	. . .	Y_{I1k}	$Y_{I1.}$
A_ID_2	Y_{I21}	Y_{I22}	. . .	Y_{I2k}	$Y_{I2.}$
. . .					
A_ID_J	Y_{IJ1}	Y_{IJ2}	. . .	Y_{IJk}	$Y_{IJ.}$
$Y_{..k}$	$Y_{..1}$	$Y_{..2}$	. . .	$Y_{..k}$	$Y_{...}$
Total do bloco k	Total do bloco 1			Total do bloco k	Total geral

Slide nº 251

Totais de tratamentos e dos níveis de um experimento bifatorial AxD.

$Y_{11\cdot}$ = Total do tratamento A_1D_1

Total do nível j do fator D

		Fator A				
		A_1	A_2	. . .	A_I	$Y_{\cdot j\cdot}$
Fator D	D_1	$Y_{11\cdot}$	$Y_{21\cdot}$	. . .	$Y_{I1\cdot}$	$Y_{\cdot 1\cdot}$
	D_2	$Y_{12\cdot}$	$Y_{22\cdot}$	. . .	$Y_{I2\cdot}$	$Y_{\cdot 2\cdot}$
	. . .					
	D_J	$Y_{1J\cdot}$	$Y_{2J\cdot}$	. . .	$Y_{IJ\cdot}$	$Y_{\cdot J\cdot}$
	$Y_{i\cdot\cdot}$	$Y_{1\cdot\cdot}$	$Y_{2\cdot\cdot}$	. . .	$Y_{I\cdot\cdot}$	$Y_{\cdot\cdot\cdot}$

Total do nível i do fator A

Total do nível 2 do fator A

Total geral

$Y_{\cdot 2\cdot}$ = Total do nível 2 do fator D

Slide nº 252

Médias de tratamentos e dos níveis de um experimento bifatorial AxD.

Média do nível j do fator D

Média do tratamento A_1D_1

		Fator A				
		A_1	A_2	. . .	A_I	$\bar{Y}_{\cdot j\cdot}$
Fator D	D_1	$\bar{Y}_{11\cdot}$	$\bar{Y}_{21\cdot}$	. . .	$\bar{Y}_{I1}$	$\bar{Y}_{\cdot 1\cdot}$
	D_2	$\bar{Y}_{12\cdot}$	$\bar{Y}_{22\cdot}$	. . .	$\bar{Y}_{I2}$	$\bar{Y}_{\cdot 2\cdot}$
	. . .					
	D_J	$\bar{Y}_{1J\cdot}$	$\bar{Y}_{2J\cdot}$	. . .	$\bar{Y}_{IJ\cdot}$	$\bar{Y}_{\cdot J\cdot}$
	$\bar{Y}_{i\cdot\cdot}$	$\bar{Y}_{1\cdot\cdot}$	$\bar{Y}_{2\cdot\cdot}$	. . .	$\bar{Y}_{I\cdot\cdot}$	$\bar{Y}_{\cdot\cdot\cdot}$

Média do nível i do fator A

Média do nível 2 do fator D

Média do nível 2 do fator A

Média geral

Slide nº 253

Modelo matemático

Slide nº 254

O modelo matemático para um experimento bifatorial, no delineamento blocos ao acaso é caracterizado por:

$$\boxed{\mathbf{Y_{ijk} = m + a_i + d_j + (ad)_{ij} + b_k + e_{ijk}}}$$

em que:

$\mathbf{Y_{ijk}}$ é uma observação no bloco k (k = 1, 2 , ... ,**K**) referente ao tratamento "nível i do fator **A** com o nível j do fator **D**";

m é a média geral do experimento;

$\mathbf{a_i}$ é o efeito do nível i (i = 1, 2, ... , **I**) do fator **A**;

$\mathbf{d_j}$ é o efeito do nível j (j = 1, 2, ... ,**J**) do fator **D**;

$\mathbf{(ad)_{ij}}$ é o efeito da interação do nível i do fator **A** com o nível j do fator **D**;

$\mathbf{b_k}$ é o efeito aleatório do bloco k, conjuntamente independentes de distribuição normal, média zero e variância comum σ_b^2 ; $\mathbf{e_{ijk}}$ é o efeito aleatório do erro experimental, conjuntamente independentes de distribuição normal, média zero e variância comum σ^2.

Slide nº 255

Estimativa dos parâmetros

$$\hat{m} = Y\ldots/IJK = \overline{Y}\ldots;$$

$$\hat{a}_i = \overline{Y}_i\ldots - \hat{m};$$

$$\hat{d}_j = \overline{Y}_{\cdot j}\,. - \hat{m};$$

$$\hat{b}_k = \overline{Y}_{\cdot\cdot k} - \hat{m};$$

$$\left(a\hat{d}\right)_{ij} = \overline{Y}_{ij}. - \hat{m} - \hat{a}_i - \hat{d}_j$$

Restrições usuais, $\sum_i \hat{a}_i = \sum_j \hat{d}_j = \sum_k \hat{b}_k = 0$ e $\sum_i \left(a\hat{d}\right)_{ij} = \sum_j \left(a\hat{d}\right)_{ij} = 0$ equivalente a $\sum_{ij} \left(a\hat{d}\right)_{ij} = 0$.

Conceitos e interpretação dos efeitos principais A e D e da interação AD

Caso 1. Considere as estimativas das médias (sobre K repetições) e dos efeitos principais e das interações [(ad)], entre parênteses:

(A_iD_j)	**A_1**	**A_2**	$\bar{Y}_{\cdot j \cdot}$	Efeito simples de $\hat{d}_j$
D_1	40 (1,5)	42 (-1,5)	41	$\hat{d}_1 = 41 - 45{,}5 = -4{,}5$
D_2	46 (-1,5)	54 (1,5)	50	$\hat{d}_2 = 50 - 45{,}5 = 4{,}5$
$\bar{Y}_{i\cdot\cdot}$	43	48	45,5	$\sum_j \hat{d}_j = 0$
Efeito simples de $\hat{a}_i$	$\hat{a}_1 = 43 - 45{,}5 = -2{,}5$	$\hat{a}_2 = 48 - 45{,}5 = 2{,}5$	$\sum_i \hat{a}_i = 0$	

Efeito da interação $(\hat{ad})_{ij}$ == > $(\hat{ad})_{ij} = \bar{Y}_{ij\cdot} - \hat{m} - \hat{a}_i - \hat{d}_j$

$(\hat{ad})_{11} = \bar{Y}_{11\cdot} - \hat{m} - \hat{a}_1 - \hat{d}_1 \rightarrow (\hat{ad})_{11} = 40 - 45{,}5 - (-2{,}5) - (-4{,}5) = 1{,}5$

$(\hat{ad})_{12} = \bar{Y}_{12\cdot} - \hat{m} - \hat{a}_1 - \hat{d}_2 \rightarrow (\hat{ad})_{12} = 46 - 45{,}5 - (-2{,}5) - (4{,}5) = -1{,}5$

$(\hat{ad})_{21} = \bar{Y}_{21\cdot} - \hat{m} - \hat{a}_2 - \hat{d}_1 \rightarrow (\hat{ad})_{21} = 42 - 45{,}5 - (2{,}5) - (-4{,}5) = -1{,}5$

$(\hat{ad})_{22} = \bar{Y}_{22\cdot} - \hat{m} - \hat{a}_2 - \hat{d}_2 \rightarrow (\hat{ad})_{22} = 54 - 45{,}5 - (2{,}5) - (4{,}5) = 1{,}5$

Restrição: $\sum_{ij} (\hat{ad})_{ij} = 0$

1,5 + (-1,5) + (-1,5) + 1,5 = 0 == > 0 = 0 (confere a restrição)

Caso 1. Considere as estimativas das médias (sobre K repetições) e dos efeitos principais e das interações [(ad)], entre parênteses:

(A_iD_j)	A_1	A_2	$\overline{Y}_{\cdot j \cdot}$	Efeito simples de $\hat{d}_j$
D_1	40 (1,5)	42 (-1,5)	41	$\hat{d}_1 = 41 - 45{,}5 = -4{,}5$
D_2	46 (-1,5)	54 (1,5)	50	$\hat{d}_2 = 50 - 45{,}5 = 4{,}5$
$\overline{Y}_{i\cdot\cdot}$	43	48	45,5	$\sum_j \hat{d}_j = 0$
Efeito simples de $\hat{a}_i$	$\hat{a}_1 = 43 - 45{,}5 = -2{,}5$	$\hat{a}_2 = 48 - 45{,}5 = 2{,}5$	$\sum_i \hat{a}_i = 0$	

~~**Efeitos principais**~~

O efeito principal do fator **A**, para o caso de dois níveis, é obtido pela diferença dos efeitos simples ($\hat{a}_i$), isto é: $\hat{a}_2 - \hat{a}_1 = 2{,}5 - (-2{,}5) = 5{,}0$ ou $\overline{Y}_{2\cdot\cdot} - \overline{Y}_{1\cdot\cdot} = 48 - 43 = 5$

O efeito principal do fator **D** é obtido por:

$\hat{d}_2 - \hat{d}_1 = 4{,}5 - (-4{,}5) = 9{,}0$ ou $\overline{Y}_{\cdot 2 \cdot} - \overline{Y}_{\cdot 1 \cdot} = 50 - 41 = 9$.

Logo, o efeito principal de um fator é obtido ignorando o(s) efeito(s) do(s) outro(s) fator(es).

Slide nº 260

Caso 1. Considere as estimativas das médias (sobre K repetições) e dos efeitos principais e das interações [(ad)], entre parênteses:

(A_iD_j)	A_1	A_2	$\overline{Y}_{\cdot j \cdot}$	Efeito simples de $\hat{d}_j$
D_1	40 (1,5)	42 (-1,5)	41	$\hat{d}_1 = 41 - 45{,}5 = -4{,}5$
D_2	46 (-1,5)	54 (1,5)	50	$\hat{d}_2 = 50 - 45{,}5 = 4{,}5$
$\overline{Y}_{i\cdot\cdot}$	43	48	45,5	$\sum_j \hat{d}_j = 0$
Efeito simples de $\hat{a}_i$	$\hat{a}_1 = 43 - 45{,}5 = -2{,}5$	$\hat{a}_2 = 48 - 45{,}5 = 2{,}5$	$\sum_i \hat{a}_i = 0$	

A interação é o efeito atribuído a uma combinação entre os níveis de dois fatores e que não é explicada pelos efeitos principais destes dois fatores.

No caso 1, acima, no quadro dos efeitos da interação **(ad)**$_{ij}$, observamos que as interações A_1D_1 e A_2D_2 são positivas (sinergismo) e as interações A_1D_2 e A_2D_1 são negativas (antagonismo). Logo existe interação.

Slide nº 261

Caso 1. Considere as estimativas das médias (sobre K repetições) e dos efeitos principais e das interações [(ad)], entre parênteses:

(A_iD_j)	**A_1**	**A_2**	$\bar{Y}_{\cdot j \cdot}$	Efeito simples de $\hat{d}_j$
D_1	40 (1,5)	42 (-1,5)	41	$\hat{d}_1 = 41 - 45{,}5 = -4{,}5$
D_2	46 (-1,5)	54 (1,5)	50	$\hat{d}_2 = 50 - 45{,}5 = 4{,}5$
$\bar{Y}_{i\cdot\cdot}$	43	48	45,5	$\sum_j \hat{d}_j = 0$
Efeito simples de $\hat{a}_i$	$\hat{a}_1 = 43 - 45{,}5 = -2{,}5$	$\hat{a}_2 = 48 - 45{,}5 = 2{,}5$	$\sum_i \hat{a}_i = 0$	

Há interação - a interação pode ser entendida como uma mudança no comportamento (ou nas diferenças) dos níveis de um fator quando varia os níveis do outro fator.

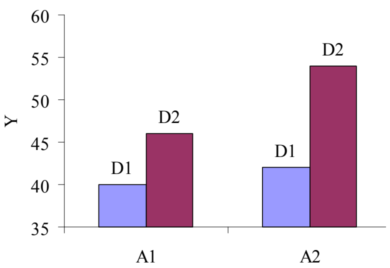

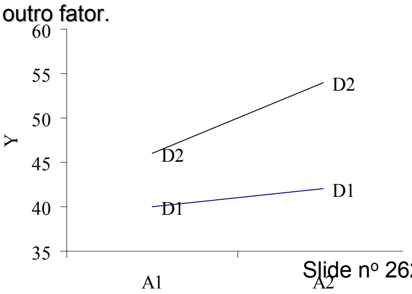

Slide nº 262

Caso 2. Considere as estimativas das médias (sobre K repetições) e dos efeitos principais e das interações [(ad)], entre parênteses:

(A_iD_j)	**A_1**	**A_2**	$\bar{Y}_{\cdot j \cdot}$	$\hat{d}_j$
D_1	40 (-3)	42 (3)	41	0
D_2	46 (3)	36 (-3)	41	0
$\bar{Y}_{i\cdot\cdot}$	43	39	41	0
$\hat{a}_i$	2	-2	0	

Há interação - representada por uma alteração na direção da resposta

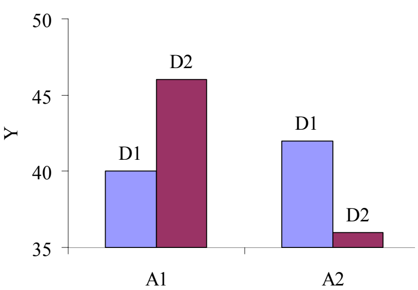

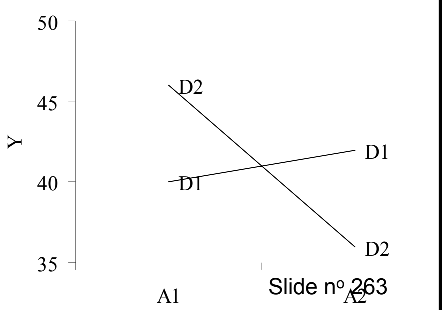

Slide nº 263

Caso 3. Considere as estimativas das médias (sobre K repetições) e dos efeitos principais e das interações [(ad)], entre parênteses:

(A_iD_j)	A_1	A_2	$\bar{Y}_{.j.}$	$\hat{d}_j$
D_1	40 (0)	42 (0)	41	-3
D_2	46 (0)	48 (0)	47	3
$\bar{Y}_{i..}$	43	45	44	0
$\hat{a}_i$	-1	1	0	

Não há interação – retas paralelas

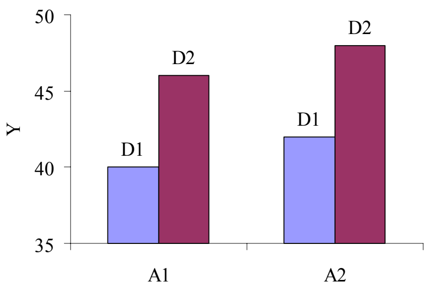

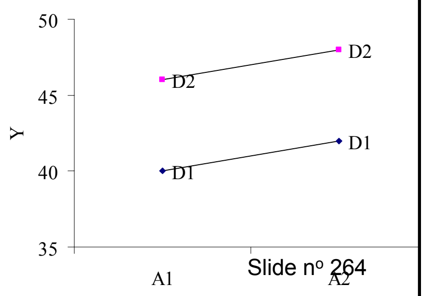

Slide nº 264

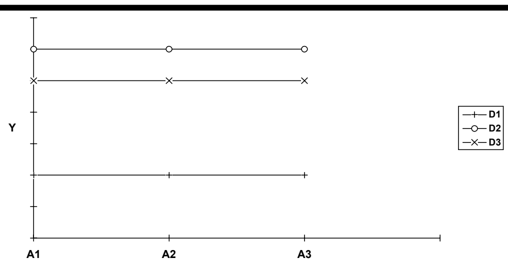

- Sem interação;
- Sem efeito do fator A;
- Com efeito do fator D.

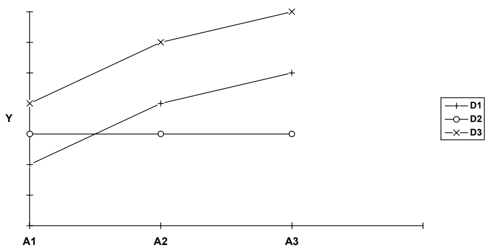

- Com interação;
- Com efeito do fator A;
- Com efeito do fator D.

Demonstração do comportamento de um fator quantitativo (D) e um qualita

Slide nº 265

Como nos resultados dos experimentos sempre existe o erro experimental não se deve fazer conclusões baseadas na simples observação gráfica. Para saber se a interação e/ou os efeitos principais são significativos deve-se fazer a análise de variância e os respectivos testes de hipóteses.

Após os testes de hipótese da análise de variância deve-se fazer as análises complementares adequadas, ou seja, conforme os resultados dos testes de hipóteses faz-se as análises complementares.

Slide nº 266

Análise de variância (modelo fixo)

Slide nº 267

Análise de variância de um experimento bifatorial (Fator A e Fator D) no delineamento blocos ao acaso

F.V.	GL	SQ	QM	F_{CALC}
Blocos	K-1	SQ_{BL}	QM_{BL}	QM_{BL}/QM_E
A	I-1	SQ_A	QM_A	QM_A/QM_E
D	J-1	SQ_D	QM_D	QM_D/QM_E
AxD	(I-1)(J-1)	SQ_{AD}	QM_{AD}	QM_{AD}/QM_E
Erro	(IJ-1)(K-1)	SQ_E	QM_E	-
Total	IJK-1	SQ_{TOTAL}	-	-

Slide nº 268

Fator de correção ==> $C = Y_{...}^2 / IJK$

Somas de quadrados

$$SQ_{Total} = \sum_{ijk} Y_{ijk}^2 - C$$

$$SQ_A = (1/JK)\sum_i Y_{i}^2.. - C$$

$$SQ_D = (1/IK)\sum_j Y^2._j. - C$$

$$SQ_{AD} = (1/K)\sum_{ij} Y_{ij}^2. - C - SQ_A - SQ_D$$

$$SQ_{Blocos} = (1/IJ)\sum_k Y^2.._k - C$$

$$SQ_E = SQ_{Total} - SQ_{Blocos} - SQ_A - SQ_D - SQ_{AD}$$

Slide nº 269

Quadrado Médio = Soma de Quadrado/Graus de Liberdade

$$QM_{BLOCO} = SQ_{BLOCO}/GL_{BLOCO}$$
$$QM_A = SQ_A/GL_A$$
$$QM_D = SQ_D/GL_D$$
$$QM_{AD} = SQ_{AD}/GL_{AD}$$
$$QM_E = SQ_E/GL_E$$

Slide nº 270

Teste de hipótese para o efeito da interação AD

a) Estabelecer as hipóteses:

H_0: $ad_{ij} = 0$ (interação entre os fatores A e D não difere de zero, ou seja, a interação não é significativa).

H_1: $ad_{ij} \neq 0$ (a interação difere de zero, ou seja, a interação é significativa).

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_{AD}/QM_E$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_{AD};\ GL_E)$

Veja tabela F a seguir (5%)

Slide nº 271

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{AD}

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 272

e) Decisão e conclusão

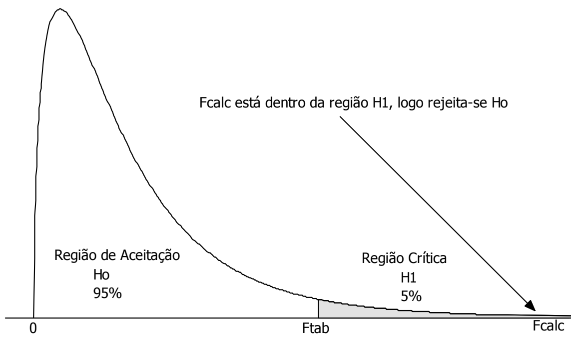

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0 e concluímos que existe interação em nível α probabilidade de erro. A interação estimada não pode ser atribuída ao acaso, ou seja, é significativa. Existe interação entre os fatores A e D.

Slide nº 273

e) Decisão e conclusão

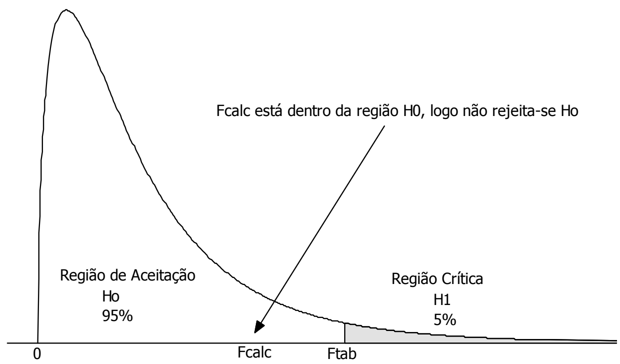

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e concluímos que não existe interação entre os fatores A e D. A interação estimada pode ser atribuída ao acaso, ou seja, não é significativa.

Slide nº 274

OBS.: Em publicações é comum a utilização do símbolo "*" para representar um efeito significativo, ou seja, quando rejeita H_0 e "ns" para um efeito não significativo, ou seja, quando não rejeita H_0.

Quando a interação é significativa temos que estudar o comportamento dos níveis de um fator dentro de cada nível do outro fator.

Este estudo é feito através de métodos de comparação de médias (para fatores qualitativos ou quantitativos com dois níveis, tais como os testes de Tukey, de Duncan, de Scheffé ou contrastes) ou através de regressão (para fatores quantitativos com mais de dois níveis).

Quando a interação não é significativa, isto é, não rejeitamos H_0: $ad_{ij} = 0$, então, testamos as hipóteses sobre os efeitos principais dos fatores A e D, como será exposto a seguir:

Slide nº 275

Teste de hipótese para o efeito do fator A

a) Estabelecer as hipóteses:

H_0: a_i = 0 (para todo e qualquer i), ou seja, as médias dos níveis do fator A não diferem.

H_1: $a_i \neq 0$ (para algum i), ou seja, as médias dos níveis do fator A diferem.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_A/QM_E$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_A;\ GL_E)$

Veja tabela F a seguir (5%)

Slide nº 276

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_A

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 277

e) Decisão e conclusão

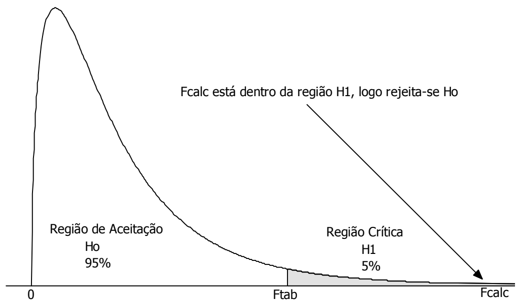

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0, em nível α de probabilidade de erro, e concluímos que há efeito (principal) do fator A. A diferença entre as médias dos níveis do fator A não pode ser atribuída ao acaso. O efeito do fator A é significativo. Se o fator A for qualitativo comparamos as médias dos níveis do fator A através de testes de comparação múltipla de médias (Tukey, Duncan, Contrastes, etc.) e se for quantitativo estudamos por regressão.

Slide nº 278

e) Decisão e conclusão

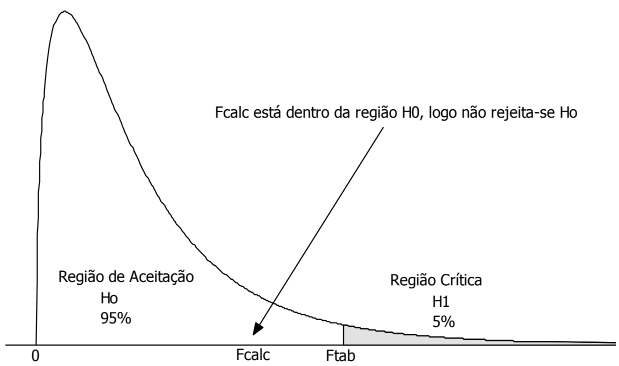

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e conclui-se que o fator A não influenciou na resposta observada. A diferença entre as médias dos níveis do fator A pode ser atribuída ao acaso. O efeito do fator A não é significativo.

Slide nº 279

Teste de hipótese para o efeito do fator D

a) Estabelecer as hipóteses:

H_0: d_j = 0 (para todo e qualquer j), ou seja, as médias dos níveis do fator D não diferem.

H_1: $d_j \neq 0$ (para algum j), ou seja, as médias dos níveis do fator D diferem.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_D/QM_E$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_D;\ GL_E)$

Veja tabela F a seguir (5%)

Slide nº 280

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_D

GL_E

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 281

e) Decisão e conclusão

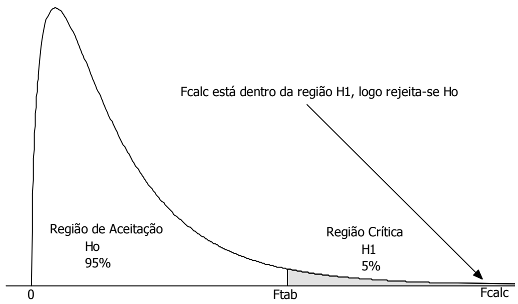

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0, em nível α de probabilidade de erro, e concluímos que há efeito (principal) do fator D. A diferença entre as médias dos níveis do fator D não pode ser atribuída ao acaso. O efeito do fator D é significativo. Se o fator D for qualitativo comparamos as médias dos níveis do fator D através de testes de comparação múltipla de médias (Tukey, Duncan, Contrastes, etc.) e se for quantitativo estudamos por regressão.

Slide nº 282

e) Decisão e conclusão

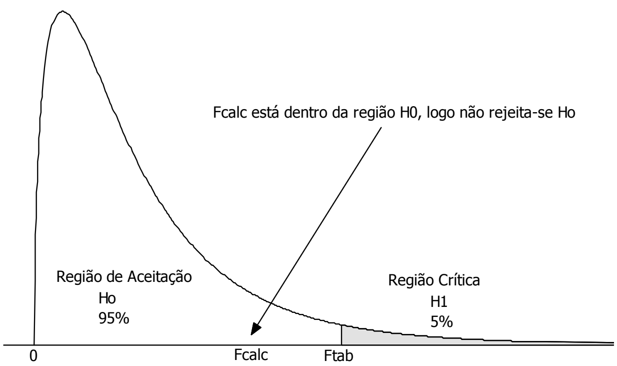

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e conclui-se que o fator D não influenciou na resposta observada. A diferença entre as médias dos níveis do fator D pode ser atribuída ao acaso. O efeito do fator D não é significativo.

Slide nº 283

Teste de hipótese para o efeito de blocos

a) Estabelecer as hipóteses:

H_0: $\sigma_b^2 = 0$ (blocos não heterogêneos).
H_1: $\sigma_b^2 \neq 0$ (blocos heterogêneos).

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_{BL}/QM_E$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_{BL};\ GL_E)$

Veja tabela F a seguir (5%)

Slide nº 284

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{BLOCO}

GL_E (m)

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 285

e) Decisão e conclusão

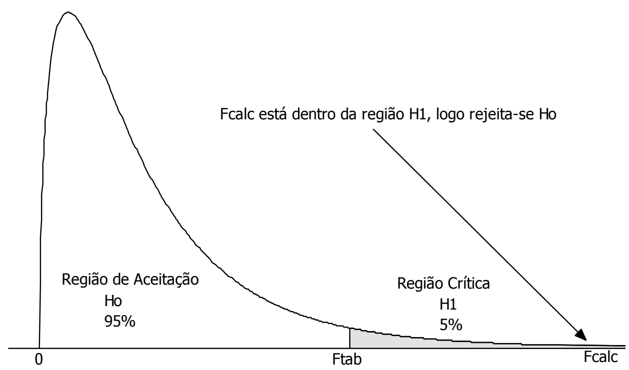

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0 e concluímos que os blocos são heterogêneos, em nível α de probabilidade de erro ou de significância, ou seja, o uso de blocos foi eficiente.

Slide nº 286

e) Decisão e conclusão

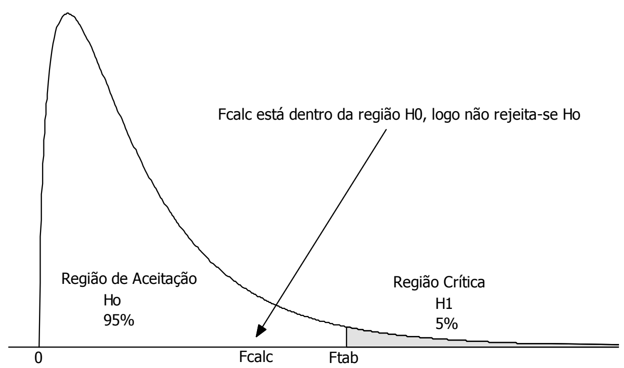

- se $F_{CALC} < F_{TAB}$, não rejeitamos H0 e concluímos que os blocos não são heterogêneos, ou seja, o uso de blocos não foi eficiente. Em próximos experimentos podemos utilizar o DIC, pois o bloqueamento não foi eficiente.

Slide nº 287

Avaliação da precisão experimental

A precisão experimental pode ser avaliada pela magnitude do erro experimental. Quanto menor o erro experimental, mais preciso é o experimento. A estatística coeficiente de variação (CV) serve para avaliar a precisão experimental.

O CV é calculado pela seguinte expressão:

$$CV = \frac{\sqrt{QME}}{\text{média}} x100$$

O autor Pimentel Gomes sugeriu a seguinte classificação da precisão experimental de acordo com o CV.

CV (%)	Classificação do CV	Classificação da Precisão Experimental
< 10	Baixo	Alta
≥ 10 e < 20	Médio	Média
≥ 20 e < 30	Alto	Baixa
≥ 30	Muito Alto	Muito Baixa

Procedimentos complementares da análise de variância

Definição dos procedimentos complementares para análise de experimentos bifatoriais nas diferentes situações de interação (H_0 = não significativa; H_1 = significativa) e para fator qualitativo ou quantitativo.

Interação	Fator A	Fator D	Procedimento
H_0	Qual.	Qual.	Fator A: Teste de F + teste de médias Fator D: Teste de F + teste de médias
H_0	Qual.	Quant.	Fator A: Teste de F + teste de médias Fator D: regressão + equação + gráfico + máxima eficiência
H_0	Quant.	Quant.	Fator A: regressão + equação + gráfico + máxima eficiência Fator D: regressão + equação + gráfico + máxima eficiência
H_1	Qual.	Qual.	Comparar médias de A dentro de D_j ou Comparar médias de D dentro de A_i
H_1	Qual.	Quant.	Regressão de D dentro de A_i com gráficos + máx.efic.
H_1	Quant.	Qual.	Regressão de A dentro de D_j com gráficos + máx.efic.
H_1	Quant.	Quant.	Superfície de resposta.

Slide nº 290

Estudo de casos:

Slide nº 291

Procedimentos complementares da análise de variância

Caso a) Caso em que os fatores A e D são qualitativos e a interação AD não é significativa.

Fator A

Se o efeito do fator A for significativo então o valor da diferença mínima significativa pelo teste de Tukey é calculado por $\Delta = q_{\alpha}(I; GL_E)\sqrt{QM_E / JK}$.

Fator D

Se o efeito do fator D for significativo então o valor da diferença mínima significativa pelo teste de Tukey é calculado por $\Delta = q_{\alpha}(J; GL_E)\sqrt{QM_E / IK}$.

Onde:

I = número de níveis do fator A

J = número de níveis do fator D

K = número de blocos ou repetições

Slide nº 292

Exercício

Prática 5

Caso a) Caso em que os fatores A e D são qualitativos e a interação AD não é significativa.

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 293

Caso b) Caso em que os fatores A e D são qualitativos e a interação AD é significativa.

Neste caso pode-se comparar as médias do fator A dentro de D_j (A/D_j) ou comparar as médias do fator D dentro de A_i (D/A_i).

Para comparar as médias do fator **A** dentro de cada nível do fator **D** (A/D_j, $\forall_j$), usando o teste de Tukey temos que calcular $\Delta = q_\alpha(I;GL_E)\sqrt{QM_E / K}$

Para comparar as médias do fator **D** dentro de cada nível do fator **A** (**D/A_i** $\forall_i$), usando o teste de Tukey temos que calcular $\Delta = q_\alpha(J;GL_E)\sqrt{QM_E / K}$

Slide nº 294

Exercício

Prática 6

Caso b) Caso em que os fatores A e D são qualitativos e a interação AD é significativa.

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 295

Caso c) Caso em que um fator é qualitativo e o outro quantitativo e a interação AD não é significativa.

Situação 1:

Fator D qualitativo
Fator A quantitativo

Slide nº 296

Fator D qualitativo

Se o efeito do fator D for significativo então o valor da diferença mínima significativa pelo teste de Tukey é calculado por $\Delta = q_{\alpha}(J; GL_E)\sqrt{QM_E / IK}$.

Onde:

I = número de níveis do fator A;

J = número de níveis do fator D;

K = número de blocos ou repetições;

Slide nº 297

Fator A quantitativo

Quando o fator A é quantitativo com mais de dois níveis aplica-se a análise da regressão que, neste caso, tem os I-1 graus de liberdade desdobrados em regressões e desvios de acordo com a Tabela 8.15.

Tabela 8.15 Tabela suplementar da análise para fator A quantitativo.

C.V.	GL	SQ	QM	F(sob H_0)
Fator **A**	I-1	SQ_A	----	------
RL	1	SQ_{RL}	QM_{RL}	QM_{RL}/QM_E
RQ	1	SQ_{RQ}	QM_{RQ}	QM_{RQ}/QM_E
RC	1	SQ_{RC}	QM_{RC}	QM_{RC}/QM_E
Desvios	I-4	SQ_{Desv}	QM_{Desv}	QM_{Desv}/QM_E
Erro	GL_E	SQ_E	QM_E	

Slide nº 298

Fator A quantitativo

Para calcular as SQ das regressões, correspondentes a Tabela 8.15, considerar as seguintes fórmulas para as somas de quadrados:

$$SQ_{RL} = \left(\sum_i C_{i1} Y_{i}..\right)^2 / JK \sum_i C_{i1}^2 \qquad SQ_{RQ} = \left(\sum_i C_{i2} Y_{i}..\right)^2 / JK \sum_i C_{i2}^2$$

$$SQ_{RC} = \left(\sum_i C_{i3} Y_{i}..\right)^2 / JK \sum_i C_{i3}^2 \qquad SQ_{Desv} = SQ_A - SQ_{RL} - SQ_{RQ} - SQ_{RC}$$

A interpretação do efeito dos graus dos polinômios são semelhantes a interpretação de experimentos com tratamentos quantitativos.

Slide nº 299

Fator A quantitativo

O modelo geral da equação é $Y = Y.../IJK + B_1M_1P_1 + B_2M_2P_2 + B_3M_3P_3 + ... + B_mM_mP_m + e$, na qual os parâmetros são obtidos pelas fórmulas a seguir: $B_1 = \left(\sum_i C_{i1}Y_i..\right) / JK\sum_i C_{i1}^2$; $B_2 = \left(\sum_i C_{i2}Y_i..\right) / JK\sum_i C_{i2}^2$; $B_3 = \left(\sum_i C_{i3}Y_i..\right) / JK\sum_i C_{i3}^2$; P_1=x; $P_2 = x^2 - \frac{I^2 - 1}{12}$; $P_3 = x^3 - x\frac{\left(3I^2 - 7\right)}{20}$, em que $x = \left(X - \overline{X}\right) / h$; C_{i1}, C_{i2}, C_{i3} são os coeficientes para interpolação de polinômios ortogonais (I níveis eqüidistantes em h unidades do fator A).

Para obter as conclusões através da regressão, deve-se estimar o coeficiente de determinação e os valores de máxima eficiência técnica e/ou econômica.

Slide nº 300

Caso c) Caso em que um fator é qualitativo e o outro quantitativo e a interação AD não é significativa.

Situação 2:

Fator A qualitativo
Fator D quantitativo

Slide nº 301

Fator A qualitativo

Se o efeito do fator A for significativo então o valor da diferença mínima significativa pelo teste de Tukey é calculado por $\Delta = q_{\alpha}(I;GL_E)\sqrt{QM_E/JK}$.

Onde:

I = número de níveis do fator A;

J = número de níveis do fator D;

K = número de blocos ou repetições;

Slide nº 302

Fator D quantitativo

Quando o fator D é quantitativo com mais de dois níveis aplica-se a análise da regressão que, neste caso, tem os J-1 graus de liberdade desdobrados em regressões e desvios de acordo com a Tabela 8.16.

Tabela 8.16 Tabela suplementar da análise para o fator **D** quantitativo

C.V.	GL	SQ	QM	F(sob H_0)
Fator **D**	J-1	SQ_D	------	--------
RL	1	SQ_{RL}	QM_{RL}	QM_{RL}/QM_E
RQ	1	SQ_{RQ}	QM_{RQ}	QM_{RQ}/QM_E
RC	1	SQ_{RC}	QM_{RC}	QM_{RC}/QM_E
Desvios	J-4	SQ_{Desv}	QM_{Desv}	QM_{Desv}/QM_E
Erro	GL_E	SQ_E	QM_E	

Slide nº 303

Fator D quantitativo

Para calcular as SQ das regressões, correspondentes a Tabela 8.16, considerar as seguintes fórmulas para as somas de quadrados:

$SQ_{RL} = \left(\sum_j C_{j1} Y_{\cdot j \cdot}\right)^2 / IK \sum_j C_{j1}^2$ $\quad$ $SQ_{RQ} = \left(\sum_j C_{j2} Y_{\cdot j \cdot}\right)^2 / IK \sum_j C_{j2}^2$

$SQ_{RC} = \left(\sum_j C_{j3} Y_{\cdot j \cdot}\right)^2 / IK \sum_j C_{j3}^2$ $\quad$ $SQ_{Desv} = SQ_D - SQ_{RL} - SQ_{RQ} - SQ_{RC}$

A interpretação do efeito dos graus dos polinômios é semelhante a interpretação de experimentos com tratamentos quantitativos.

Slide nº 304

Fator D quantitativo

O modelo geral da equação é $Y = Y\ldots/IJK + B_1M_1P_1 + B_2M_2P_2 + B_3M_3P_3 + \ldots + B_mM_mP_m + e$, na qual os parâmetros são obtidos pelas fórmulas: $B_1 = \left(\sum_j C_{j1} Y_{\cdot j \cdot}\right) / IK \sum_j C_{j1}^2$; $B_2 = \left(\sum_j C_{j2} Y_{\cdot j \cdot}\right) / IK \sum_j C_{j2}^2$; $B_3 = \left(\sum_j C_{j3} Y_{\cdot j \cdot}\right) / IK \sum_j C_{j3}^2$; P_1=x; $P_2 = x^2 - \frac{J^2 - 1}{12}$; $P_3 = x^3 - x\frac{(3J^2 - 7)}{20}$ em que $x = (X - \overline{X}) / h$; C_{j1}, C_{j2}, C_{j3} são os coeficientes para interpolação de polinômios ortogonais (I níveis eqüidistantes em h unidades do fator D).

Para obter as conclusões através da regressão, deve-se estimar o coeficiente de determinação e os valores de máxima eficiência técnica e/ou econômica.

Slide nº 305

Exercício

Prática 7

Caso c) Caso em que um fator é qualitativo e o outro quantitativo e a interação AD não é significativa.

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 306

5.3 Experimentos bifatoriais com parcelas subdivididas

Experimento bifatorial (3x4) com parcela subdividida

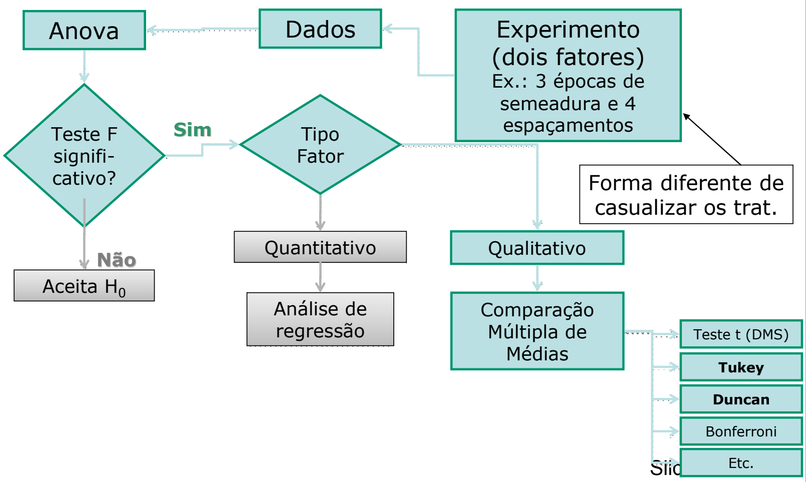

Num delineamento básico qualquer (DIC, DBA e DQL):

- Os níveis do fator A são casualizados nas parcelas principais (PP = grupo de unidades experimentais)

- Os níveis do fator D são casualizados em subdivisões das parcelas principais (SP = subparcelas = unidades experimentais).

Slide nº 310

Bifatorial 3x4, com parcelas subdivididas, no delineamento blocos ao acaso.

Fator **A** (épocas de semeadura) e Fator **D** (espaçamento)

	1	2	3	4	5	6	7	8	9	10	11	12
Bloco 1	D_3	D_1	D_4	D_2	D_2	D_3	D_1	D_4	D_4	D_2	D_3	D_1
		A_2				A_1				A_3		

	13	14	15	16	17	18	19	20	21	22	23	24
Bloco 2	D_1	D_3	D_4	D_2	D_3	D_4	D_1	D_2	D_1	D_4	D_3	D_2
		A_3				A_1				A_2		

. . .

											. . .	12K
Bloco K	D_4	D_1	D_3	D_2	D_1	D_3	D_2	D_4	D_4	D_2	D_1	D_3
		A_1				A_3				A_2		

= SP=UE; = PP

Slide nº 311

Sorteio (casualização):

- Observe que, cada bloco possui 3 parcelas principais para a casualização dos 3 níveis do fator A e cada PP tem 4 SP para a casualização dos 4 níveis do fator D.

- As parcelas principais são "blocos" (grupo de UEs uniformes) para os níveis do fator D, logo o fator D é avaliado sob (I níveis de A e de K blocos) IK repetições, o mesmo ocorrendo para a interação AxD, tendo-se maior precisão para as estimativas dos efeitos do fator D e para a interação AxD.

Slide nº 312

As principais aplicações da técnica de subdivisão de parcelas são classificadas em função das necessidades:

1) Quando o número de tratamentos (IJ) é maior que o número de UE uniformes (no caso do delineamento blocos ao acaso) e a precisão do fator A pode ser parcialmente sacrificada em benefício de uma maior precisão para o fator D e da interação AxD;

2) Quando, por razões de ordem técnica, na condução do experimento, as parcelas (UE) para avaliar os níveis do fator A necessitam de áreas maiores e, para o fator D as parcelas podem ser menores. Alguns exemplos podem ocorrer, sendo o fator A igual a "épocas de semeadura"; "uso de máquinas"; "uso de calcário"; "métodos de irrigação"; etc.;

Slide nº 313

As principais aplicações da técnica de subdivisão de parcelas são classificadas em função das necessidades:

3) Experimentos unifatoriais quando avaliados no tempo (primeira avaliação, segunda avaliação, etc. constituindo os níveis do fator D parcelas subdivididas no tempo).

Quando os níveis do fator D são constituídos por avaliações efetuadas em diferentes tempos, estes são considerados quantitativos e estudados através de regressão.

Slide nº 314

O modelo matemático para um experimento bifatorial, no delineamento blocos ao acaso, com parcelas subdivididas é definido por:

$$\mathbf{Y_{ijk} = m + b_k + a_i + (ba)_{ik} + d_j + (ad)_{ij} + e_{ijk}}$$

em que:

$\mathbf{Y_{ijk}}$ é uma observação da variável aleatória **Y**, referente à unidade experimental (subparcela no espaço) que recebeu o nível i do fator **A** na PP e o nível j do fator **D** na SP situado no k-ésimo bloco (repetição);

m é a média geral do experimento;

$\mathbf{b_k}$ é o efeito aleatório do bloco k; k= 1, 2 ... **K**;

$\mathbf{a_i}$ é o efeito (geralmente fixo) do nível i (i = 1, 2, ... , **I**) do fator **A** na PP;

$\mathbf{(ba)_{ik}}$ é o efeito aleatório da interação do bloco k com o nível i do fator A e constitui o erro experimental referente a PP ik.

$\mathbf{d_j}$ é o efeito (geralmente fixo) do nível j (j = 1, 2, ... ,J) do fator **D** (no espaço);

$\mathbf{(ad)_{ij}}$ é o efeito (geralmente fixo) da interação do nível i do fator **A** com o nível j do fator **D**;

$\mathbf{e_{ijk}}$ é o efeito aleatório do erro experimental referente a **UE** ou SP_{ijk}.

Slide nº 316

Organização dos dados para análise

Slide nº 317

Y_{ijk} i = níveis de A
J = níveis de D
K = blocos (rep)

Resultados de um experimento bifatorial no delineamento blocos ao acaso com parcelas subdivididas

Tratamento	Bloco 1	Bloco 2	. . .	Bloco K	$Y_{ij\cdot}$
A_1D_1	Y_{111}	Y_{112}	. . .	Y_{11K}	$Y_{11\cdot}$
A_1D_2	Y_{121}	Y_{122}	. . .	Y_{12K}	$Y_{12\cdot}$
. . .					
A_1D_J	Y_{1J1}	Y_{1J2}	. . .	Y_{1JK}	$Y_{1J\cdot}$
$Y_{1\cdot k}$	$Y_{1\cdot 1}$	$Y_{1\cdot 2}$	. . .	$Y_{1\cdot K}$	
A_2D_1	Y_{211}	Y_{212}	. . .	Y_{21K}	$Y_{21\cdot}$
A_2D_2	Y_{221}	Y_{222}	. . .	Y_{22K}	$Y_{22\cdot}$
. . .					
A_2D_J	Y_{2J1}	Y_{2J2}	. . .	Y_{2JK}	$Y_{2J\cdot}$
$Y_{2\cdot k}$	$Y_{2\cdot 1}$	$Y_{2\cdot 2}$	. . .	$Y_{2\cdot K}$	
A_ID_1	Y_{I11}	Y_{I12}	. . .	Y_{I1K}	$Y_{I1\cdot}$
A_ID_2	Y_{I21}	Y_{I22}	. . .	Y_{I2K}	$Y_{I2\cdot}$
. . .					
A_ID_J	Y_{IJ1}	Y_{IJ2}	. . .	Y_{IJK}	$Y_{IJ\cdot}$
$Y_{I\cdot k}$	$Y_{I\cdot 1}$	$Y_{I\cdot 2}$	. . .	$Y_{I\cdot K}$	
$Y_{\cdot\cdot k}$	$Y_{\cdot\cdot 1}$	$Y_{\cdot\cdot 2}$	. . .	$Y_{\cdot\cdot K}$	$Y_{\cdot\cdot\cdot}$

Total de tratamento ij

Total da PP

Total do bloco 1

Total do bloco k

Total geral

Slide nº 318

Totais de tratamentos e dos níveis de um experimento bifatorial AxD.

$Y_{11.}$ = Total do tratamento A_1D_1

Total do nível j do fator D

Fator D		Fator A				
		A_1	A_2	. . .	A_I	$Y_{.j.}$
	D_1	$Y_{11.}$	$Y_{21.}$	. . .	$Y_{I1.}$	$Y_{.1.}$
	D_2	$Y_{12.}$	$Y_{22.}$	. . .	$Y_{I2.}$	$Y_{.2.}$
	. . .					
	D_J	$Y_{1J.}$	$Y_{2J.}$	. . .	$Y_{IJ.}$	$Y_{.J.}$
	$Y_{i..}$	$Y_{1..}$	$Y_{2..}$	. . .	$Y_{I..}$	$Y_{...}$

Total do nível i do fator A

Total do nível 2 do fator A

Total geral

$Y_{.2.}$ = Total do nível 2 do fator D

Slide nº 319

Médias de tratamentos e dos níveis de um experimento bifatorial AxD.

Média do tratamento A_1D_1

Média do nível j do fator D

Fator D		Fator A				
		A_1	A_2	. . .	A_I	$\bar{Y}_{.j.}$
	D_1	$\bar{Y}_{11.}$	$\bar{Y}_{21.}$	. . .	$\bar{Y}_{I1}$	$\bar{Y}_{.1.}$
	D_2	$\bar{Y}_{12.}$	$\bar{Y}_{22.}$	. . .	$\bar{Y}_{I2}$	$\bar{Y}_{.2.}$
	. . .					
	D_J	$\bar{Y}_{1J.}$	$\bar{Y}_{2J.}$	. . .	$\bar{Y}_{IJ.}$	$\bar{Y}_{.J.}$
	$\bar{Y}_{i..}$	$\bar{Y}_{1..}$	$\bar{Y}_{2..}$	. . .	$\bar{Y}_{I..}$	$\bar{Y}_{...}$

Média do nível i do fator A

Média do nível 2 do fator A

Média do nível 2 do fator D

Média geral

Slide nº 320

Análise de variância (modelo fixo)

Slide nº 321

Experimento bifatorial no delineamento blocos ao acaso com parcelas subdivididas no espaço.

C.V.	GL	SQ	QM	F_{CALC}
Blocos	K-1	SQ_{BL}	QM_{BL}	$QM_{BL}/QM_{E(A)}$
A	I-1	SQ_{A}	QM_{A}	$QM_{A}/QM_{E(A)}$
Erro (A)	(K-1)(I-1)	$SQ_{E(A)}$	$QM_{E(A)}$	$QM_{E(A)}/QM_{E(D)}$
D	J-1	SQ_{D}	QM_{D}	$QM_{D}/QM_{E(D)}$
AxD	(I-1)(J-1)	SQ_{AD}	QM_{AD}	$QM_{AD}/QM_{E(D)}$
Erro (D)	I(J-1)(K-1)	$SQ_{E(D)}$	$QM_{E(D)}$	
Total	IJK-1	SQ_{Total}		

Slide nº 322

Fator de correção: $C = Y^2... / IJK$;

Soma de quadrados:

$SQ_{Total} = \sum_{ijk} Y_{ijk}^2 - C$;

$SQ_A = (1/JK)\sum_i Y_i^2.. - C$;

$SQ_{Blocos} = (1/IJ)\sum_k Y^2.._k - C$;

$SQ_{E(A)} = (1/J)\sum_{ik} Y_i^2._k - C - SQ_A - SQ_{Bloco}$;

$SQ_D = (1/IK)\sum_j Y^2._j. - C$;

$SQ_{AD} = (1/K)\sum_{ij} Y_{ij}^2. - C - SQ_A - SQ_D$;

$$SQ_{E(D)} = SQ_{Total} - SQ_{Blocos} - SQ_{E(A)} - SQ_A - SQ_D - SQ_{AD}$$

Slide nº 323

Quadrado Médio = Soma de Quadrado/Grau de Liberdade

$QM_{BL} = SQ_{BL}/GL_{BL}$

$QM_A = SQ_A/GL_A$

$QM_{E(A)} = SQ_{E(A)}/GL_{E(A)}$

$QM_D = SQ_D/GL_D$

$QM_{AD} = SQ_{AD}/GL_{AD}$

$QM_{E(D)} = SQ_{E(D)}/GL_{E(D)}$

Slide nº 324

Teste de hipótese para o efeito da interação AD

a) Estabelecer as hipóteses:

H_0: $ad_{ij} = 0$ (interação entre os fatores A e D não difere de zero, ou seja, a interação não é significativa).

H_1: $ad_{ij} \neq 0$ (a interação difere de zero, ou seja, a interação é significativa).

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_{AD}/QM_{E(D)}$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_{AD};\ GL_{E(D)})$

Veja tabela F a seguir (5%)

Slide nº 325

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_{AD}

m: $GL_{E(D)}$

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 326

e) Decisão e conclusão

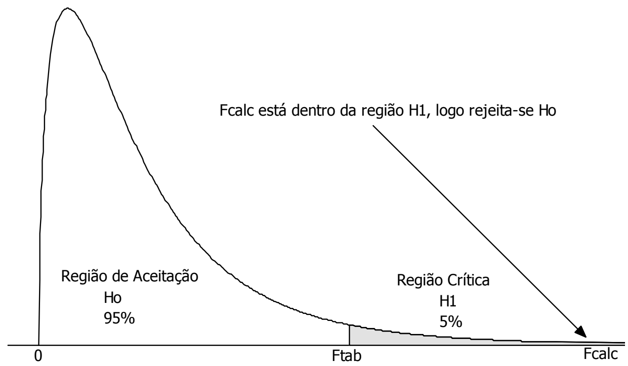

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0 e concluímos que existe interação em nível α probabilidade de erro. A interação estimada não pode ser atribuída ao acaso, ou seja, é significativa. Existe interação entre os fatores A e D.

Slide nº 327

e) Decisão e conclusão

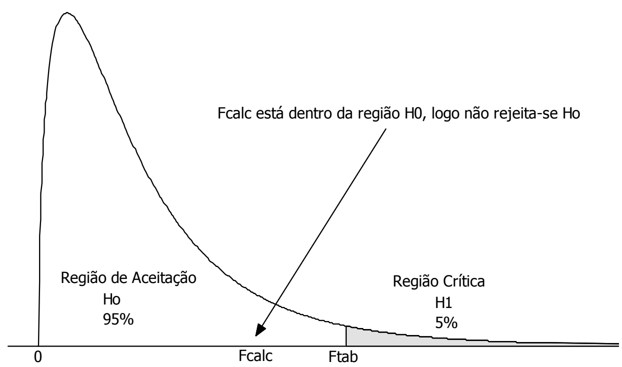

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e concluímos que não existe interação entre os fatores A e D. A interação estimada pode ser atribuída ao acaso, ou seja, não é significativa.

Slide nº 328

Quando a interação é significativa temos que estudar o comportamento dos níveis de um fator dentro de cada nível do outro fator.

Este estudo é feito através de métodos de comparação de médias (para fatores qualitativos ou quantitativos com dois níveis, tais como os testes de Tukey, de Duncan, de Scheffé ou contrastes) ou através de regressão (para fatores quantitativos com mais de dois níveis).

Quando a interação não é significativa, isto é, não rejeitamos H_0: $ad_{ij} = 0$, então, testamos as hipóteses sobre os efeitos principais dos fatores A e D, como será exposto a seguir:

Slide nº 329

Teste de hipótese para o efeito do fator A

a) Estabelecer as hipóteses:

H_0: $a_i = 0$ (para todo e qualquer i), ou seja, as médias dos níveis do fator A não diferem.

H_1: $a_i \neq 0$ (para algum i), ou seja, as médias dos níveis do fator A diferem.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_A/QM_{E(A)}$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_A;\ GL_{E(A)})$

Veja tabela F a seguir (5%)

Slide nº 330

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ GL_A

m: $GL_{E(A)}$

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 331

e) Decisão e conclusão

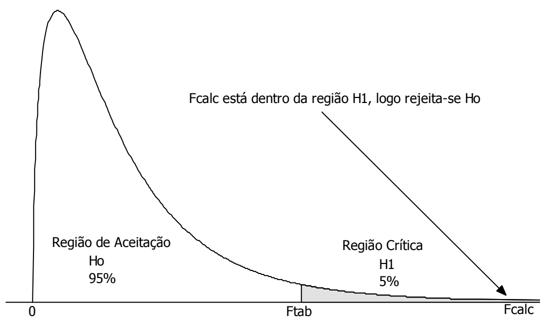

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0, em nível α de probabilidade de erro, e concluímos que há efeito (principal) do fator A. A diferença entre as médias dos níveis do fator A não pode ser atribuída ao acaso. O efeito do fator A é significativo. Se o fator A for qualitativo comparamos as médias dos níveis do fator A através de testes de comparação múltipla de médias (Tukey, Duncan, Contrastes, etc.) e se for quantitativo estudamos por regressão.

Slide nº 332

e) Decisão e conclusão

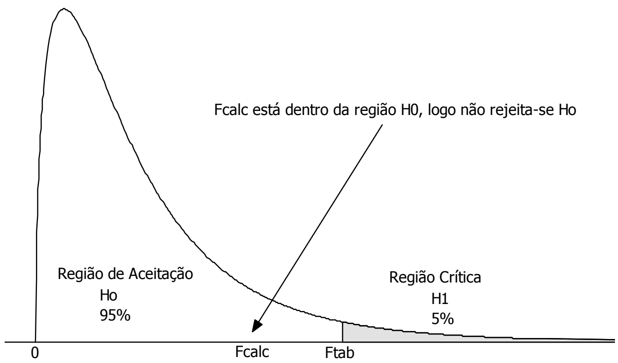

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e conclui-se que o fator A não influenciou na resposta observada. A diferença entre as médias dos níveis do fator A pode ser atribuída ao acaso. O efeito do fator A não é significativo.

Slide nº 333

Teste de hipótese para o efeito do fator D

a) Estabelecer as hipóteses:

H_0: $d_j = 0$ (para todo e qualquer j), ou seja, as médias dos níveis do fator D não diferem.

H_1: $d_j \neq 0$ (para algum j), ou seja, as médias dos níveis do fator D diferem.

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_D/QM_{E(D)}$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_D;\ GL_{E(D)})$

Veja tabela F a seguir (5%)

Slide nº 334

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador → GL_D

m → $GL_{E(D)}$

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 335

e) Decisão e conclusão

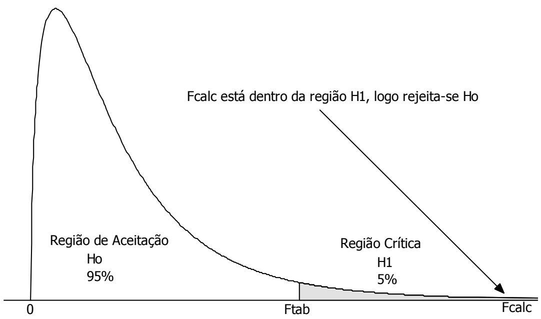

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0, em nível α de probabilidade de erro, e concluímos que há efeito (principal) do fator D. A diferença entre as médias dos níveis do fator D não pode ser atribuída ao acaso. O efeito do fator D é significativo. Se o fator D for qualitativo comparamos as médias dos níveis do fator D através de testes de comparação múltipla de médias (Tukey, Duncan, Contrastes, etc.) e se for quantitativo estudamos por regressão.

Slide nº 336

e) Decisão e conclusão

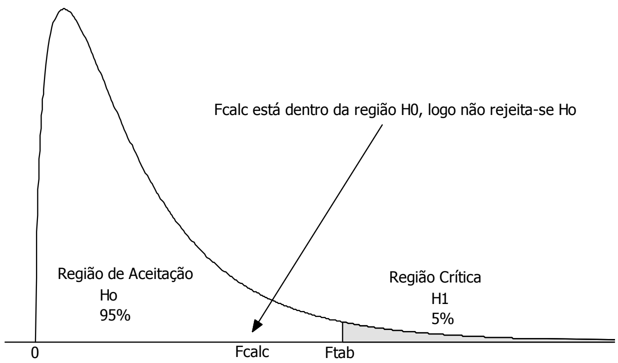

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e conclui-se que o fator D não influenciou na resposta observada. A diferença entre as médias dos níveis do fator D pode ser atribuída ao acaso. O efeito do fator D não é significativo.

Slide nº 337

Teste de hipótese para o efeito de blocos

a) Estabelecer as hipóteses:

H_0: $\sigma_b^2 = 0$ (blocos não heterogêneos).
H_1: $\sigma_b^2 \neq 0$ (blocos heterogêneos).

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_{BL}/QM_{E(A)}$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_{BL};\ GL_{E(A)})$

Veja tabela F a seguir (5%)

Slide nº 338

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador → GL_{BLOCO}

m: $GL_{E(A)}$

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 339

e) Decisão e conclusão

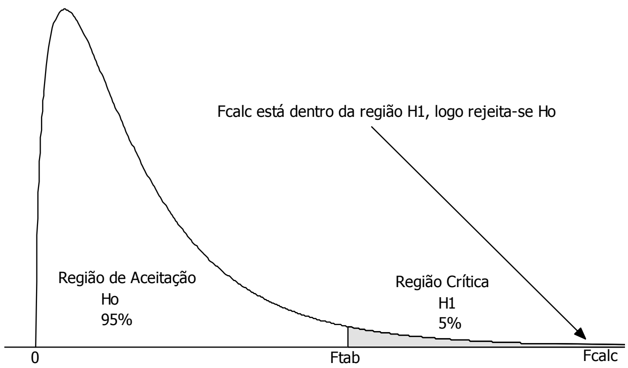

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0 e concluímos que os blocos são heterogêneos, em nível α de probabilidade de erro ou de significância, ou seja, o uso de blocos foi eficiente.

Slide nº 340

e) Decisão e conclusão

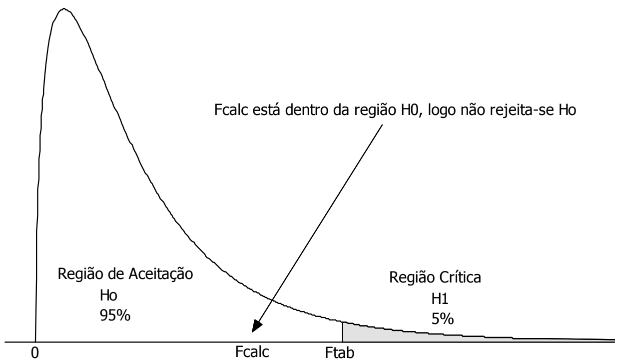

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e concluímos que os blocos não são heterogêneos, ou seja, o uso de blocos não foi eficiente. Em próximos experimentos podemos utilizar o DIC, pois o bloqueamento não foi eficiente.

Slide nº 341

Teste de hipótese para o efeito de parcelas principais

a) Estabelecer as hipóteses:

H_0: $\sigma_p^2 = 0$
H_1: $\sigma_p^2 \neq 0$

b) Estabelecer o nível de significância do teste, ou erro tipo I (α).

c) Calcular o valor da estatística F_{CALC} ➔ $F_{CALC} = QM_{E(A)}/QM_{E(D)}$

d) Ver o valor de $F_{tabelado}$ ➔ $F_{TAB} = F\alpha\ (GL_{E(A)};\ GL_{E(D)})$

Veja tabela F a seguir (5%)

Slide nº 342

Tabela **F** - Contém os valores teóricos (f) da distribuição de **F(n;m)** em que P(F>f) =5%, para **n** graus de liberdade do numerador e **m** graus de liberdade do denominador.

n = graus de liberdade do numerador ⟷ $GL_{E(A)}$

$GL_{E(D)}$

m	1	2	3	4	5	6	7	8	9	10
1	161,4	199,5	215,7	224,6	230,2	234,0	236,8	238,9	240,5	241,9
2	18,51	19,00	19,16	19,25	19,30	19,33	19,35	19,37	19,38	19,40
3	10,13	9,55	9,28	9,12	9,01	8,94	8,89	8,85	8,81	8,79
4	7,71	6,94	6,59	6,39	6,26	6,16	6,09	6,04	6,00	5,96
5	6,61	5,79	5,41	5,19	5,05	4,95	4,88	4,82	4,77	4,74
6	5,99	5,14	4,76	4,53	4,39	4,28	4,21	4,15	4,10	4,06
7	5,59	4,74	4,35	4,12	3,97	3,87	3,79	3,73	3,68	3,64
8	5,32	4,46	4,07	3,84	3,69	3,58	3,50	3,44	3,39	3,35
9	5,12	4,26	3,86	3,63	3,48	3,37	3,29	3,23	3,18	3,14
10	4,96	4,10	3,71	3,48	3,33	3,22	3,14	3,07	3,02	2,98
11	4,84	3,98	3,59	3,36	3,20	3,09	3,01	2,95	2,90	2,85
12	4,75	3,89	3,49	3,26	3,11	3,00	2,91	2,85	2,80	2,75
13	4,67	3,81	3,41	3,18	3,03	2,92	2,83	2,77	2,71	2,67
14	4,60	3,74	3,34	3,11	2,96	2,85	2,76	2,70	2,65	2,60
15	4,54	3,68	3,29	3,06	2,90	2,79	2,71	2,64	2,59	2,54
16	4,49	3,63	3,24	3,01	2,85	2,74	2,66	2,59	2,54	2,49
17	4,45	3,59	3,20	2,96	2,81	2,70	2,61	2,55	2,49	2,45
18	4,41	3,55	3,16	2,93	2,77	2,66	2,58	2,51	2,46	2,41
19	4,38	3,52	3,13	2,90	2,74	2,63	2,54	2,48	2,42	2,38
20	4,35	3,49	3,10	2,87	2,71	2,60	2,51	2,45	2,39	2,35
21	4,32	3,47	3,07	2,84	2,68	2,57	2,49	2,42	2,37	2,32
22	4,30	3,44	3,05	2,82	2,66	2,55	2,46	2,40	2,34	2,30
23	4,28	3,42	3,03	2,80	2,64	2,53	2,44	2,37	2,32	2,27
24	4,26	3,40	3,01	2,78	2,62	2,51	2,42	2,36	2,30	2,25
25	4,24	3,39	2,99	2,76	2,60	2,49	2,40	2,34	2,28	2,24
26	4,23	3,37	2,98	2,74	2,59	2,47	2,39	2,32	2,27	2,22
27	4,21	3,35	2,96	2,73	2,57	2,46	2,37	2,31	2,25	2,20
28	4,20	3,34	2,95	2,71	2,56	2,45	2,36	2,29	2,24	2,19
29	4,18	3,33	2,93	2,70	2,55	2,43	2,35	2,28	2,22	2,18
30	4,17	3,32	2,92	2,69	2,53	2,42	2,33	2,27	2,21	2,16

Slide nº 343

e) Decisão e conclusão

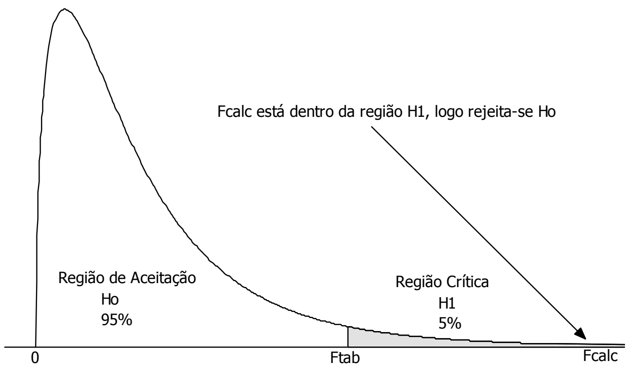

- se $F_{CALC} \geq F_{TAB}$, rejeitamos H_0 e conclui-se que a variância das PP é maior do que a variância das SP e que o uso das PP foi adequado para o experimento.

Slide nº 344

e) Decisão e conclusão

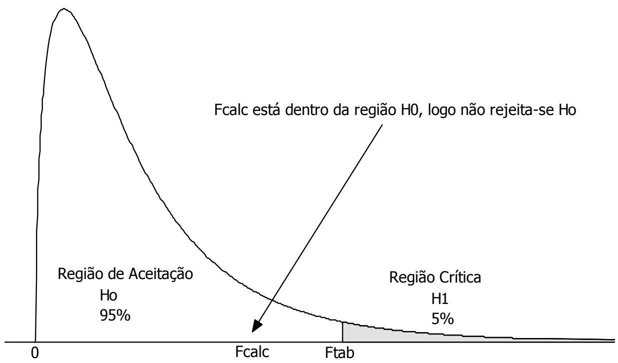

- se $F_{CALC} < F_{TAB}$, não rejeitamos H_0 e conclui-se que a variância das PP não é maior do que a variância das SP e que o uso das PP não foi adequado para o experimento.

Slide nº 345

Avaliação da precisão experimental

O coeficiente de variação referente aos níveis do fator **A** é obtido por

$$\mathbf{CV}(A) = 100x\sqrt{QM_{E(A)}}\ /\ \text{média}$$

O coeficiente de variação referente aos níveis do fator **D** e da interação **AD** é:

$$\mathbf{CV}(D)=100x\sqrt{QM_{E(D)}}\ /\ \text{média}$$

Em geral, a estimativa **CV**(A) é maior que **CV**(D).

O autor Pimentel Gomes sugeriu a seguinte classificação da precisão experimental de acordo com o CV.

CV (%)	Classificação do CV	Classificação da Precisão Experimental
< 10	Baixo	Alta
≥ 10 e < 20	Médio	Média
≥ 20 e < 30	Alto	Baixa
≥ 30	Muito Alto	Muito Baixa

Slide nº 346

Procedimentos complementares da análise de variância

Slide nº 347

Fator qualitativo: Teste Tukey

a) Comparação de médias dos níveis do fator **A**: $\Delta = q_{\alpha(I;GLE(A))}\sqrt{QM_{E(A)} / JK}$

b) Comparação de médias dos níveis do fator **D**: $\Delta = q_{\alpha(J;GLE(D))}\sqrt{QM_{E(D)} / IK}$

c) Comparação de médias dos níveis do fator **D** dentro do mesmo nível do fator **A**:

$$\Delta = q_{\alpha(J;GLE(D))}\sqrt{QM_{E(D)} / K}$$

d) Comparação de médias dos níveis do fator **A** dentro do mesmo nível do fator **D** -

$\Delta = q_{\alpha(I;n)}\sqrt{QM_E}$

em que QM_E = $\{(J\text{-}1)QM_{E(D)} + QM_{E(A)}\}/JK$ com **n** graus de liberdade obtidos pela fórmula de Satterthwaite como sendo

$n = \{(J\text{-}1)QM_{E(D)}+QM_{E(A)}\}^2 / \{(J\text{-}1)^2QM_{E(D)}{}^2 /GL_{E(D)}+QM_{E(A)}{}^2/GL_{E(A)}\}$.

Slide nº 348

Interpretação para fator(es) quantitativo(s)

Comparado com o caso de parcelas não subdivididas temos apenas que considerar, aqui, o erro adequado para os testes de hipóteses das regressões. Assim: as regressões para o fator **A** são testadas com relação ao $QM_{E(A)}$; as regressões do fator **D** são testadas com relação ao $QM_{E(D)}$; e as regressões do fator **D** dentro de cada nível do fator **A** (aplicado aos casos em que a interação é significativa e o fator **A** é qualitativo e **D** é quantitativo) são testados com relação ao $QM_{E(D)}$.

Slide nº 349

Exercício

Prática 8
Experimentos bifatoriais com parcela subdividida

Caso a) Caso em que os fatores A e D são qualitativos e a interação AD não é significativa.

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 350

Exercício

Prática 9
Experimentos bifatoriais com parcela subdividida

Caso b) Caso em que os fatores A e D são qualitativos e a interação AD é significativa.

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 351

6 Análise Conjunta de Experimentos

6.1 Introdução

Um experimento executado em um determinado local e ano permite obter conclusões válidas apenas para as condições em que foi executado.

Em termos de amostragem, é uma amostra tirada num só estrato e tem validade restrita para fins de recomendação das tecnologias avaliadas.

A repetição de um experimento em vários locais num mesmo ano, ou em vários anos num mesmo local, resulta num grupo de experimentos.

A análise dos resultados deste grupo de experimentos, denominada análise conjunta, permite conclusões mais confiáveis e com conhecimento da abrangência das recomendações.

Slide nº 354

A análise conjunta se torna mais fácil se o grupo de experimentos possui os mesmos tratamentos, o mesmo número de repetições e o mesmo delineamento experimental.

Além disso, se for realizado em diferentes locais é conveniente que estes sejam semelhantes quanto ao clima, solo, etc, representando a região na qual se quer aplicar os resultados dos tratamentos que estão sendo avaliados.

Slide nº 355

Exemplos de grupos de experimentos para uma análise conjunta:

- Experimento de 6 cultivares de soja no delineamento blocos ao acaso, 5 repetições, conduzido em 18 locais do Rio Grande do Sul.

- Experimento bifatorial (Manejo x Cultivares) no delineamento inteiramente ao acaso, 6 repetições, em 12 locais da região Alto Uruguai do Rio Grande do Sul.

- Experimento de 15 cultivares de milho no delineamento inteiramente casualizado, 5 repetições, conduzido durante 4 anos no Departamento de Fitotecnia da UFSM.

Slide nº 356

6.2 Procedimentos de análise e interpretação de experimentos

Modelo matemático:

Considerando tanto os locais quanto os anos como sendo simplesmente ambientes, o modelo matemático para experimentos unifatoriais, em vários ambientes (locais e/ou anos), no delineamento blocos ao acaso é:

$Y_{ijk} = m + b_{k(j)} + \alpha_i + \tau_j + \lambda_{ij} + e_{ijk}$,

Y_{ijk} = observação do tratamento i (i=1,2,...,I) no ambiente j (j=1,2,...J) no bloco k (k=1,2,...,K);

m = constante; $b_{k(j)}$ = efeito aleatório do bloco k no ambiente

α_i = efeito fixo do tratamento i

τ_j = efeito aleatório do ambiente j

λ_{ij} = efeito aleatório da interação entre o tratamento i com o ambiente j

e_{ijk} = erro experimental

Slide nº 358

Análise de variância conjunta

C.V.	GL	SQ	QM
Bloco/Amb	$GL_{B/A}$	$SQ_{B/A}$	$QM_{B/A}$
Trat.(T)	GL_T	SQ_T	QM_T
Amb.(A)	GL_A	SQ_A	QM_A
T x A	GL_{TA}	SQ_{TA}	QM_{TA}
Erro Médio	GL_{EM}	SQ_{EM}	QM_{EM}

Slide nº 359

Pressuposição da análise de variância conjunta:

- É pressuposto que as variâncias dos erros experimentais nos diferentes experimentos sejam homogêneas, isto é, que todos QMe sejam estimadores de uma mesma variância s^2.

- Esta pressuposição deve ser testada e atendida antes de se proceder a análise conjunta. Para isto, pode-se aplicar os testes de Bartlett, Hartley, F máximo.

- O teste de F é o mais simples e consiste em dividir o maior QMe pelo menor QMe (Fc= >QMe / <QMe). Se o Fc calculado for maior que F tabelado, conclui-se que os erros são heterogêneos.

Regra prática: se Fc= >QMe / <QMe for menor que 7 pode-se fazer a análise conjunta.

Slide nº 360

- No caso de ocorrer heterogeneidade dos erros, convém separar os experimentos em dois ou mais grupos, de tal forma que os erros dentro de cada grupo sejam homogêneos, pelo mesmo teste, e calcular a análise conjunta para cada grupo de forma independente.

- Pode-se também, utilizar uma análise ponderada que não será abordada nesse texto.

Slide nº 361

Os cálculos dos graus de liberdade e das somas de quadrados são obtidos, com a análise de cada experimento.

C.V.	GL	SQ	QM
Bloco/Amb	$GL_{B/A}$	$SQ_{B/A}$	$QM_{B/A}$
Trat.(T)	GL_T	SQ_T	QM_T
Amb.(A)	GL_A	SQ_A	QM_A
T x A	GL_{TA}	SQ_{TA}	QM_{TA}
Erro Médio	GL_{EM}	SQ_{EM}	QM_{EM}

Experimento	GL_bloco	SQ_bloco	GL_erro	SQ_erro	QM_erro
1	GLB_1	SQB_1	GLE_1	SQE_1	QME_1
2	GLB_2	SQB_2	GLE_2	SQE_2	QME_2
. . .					
J	GLB_J	SQB_J	GLE_J	SQE_J	QME_J
Soma	$GL_{B/A}$	$SQ_{B/A}$	GL_{EM}	SQ_{EM}	(F máx.)

Slide nº 362

Montamos uma tabela auxiliar com os totais de tratamentos em cada ambiente, ou seja os valores Yij.

Trat.(i)	Ambiente (j) 1	2	3	. . .	J	Total $Y_{i..}$
1	$Y_{11.}$	$Y_{12.}$	$Y_{13.}$		$Y_{1J.}$	$Y_{1..}$
2	$Y_{21.}$	$Y_{22.}$	$Y_{23.}$		$Y_{2J.}$	$Y_{2..}$
. . .						
I	$Y_{I1.}$	$Y_{I2.}$	$Y_{I3.}$		$Y_{IJ.}$	$Y_{I..}$
Total $Y_{.j.}$	$Y_{.1.}$	$Y_{.2.}$	$Y_{.3.}$	. . .	$Y_{.J.}$	$Y_{...}$

C.V.	GL	SQ	QM
Bloco/Amb	$GL_{B/A}$	$SQ_{B/A}$	$QM_{B/A}$
Trat.(T)	GL_T	SQ_T	QM_T
Amb.(A)	GL_A	SQ_A	QM_A
T x A	GL_{TA}	SQ_{TA}	QM_{TA}
Erro Médio	GL_{EM}	SQ_{EM}	QM_{EM}

$GL_T=(I-1)$; $GL_A=(J-1)$; $GL_{TA}=(I-1)(J-1)$; e $C=Y_{...}^2/IJK$; $SQT = \frac{1}{JK}\sum_i Y_{i..}^2 - C$;

$SQA = \frac{1}{IK}\sum_j Y_{.j.}^2 - C$; e $SQTA = \frac{1}{K}\sum_{ij} Y_{ij.}^2 - C - SQT - SQA$

K = número de blocos

Slide nº 363

Testes de hipóteses (interpretação da análise de variância)

Slide nº 364

Interpretação para efeito de blocos

Quando o delineamento for em blocos ao acaso pode-se, embora não se tenha muito interesse, testar o efeito de blocos. O teste é sobre a existência ou não de homogeneidade entre os blocos dentro dos ambientes. A hipótese nula é $H_0:\sigma_b^2=0$ (blocos não heterogêneos) vs. $H_1:\sigma_b^2>0$ (blocos heterogêneos). A hipótese H_0 será rejeitada em nivel α de erro, se $Fc = QM_B/QM_{EM}$ for ≥ do que $F_{\alpha(GLB;GLEM)}$.

Slide nº 365

Interpretação para a interação Tratamentos x Ambientes

Hipótese de nulidade: $H_0:\sigma_\lambda^2=0$ e a hipótese alternativa $H_1:\sigma_\lambda^2>0$. Rejeita-se H_0 se $Fc = QM_{TA}/QM_{EM}$ for ≥ do que $F_{\alpha(GLTA;GLEM)}$, em nível α de erro.

Quando se faz análise conjunta de experimentos não é interessante rejeitar esta hipótese pois, ao rejeitar esta hipótese, concluímos que o comportamento dos tratamentos não é o mesmo nos diferentes ambientes. Isto é o contrário do objetivo da análise conjunta da qual queremos obter conclusões, para um grupo de tratamentos, em condições bem mais generalizadas.

Quando a interação for significativa (rejeitar H_0) deve-se proceder o estudo desta interação por outras técnicas de análise denominadas de "análise de estabilidade" ou "análises de agrupamento".

Slide nº 366

Interpretação para o efeito de Ambientes

Delineamento blocos ao acaso:

H_0:σ_τ^2=0 vs H_1:σ_τ^2>0, pode ser testada pela estatística $Fc=(QM_A+QM_{EM})/(QM_{TA}+QM_B)$. Rejeita-se H_0 em nível α de erro, se Fc for ≥ do que $F_{\alpha(n1;n2)}$ onde: $n1=(QM_A+QM_{EM})^2/(QM_A^2/GL_A+QM_{EM}^2/GL_{EM})$ e $n2=(QM_{TA}+QM_B)^2/(QM_{TA}^2/GL_{TA}+QM_B^2/GL_B)$.

No entanto, se cada experimento for conduzido no delineamento inteiramente casualizado então, vamos rejeitar H_0 se $Fc=QM_A/QM_{TA}$ for ≥ do que $F_{\alpha(GLA;GLTA)}$.

Slide nº 367

Interpretação do efeito de tratamentos

Quando a interação não é significativa, independente da variância dos ambientes, pode-se testar hipóteses sobre os efeitos de tratamentos. Vamos supor que os tratamentos são de efeito fixo e qualitativos, então, a hipótese a ser testada e H_0:α_i=0, $\forall$i vs. H_1:$\alpha_i \neq 0$, para algum i. Rejeita-se H_0 se $Fc=QM_T/QM_{TA}$ for ≥ do que $F_{\alpha(GLT;GLTA)}$ e compara-se as médias dos tratamentos, por exemplo, pelo procedimento de Tukey, calculando a diferença mínima significativa por: $\Delta = q_{\alpha(I;GLTA)}.\{QMTA/JK\}^{1/2}$.

Quando os tratamentos são quantitativos estuda-se o comportamento dos tratamentos por análise de regressão, cuja equação ajustada será válida para os ambientes avaliados.

Slide nº 368

Exercício

Prática 10

Análise conjunta de experimentos

Gabarito disponível em:

www.ufsm.br/cargnelutti

Slide nº 369

7 Controle de qualidade e planejamento de experimentos

O planejamento de um experimento visa determinar com antecedência "como vai ser o experimento" e "como serão analisados os dados" e, o controle de qualidade orienta o pesquisador e o estatístico sobre os cuidados no planejamento, execução e análise dos resultados do experimento para manter o erro experimental em nível aceitável.

7.1 Controle de qualidade de experimentos

A qualidade de um experimento pode ser avaliada pela **magnitude do erro experimental (QME)**. Sabe-se que o erro experimental é inevitável, no entanto, se forem conhecidas suas causas (origens), podemos contorná-las e mantê-lo em níveis aceitáveis. Além disso, deve-se avaliar a qualidade da análise do experimento verificando se as **pressuposições do modelo estão sendo satisfeitas**.

7.1.1 - Considerações sobre o erro experimental

O "erro experimental" consiste na variação não controlada pelo pesquisador e ocorre, de forma aleatória, entre as unidades experimentais (UE) que receberam os mesmos tratamentos. Assim, a variância entre unidades experimentais que recebem o mesmo tratamento é uma estimativa do erro experimental (QME).

Em princípio, se o experimento for executado no delineamento inteiramente casualizado, todas as unidades experimentais são homogêneas, ou, se o experimento for executado no delineamento blocos ao acaso, existem grupos de UE homogêneas (blocos). No entanto, pequenas variações, de toda natureza, existentes nas UE, antes de se aplicar os tratamentos ou induzidas (involuntariamente) durante a execução do experimento, em maior ou menor grau, tornam as mesmas heterogêneas. Esta heterogeneidade também é conhecida como variação casual, variação ambiental ou, simplesmente, erro.

7.1.2 - Importância do erro experimental na análise dos experimentos

- Teste de hipótese: Exemplo: para o efeito de tratamento:
$Fcalc = QM_{Trat}/QM_E$

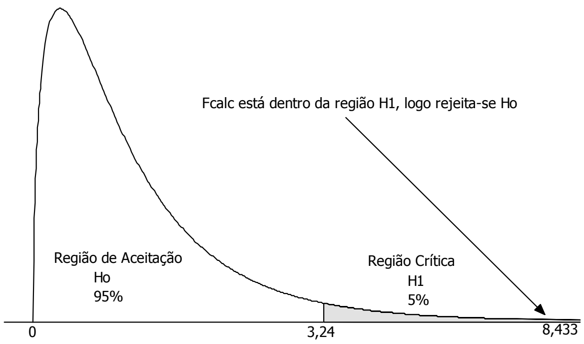

Permanecendo fixo o QMtrat quanto menor o valor do QME maior o valor de Fcalc e mais fácil de rejeitar H_0.

- Testes de comparações múltiplas de médias:

Exemplo: Tukey $\Delta = q_{\alpha(I;GLE)}\sqrt{QM_E / J}$

Quanto maior o QME maior é o Δ e maiores diferenças entre médias serão necessárias para serem consideradas significativas.

7.1.3 - Avaliação do erro experimental

A magnitude do erro experimental pode ser avaliada pelo:

A - Coeficiente de variação ➔ $CV(\%) = 100\sqrt{QM_E} / \hat{m}$

em que, $\hat{m}$=média geral do experimento.

Quanto maior o CV menor é a precisão do experimento e menor é a qualidade do experimento.

Gomes (1985), para ensaios agrícolas de avaliação da produtividade de grãos, apresenta a seguinte classificação para os coeficientes de variação:

Classes de CV	Limites do CV	Precisão
Baixos	$\leq$ 10%	Alta
Médios	10 - 20%	Média
Altos	20 - 30%	Baixa
Muito Altos	$\geq$ 30%	Muito Baixa

B - coeficiente de precisão ➔ CP = 100 $\sqrt{QME/J}\,/\,\hat{m}$.

Considera as repetições J.

Quanto menor o CP, mais preciso ou de maior qualidade é o experimento.

C - Diferença mínima significativa ➔ $DMS(\%) = 100 * q_{\alpha(I;GLE)} \sqrt{QM_E / J} / \hat{m}$

É o valor do delta tukey em percentagem da média (Lúcio, 1997).

Quanto menor o DMS (%) mais preciso é o experimento.

Há outras estatísticas que vem sendo publicadas recentemente com propriedades importantes na classificação dos experimentos.

CARGNELUTTI FILHO, Alberto e STORCK, Lindolfo. Estatísticas de avaliação da precisão experimental em ensaios de cultivares de milho. **Pesquisa Agropecuária Brasileira**, v.42, n.1, p.17-24, 2007.

CARGNELUTTI FILHO, Alberto e STORCK, Lindolfo. Medidas do grau de precisão experimental em ensaios de competição de cultivares de milho **Pesquisa Agropecuária Brasileira**, v.44, n.2, p.111-117, 2009.

7.1.4 - Tipos de erros em experimentos

a) *Erro aleatório ou erro experimental* é a variação entre as UE com o mesmo tratamento. Neste caso, um determinado tratamento ora é favorecido, ora é prejudicado por fatores naturais e/ou induzidos, durante a execução do experimento. Este erro, que não incide sempre no mesmo tratamento e que não pode ser eliminado completamente, mas apenas reduzido ou minimizado, é reconhecido pelo modelo matemático do delineamento. Este tipo de erro repercute na magnitude do QM_E e por conseqüência nas estatísticas F, testes de comparações de médias, CV, CP, DMS, etc.

b) *Erro sistemático* é o erro onde um determinado tratamento é favorecido (ou prejudicado) em todas as suas repetições. Neste caso, este erro é somado ao efeito de tratamento e altera o QM_{Trat}, a estatística F e as conclusões sobre os efeitos ou diferenças entre as médias de tratamentos. É um erro que tem suas origens, normalmente, em descuidos do experimentador. Exemplos: - Erro no cálculo dos tratamentos (nas doses, por exemplo); - Aplicação de defensivos onde cada um é aplicado com pulverizador diferente, havendo um deles mais eficiente favorecerá o tratamento pulverizado com aquela máquina.

7.1.5 - Principais fontes de erro e respectivos cuidados

1) Heterogeneidade das unidades experimentais

Quando as UE são áreas de campo (parcelas), a heterogeneidade é devida a uma soma de fatores, tais como: variação na fertilidade do solo, drenagem, nivelamento, decomposição de restos de culturas de anos anteriores, plantas daninhas, textura e estrutura do solo, etc., além de variações introduzidas durante o preparo ou manejo do solo.

Para amenizar estas variações, o pesquisador precisa conhecer a variabilidade entre as UE desta área experimental, usando resultados de anos anteriores ou executando um experimento em branco (ensaio de uniformidade, sem tratamentos) para tal fim. O principal método de contornar a heterogeneidade é o de adequar a área experimental escolhida ao delineamento experimental, tamanho e forma de parcela, número de repetições e número de tratamentos com a precisão requerida para o experimento.

2) Heterogeneidade do material experimental

Denomina-se de material experimental, o material que compõe os tratamentos, como, por exemplo, as mudas das diferentes espécies que serão avaliadas, as sementes, os adubos, etc. Quando esse material não é homogêneo então, certa quantidade deste, numa UE, não representa (por amostragem) esta mesma quantidade em outra UE do mesmo tratamento e, com isto aumenta-se o erro aleatório.

Quando possível, deve-se homogeneizar o material experimental. Exemplos: misturar bem o adubo que será usado para fertilizar as UE, misturar bem o solo que será colocado nos vasos, usar mudas oriundas da mesma planta mãe para experimentos com plantas arbóreas, usar sementes híbridas ou utilizar parcelas maiores (equivale a usar amostras maiores nas UE), usar cultivares de menor variabilidade genética quanto à sucetibilidade às pragas e/ou doenças.

3) Tratos culturais

São os procedimentos rotineiros pertinentes ao desenvolvimento da cultura como, por exemplo: capinas, controle de pragas e doenças, adubação, etc. Quando estas atividades não são feitas uniformemente, aumenta-se erro experimental.

No delineamento inteiramente casualizado, os tratos culturais devem ser realizados num mesmo dia (ou menos) de modo uniforme em todas as UE do experimento. Se o delineamento for em blocos ao acaso, então, os tratos culturais devem seguir a ordem deste controle local (um bloco depois de outro, ou um bloco para cada operador).

4) Competição intraparcelar

Quando se verificam falhas de plantas dentro da UE, devido à ocorrência de pragas, acidentes, etc., as plantas próximas a esta falha competem entre si (por luz, água, nutrientes, etc.) e apresentam crescimento e/ou desenvolvimento diferenciado se comparados com outras plantas situadas em UE onde não ocorreram falhas e não houve a competição. Muitas vezes, ocorre uma compensação nas plantas vizinhas, no entanto, nunca se sabe qual seria o valor observado na UE caso não houvesse perdas de plantas. Assim, a média observada na UE fica prejudicada quando há falha(s) de plantas. Por isto, temos uma fonte de erro experimental pois estas falhas não são iguais em todas as repetições de cada tratamento.

Neste caso, para reduzir o erro experimental deve-se, quando possível, aumentar a densidade de semeadura e fazer um posterior desbaste para deixar todas as UE com o mesmo número de plantas, usar mudas reservas (plantio em separado) para eventuais substituições ou replantios, etc. Ao fazer um desbaste, entretanto, deve-se escolher ao acaso as plântulas a serem eliminadas e não eliminar as menos desenvolvidas, pois se estaria distorcendo a realidade, principalmente se o desbaste não for feito com a mesma intensidade em todas as parcelas.

5) Competição interparcelar

Quando os tratamentos são muito diferentes entre si, como por exemplo: doses de adubos, espécies ou cultivares de diferentes estaturas ou diferentes ciclos de desenvolvimento, aplicação de fertilizantes, etc, ocorre competição entre as plantas das parcelas vizinhas. Ao competir com as plantas das UE vizinhas por luz, água, nutrientes, etc., um certo tratamento pode ora ser prejudicado ora ser favorecido, dependendo dos tratamentos existentes nas UE vizinhas e com isto aumentar o erro experimental. No caso da aplicação de defensivos, o produto aplicado numa parcela pode, por deriva, atingir a parte lateral da parcela vizinha, causando problema semelhante. Seja um experimento com doses de NPK = 0, 100, 200 e 300 kg/ha e sejam dois blocos com a distribuição dos tratamentos nas UE, feitas por sorteio:

300	0	200	100

Bloco I

200	300	100	0

Bloco II

Observe que, no bloco I o tratamento "0" foi bastante favorecido e no bloco II ele foi um pouco ou nada favorecido. Assim, no bloco I o tratamento "0" foi favorecido porque as plantas vizinhas puderam "roubar" adubo das UE dos dois lados (que foram bem adubadas), pois o adubo pode percolar lateralmente e as raízes também se deslocam mais para o lado adubado. O mesmo não acontece no bloco II e, com isto, o tratamento "0", sendo ora favorecido e ora prejudicado aumenta o erro experimental.

Como solução, nos casos em que ocorrer competição interparcelar deve-se planejar UE maiores e colher (avaliar) apenas a área central, chamada de área útil, desprezando-se as bordaduras ou áreas vizinhas. Veja um exemplo de UE com área útil e bordadura na Figura 7.2. É importante considerar que, se o pesquisador coletar os dados de toda a UE, o que implica em não usar bordadura, então o tamanho da UE pode ser menor e, com isto, o número de repetições numa dada área pode ser maior o que resulta numa maior precisão do experimento.

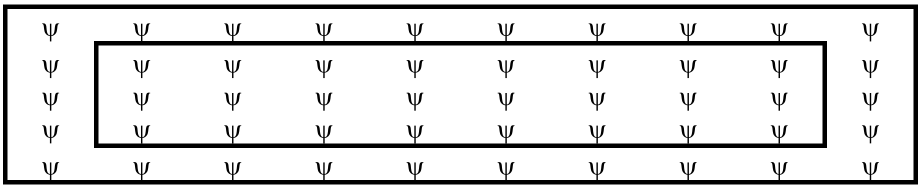

Figura 4. Esquema de uma UE com destaque da área total e a útil.

6) Pragas, doenças e plantas daninhas

Pragas, doenças e plantas daninhas ocorrem, geralmente, de modo localizado (em manchas ou colônias). Assim, devem-se manter os experimentos livres de doenças, plantas daninhas e pragas executando os devidos controles de forma preventiva (desde que estes não sejam o objetivo do experimento).

7) Amostragem na parcela

Na avaliação de um experimento, normalmente, medimos todo o material para uma variável em cada UE (ex: medimos a altura de todas as plantas e calculamos a média para representar o valor da UE). Muitas vezes, dependendo da variável e da quantidade do material (tamanho da UE), não é possível avaliar toda a UE. Nestes casos, tomamos uma amostra (parte representativa da UE) a qual, se não for homogênea e representativa provoca um aumento do erro experimental.

7.2 Planejamento de experimentos

O planejamento do experimento é um procedimento que visa auxiliar o pesquisador no desenvolvimento de um projeto de pesquisa, no qual se faz necessário a execução de experimentos. A experimentação se preocupa com a elaboração do projeto de experimento porque faz parte da pesquisa experimental.

O projeto de pesquisa é um documento que, em geral, tem os itens que se seguem: Título; Autor(es); Introdução (colocação do problema, sua importância e objetivos da pesquisa); Revisão bibliográfica; Material e métodos (contém todas as informações sobre como vai ser a pesquisa para alcançar os objetivos propostos); Cronograma físico de atividades; Orçamento; e Bibliografia consultada.

O projeto de experimento é um maior detalhamento dos itens **Material e Métodos** e **Cronograma de atividades** do projeto de pesquisa. Num projeto de pesquisa, nem sempre, a metodologia pode ser prevista e escrita de forma completa, pois, o desenvolvimento de uma etapa pode depender dos resultados obtidos em etapas anteriores e, com isto, alterar alguns tópicos do próximo experimento. Assim, ao planejar um experimento, segue-se uma linha de raciocínio determinando-se os elementos que vão compor o experimento. Como resultado, obtém-se um documento chamado de "Projeto de Experimento" com, aproximadamente, os seguintes itens:

1. Título ...
2. Vinculação com a pesquisa ...
3. Objetivos do experimento ...
4. Relação dos tratamentos ...
5. Croqui (desenho) do experimento ...
6. Modelo de "caderno de campo" ...
7. Variáveis a serem observadas ...
8. Cronograma de atividades ...
9. Condições gerais do experimento ...
10. Análise dos resultados ...

O projeto, com os itens acima, deve ser simples e suficientemente claro para que, na falta de quem o planejou, outro pesquisador possa executá-lo, analisá-lo e obter conclusões.

Uma prática recomendada é manter cópias do documento (projeto de experimento) em lugares seguros evitando-se, assim, eventuais perdas por acidentes.

A seguir, descrevem-se, com mais detalhes, os itens do projeto de experimento, citados anteriormente.

1. Título

O título do experimento deve indicar com precisão a natureza do experimento, ser claro e conciso, facilitando a comunicação entre os pesquisadores, técnicos e operários. Pode ser do tipo que reflete a natureza dos tratamentos. Este título não necessariamente será o mesmo usado para a publicação dos resultados nem aquele do projeto de pesquisa ao qual está vinculado. Exemplos de títulos podem ser: Progênies de Pinus; Adubação em erva-mate; Cobertura de sementeiras; Cultivares de soja; Rações em suínos; Épocas de semeadura de soja; Hidroponia em alface; Tomate em estufa; etc.

2. Vinculação com a pesquisa

Relacionar o nome do projeto de pesquisa (e seu número na instituição) a que o experimento está vinculado. Este item é necessário quando o pesquisador desenvolve mais de um projeto de pesquisa ou o faz em Instituições que possuem vários projetos de pesquisa, para evitar falhas na identificação do experimento. Coordenador do projeto e participantes.

3. Objetivos do experimento

Os objetivos do experimento devem ser claros e, sendo amplos, deve-se subdividi-los em ordem de prioridade. São exemplos de objetivos, os que seguem:

- Verificar o comportamento de progênies de Pinus em Santa Maria;
- Conhecer a melhor fórmula de adubação NPK para a erva-mate;
- Identificar a melhor solução nutritiva para cultivos em hidroponia;
- Verificar qual é o melhor método de cobertura de sementeiras de alface;
- Comparar o rendimento do cultivar "padrão" com os demais cultivares de soja disponíveis no mercado;
- Reconhecer o desempenho dos herbicidas para a cultura da soja;
- Testar o efeito de vários produtos na composição de ração de suínos;
- Verificar o comportamento fenológico de cultivares de soja.

Os objetivos devem ser suficientemente completos para que, a partir deles, seja possível determinar adequadamente os tratamentos que deverão compor o experimento.

4. Relação dos tratamentos

A relação dos tratamentos é decorrente dos objetivos. Deve-se evitar incluir tratamentos sem a devida justificativa. Quando possível deve-se incluir um tratamento testemunha ou padrão, o qual servirá de referência para as conclusões. No caso de tratamentos quantitativos deve-se, de preferência, usar valores eqüidistantes cuja amplitude de variação reflete a realidade. A eqüidistância entre os tratamentos quantitativos facilitará a análise da regressão e é mais adequado para os casos em que se faz a procura do melhor modelo matemático para os dados observados.

5. Croqui do experimento

É um desenho (planta baixa) do experimento, identificando o local, as dimensões, as unidades experimentais (UE) e a ordem (aleatória) de aplicação dos tratamentos sobre as UE obtida por sorteio de acordo com o delineamento. Para obter um croqui, segue-se os seguintes passos:

a) Definir o tipo de UE, a qual depende da natureza dos tratamentos;

b) Determinar o tamanho e a forma das UE;

c) Verificar a homogeneidade entre as UE;

d) Escolher o delineamento experimental mais adequado, em função da homogeneidade entre as UE e natureza dos tratamentos;

e) Calcular o número de repetições necessárias para uma dada precisão;

f) Adequar a área experimental disponível com o número de UE, resultante do produto do "número de tratamentos" pelo "número de repetições" e pela área de cada UE;

g) Desenhar as UE, distribuídas no espaço, usando pontos de referência; e,

h) Fazer o sorteio dos tratamentos sobre as UE, de acordo com o delineamento escolhido.

Na Figura 7.3, apresenta-se um exemplo de croqui de um experimento com 8 tratamentos no delineamento blocos ao acaso com três repetições. A UE é constituída de uma área de 4 por 10m (desenho está fora de escala) o que resulta em blocos de 10 por 32m.

6. Modelo de "caderno de campo"

Denominamos de "caderno de campo" (CC) uma ficha elaborada a partir do croqui do experimento cuja finalidade é a de anotar os dados sobre os efeitos dos tratamentos. O efeito dos tratamentos é avaliado através das variáveis medidas no experimento, também chamadas variáveis resposta, que na análise estatística constituem as variáveis dependentes enquanto os tratamentos constituem a variável independente. A caderneta de campo deve conter os seguintes itens:

- Identificação do experimento (nome, localização e ano de execução do experimento);
- Relação das UE e respectivos tratamentos, controle local e variáveis observadas; e,
- Um espaço para anotações gerais, como data da semeadura, emergência e colheita, datas de ocorrência de chuva, de aplicação de irrigação, de capinas, avaliações, enfim, qualquer observação que possa ser útil para auxiliar na discussão dos resultados do experimento.

Na Tabela 1 apresenta-se um modelo de CC, correspondente ao exemplo da Figura 5.

------------------------------ 32m --

Bloco 1 10m	1 T3	2 T2	3 T1	4 T6	5 T8	6 T4	7 T7	8 T5
								--- 4m --
Bloco 2	9 T6	10 T8	11 T1	12 T2	13 T7	14 T3	15 T5	16 T4
Bloco 3	17 T5	18 T2	19 T7	20 T8	21 T6	22 T3	23 T1	24 T4

Estação Meteorológica da UFSM

Norte ↑

Experimento "tal" →

Figura 5. Modelo de croqui de um experimento.

Tabela 1. Modelo de caderno de campo para o experimento “Cultivares de milho doce”; Departamento de Fitotecnia/UFSM.

N° da UE	Bloco	Tratamento	Peso	Altura	etc.
1	1	3			
2	1	2			
3	1	1			
4	1	6			
5	1	8			
6	1	4			
7	1	7			
8	1	5			
9	2	6			
10	2	8			
...	...	...			
24	3	4			
Data(s)			Atividades		
.. /.. /2009	...	...	...	...	...
.. /.. /2009	...	...	...	...	...
...		...			

7. Variáveis a serem observadas

Neste item são descritas as variáveis que serão analisadas assim como a época e o modo de realização da coleta de informações. As variáveis devem refletir o efeito dos tratamentos que estão sendo comparados. Em geral, anota-se um grande número de variáveis. Por exemplo , quando o experimento compara diferentes tipos de inseticidas para controlar insetos em sementeiras, a variável mais importante possivelmente seja "o número de insetos por unidade experimental, após a aplicação dos inseticidas" contudo, as demais variáveis, como, por exemplo, altura, diâmetro e área foliar das mudas, percentagem de pega no transplante, desenvolvimento inicial no campo, produtividade, etc, podem ser influenciadas pelo "número de insetos", devendo, também, serem analisadas.

8. Cronograma de atividades

Faz-se uma lista com as principais atividades (etapas) da execução do experimento com as respectivas datas. A implantação de experimentos, principalmente os de campo, deve coincidir com a época adequada para a cultura na região considerada. Um exemplo, resumido, de cronograma de atividades poderia ser o apresentado na Tabela 2.

Tabela 2. Cronograma de atividades do experimento “Identificação”.

Data / Período	Descrição da Atividade
01 a 06 / 2007	- Preparo das mudas
06 / 2007	- Preparo do solo, adubação e demarcação
07 / 2007	- Aplicação dos tratamentos
12 / 2007	- Capina e tratamento fitossanitário
...	. . .
07 / 2008	- Avaliação final da massa seca
08 a 10 / 2008	- Análise e interpretação

9. Condições gerais do experimento

Neste item, são descritas todas as particularidades não citadas nos itens anteriores de tal forma que seja possível uma repetição do experimento nas mesmas condições "gerais". O termo "geral" se aplica devido à impossibilidade de se repetir as mesmas condições meteorológicas sob as quais um experimento é executado.

Alguns aspectos que podem ser relacionados são: caracterização da unidade experimental; tipo de solo; análise do solo; tratos culturais; manejo; clima; máquinas a serem usadas; mão-de-obra; etc.

10. Análise dos resultados

Escrever o modelo matemático, identificando os seus componentes e pressuposições, com o respectivo esquema geral de análise (quadro da análise de variância com "causas de variação e graus de liberdade") e a análise complementar: contrastes ou comparações de médias; análise de regressão e estimativa de máxima eficiência técnica, sempre de acordo com o delineamento experimental e os tipos de tratamentos.

Após a execução do experimento e da análise estatística do mesmo, deve-se organizar um relatório. Este relatório é composto pelos mesmos itens do projeto do experimento (mudando-se o tempo dos verbos para o passado) e acrescentando-se, em tabelas, os resultados obtidos e as respectivas análises estatísticas e conclusões, bem como, toda e qualquer observação (chuvas, irrigações, adubações, tratos culturais em geral, etc.) feita durante a execução do experimento. Este relatório servirá de subsídio para a análise e conclusão global do projeto de pesquisa, ao qual o experimento está vinculado.

7.3 Qualidade na análise de experimentos

Entende-se que, a análise dos resultados de um experimento é de boa qualidade se as pressuposições do modelo matemático estão sendo satisfeitas.

Estas pressuposições para o delineamento inteiramente casualizado, cujo modelo é $Y_{ij} = m + t_i + e_{ij}$, são:

- Homogeneidade entre as variâncias;
- Normalidade dos erros;
- Aleatoriedade dos erros (independência);
- Aditividade dos efeitos do modelo matemático.

Quando as pressuposições enumeradas não são satisfeitas, a análise paramétrica via: teste de F; comparações de médias pelos testes de Tukey, Duncan e outros; teste de modelos de regressão; etc., fica prejudicada e pode levar a falsas conclusões.

Solução:

1) Transformação de dados.
2) Análise não-paramétrica (teste de Sperman, teste de Friedman, teste de Kruskal-Wallis, etc.).

Transformação dos Dados

Na transformação, a nova variável (Y_{ij}^*) é uma função da variável Y_{ij} observada: Todas as análises (de variância, comparações múltiplas de médias, etc.) e as conclusões são feitas usando-se a variável transformada Y_{ij}^* . No entanto, a apresentação dos resultados para publicação é feita com os dados (médias) na escala original.

Os casos mais comuns de dados que requerem transformação são classificados de acordo com o tipo (função) de transformação. Assim, temos, por exemplo:

a) **Transformação "Raiz Quadrada**"

A transformação é $Y_{ij}^{*} = \sqrt{Y_{ij}}$, para todo o ij. Nos experimentos em que existirem valores nulos ou próximos de zero a transformação sofre uma correção para $Y_{ij}^{*} = \sqrt{Y_{ij} + 0{,}5}$, para todo ij. Esta transformação é usada quando as observações Y_{ij} seguem, aproximadamente, a distribuição de Poisson. Isto acontece quando se têm dados de contagem com valores relativamente baixos, digamos menores que 50. Neste caso, Y_{ij}^{*} deve seguir, aproximadamente, a distribuição normal. Alguns exemplos de casos em que esta transformação pode ser aplicada são:

- Dados de contagem, como, por exemplo: número de bactérias por placa, número de insetos por planta, número de plantas daninhas por m^2 de parcela, número de sementes viáveis por metro quadrado, etc.
- Dados percentuais, quando todos os Y_{ij} estão compreendidos entre 0% e 20% ou quando todos os Y_{ij} estão entre 80% e 100%, como por exemplo: percentagem de frutos podres por caixa, percentagem de folhas doentes; percentagem de insetos mortos; etc.

b) **Transformação logarítmica**

A transformação é $Y_{ij}^{*} = \log_{10}(Y_{ij})$ ou, quando alguma UE tem valor zero ou próximo de zero, então $Y_{ij}^{*} = \log_{10}(Y_{ij} + 1)$.

É necessária, com freqüência, quando se utilizam tratamentos testemunhas, ou seja: Testemunha não capinada, testemunha onde não houve aplicação de defensivos, etc. que terão, muitas vezes, médias bem diferentes dos demais tratamentos e, conseqüentemente, variâncias bem diferentes.

c) **Transformação arcoseno**

A transformação é $Y_{ij}^{*} = \text{arcsen}\sqrt{Y_{ij}}$, é usada nos casos em que Y_{ij} é uma proporção (entre 0 e 1) e segue distribuição binomial com número N de observações comuns para todas as UE (dados em percentual). Exemplos: proporção de frutos maduros, proporção de frutos danificados, proporção de insetos mortos.

Não se aplica esta transformação a qualquer variável medida em percentagem como, por exemplo, percentagem de proteína nas sementes e sim, apenas a dados de contagem provenientes de variável aleatória discreta que apresentem distribuição binomial. A transformação arcoseno normaliza a distribuição dos dados com distribuição binomial.

8 Referências

FONSECA, J. S.; MARTINS, G. A. **Curso de estatística**. 3. ed. São Paulo: Atlas, 1992.

GOMES, F. P. **Curso de estatística experimental**. 13. ed. Piracicaba: Nobel, 1990.

RAMALHO, M. A. P. et al. **Experimentação em genética e melhoramento de plantas**. Lavras: UFLA, 2000.

STORCK, L. et al. **Experimentação vegetal**. 2. ed. Santa Maria: UFSM, 2006. 198 p.

VENCOVSKY, R.; BARRIGA, P. **Genética biométrica no fitomelhoramento**. Ribeirão Preto: Revista Brasileira de Genética, 1992.