

ANOVA

Modelos de Efeitos Fixos e Aleatórios

Modelos mais Gerais

(Neter et al. 2005; Oehlert, 2010)

Diferentes estruturas para os componente “FIXOS” e “ALEATÓRIOS” do modelo adotado para Y:

$$Y = E[Y|X] + [Y - E(Y|X)]$$

componente fixo do modelo componente aleatório do modelo

Modelo com Dois Fatores Aleatórios


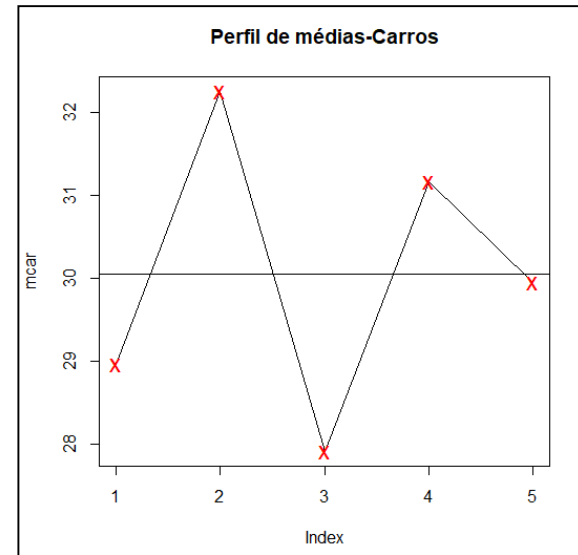

Consumo de Gasolina de acordo com carros e motoristas amostrados aleatoriamente de uma indústria automobilística

Fator B:		Fator A: Carros				
Motoristas	$j = 1$	$j = 2$	$j = 3$	$j = 4$	$j = 5$	
$i = 1$	25.3	28.9	24.8	28.4	27.1	
	25.2	30.0	25.1	27.9	26.6	
$i = 2$	33.6	36.7	31.7	35.6	33.7	
	32.9	36.5	31.9	35.0	33.9	
$i = 3$	27.7	30.7	26.9	29.7	29.2	
	28.5	30.4	26.3	30.2	28.9	
$i = 4$	29.2	32.4	27.7	31.8	30.3	
	29.3	32.4	28.9	30.7	29.9	

Os fatores Carros e Motoristas são aleatórios.

A resposta sob estudo é o consumo de combustível.

Modelo com Dois Fatores Aleatórios



Componentes da variabilidade de Y devido ao efeito (aleatório) principal de cada fator bem como de sua interação.

Modelo com Dois Fatores Aleatórios

Componente
fixo

Componente
aleatório

$$y_{ijk} = \mu_{jk} + e_{ijk} = \underbrace{\mu}_{\text{Componente fixo}} + \underbrace{\tau_j + \beta_k + \gamma_{jk} + e_{ijk}}_{\text{Componente aleatório}}; \quad i = 1, \dots, n_{jk}; j = 1, \dots, a; k = 1, \dots, b$$

$$\tau_j \sim N(0; \sigma_A^2); \quad \beta_k \sim N(0; \sigma_B^2); \quad \gamma_{jk} \sim N(0; \sigma_{AB}^2);$$

$$e_{ijk} \sim N(0; \sigma_e^2); \quad \tau_j \perp \beta_k \perp \gamma_{jk} \perp e_{ijk}$$

$$y_{ijk} \sim N\left(\mu; \sigma_A^2 + \sigma_B^2 + \sigma_{AB}^2 + \sigma_e^2\right)$$

$$\text{Cov}(y_{ijk}; y_{i'j'k'}) = \begin{cases} \sigma_A^2 + \sigma_B^2 + \sigma_{AB}^2 + \sigma_e^2 & i = i'; j = j'; k = k' \\ \sigma_A^2 + \sigma_B^2 + \sigma_{AB}^2 & i \neq i'; j = j'; k = k' \\ \sigma_A^2 & i \neq i'; j = j'; k \neq k' \\ \sigma_B^2 & i \neq i'; j \neq j'; k = k' \\ 0 & i \neq i'; j \neq j'; k \neq k' \end{cases}$$

Modelos Lineares de Efeitos Aleatórios

ANOVA para Delineamentos com Dois Fatores, A e B, Aleatórios

FV	#g.l.	E(QM)
A	$a - 1$	$\sigma_e^2 + r\sigma_{AB}^2 + rb\sigma_A^2$
B	$b - 1$	$\sigma_e^2 + r\sigma_{AB}^2 + ra\sigma_B^2$
AB	$(a - 1)(b - 1)$	$\sigma_e^2 + r\sigma_{AB}^2$
Resíduo	$n - ab = ab(r - 1)$	σ_e^2

Estrutura
Fatorial dos
efeitos
aleatórios

r: réplicas n=abr

Neter et al., 2005

$$H_0 : \sigma_{AB}^2 = 0 \Rightarrow F_{AB} = \frac{QM(AB)}{QM \text{ Res}} \sim F_{(a-1)(b-1), ab(r-1)}$$

$$H_0 : \sigma_A^2 = 0 \Rightarrow F_A = \frac{QMA}{QM(AB)} \sim F_{(a-1), (a-1)(b-1)}$$

$$H_0 : \sigma_B^2 = 0 \Rightarrow F_B = \frac{QMB}{QM(AB)} \sim F_{(b-1), (a-1)(b-1)}$$

Tabela de ANOVA equivalente ao modelo de efeitos Fixos, exceto o E(QM).

Não há uma ordem para a realização dos testes dos components de variância!

Modelo com Dois Fatores Aleatórios

Estimadores dos Componentes de Variância

$$\sigma_A^2 = \frac{E(QMA) - E(QMAB)}{rb} \Rightarrow \hat{\sigma}_A^2 = \frac{QMA - QMAB}{rb}$$

$$\sigma_B^2 = \frac{E(QMB) - E(QMAB)}{ra} \Rightarrow \hat{\sigma}_B^2 = \frac{QMB - QMAB}{ra}$$

$$\sigma_{AB}^2 = \frac{E(QMAB) - E(QM Res)}{r} \Rightarrow \hat{\sigma}_{AB}^2 = \frac{QMAB - QM Res}{r}$$

$$\sigma_e^2 = E(QM Res) \Rightarrow \hat{\sigma}_e^2 = QM Res$$

Intervalos de Confiança aproximados para Componentes de Variância em modelos balanceados podem ser obtidos por meio do procedimento de Satterthwaite que identifica os estimadores desses CV como combinações lineares de Quadrados Médios.

Modelo com 2 Fatores Aleatórios

Estimador da Média Geral

$$\hat{\mu} = \bar{y}_{...}$$



$$\begin{aligned} \text{Var}(\hat{\mu}) &= \text{Var}\left(\frac{\sum_{ijk} y_{ijk}}{rab}\right) = \frac{rb\sigma_A^2 + ra\sigma_B^2 + r\sigma_{AB}^2 + \sigma_e^2}{rab} \\ &= \frac{E(QMA) + E(QMB) - E(QMAB)}{rab} \end{aligned}$$

$$\hat{\text{Var}}(\hat{\mu}) = \frac{QMA + QMB - QMAB}{rab}$$

Modelo com Dois Fatores Aleatórios

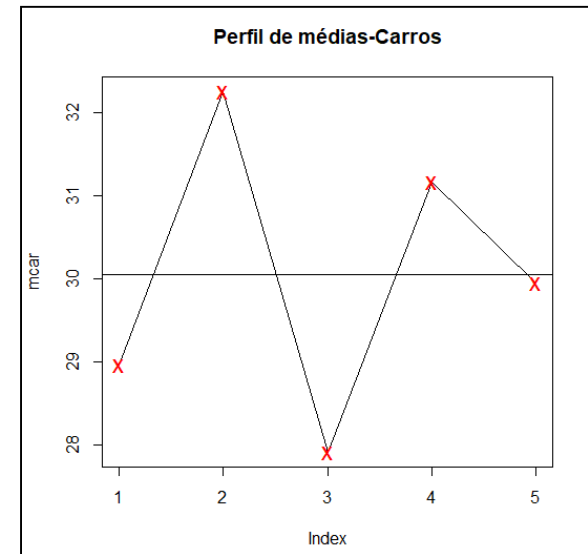
Motoristas	Fator A: Carros				
	$j=1$	$j=2$	$j=3$	$j=4$	$j=5$
$i=1$	25.3	28.9	24.8	28.4	27.1
$i=2$	25.2	30.0	25.1	27.9	26.6
$i=3$	33.6	36.7	31.7	35.6	33.7
$i=4$	32.9	36.5	31.9	35.0	33.9
$i=3$	27.7	30.7	26.9	29.7	29.2
$i=4$	28.5	30.4	26.3	30.2	28.9
$i=4$	29.2	32.4	27.7	31.8	30.3
	29.3	32.4	28.9	30.7	29.9

$$\sigma_{AB}^2 \leftarrow$$



$$\Rightarrow \sigma_B^2$$

$$\sigma_A^2 \leftarrow$$



Fator B: Motoristas	Fator A: Carros				
	$j=1$	$j=2$	$j=3$	$j=4$	$j=5$
$i=1$	25.3	28.9	24.8	28.4	27.1
	25.2	30.0	25.1	27.9	26.6
$i=2$	33.6	36.7	31.7	35.6	33.7
	32.9	36.5	31.9	35.0	33.9
$i=3$	27.7	30.7	26.9	29.7	29.2
	28.5	30.4	26.3	30.2	28.9
$i=4$	29.2	32.4	27.7	31.8	30.3
	29.3	32.4	28.9	30.7	29.9

Modelo com Dois Fatores Aleatórios

$r=2, a=5, b=4$
 $n=40$

Tabela de ANOVA: Modelo com 2 Fatores Aleatórios

	Df	Sum Sq	Mean Sq	F value
Carros (A: aleatório)	4	94.713	23.678	$23.678/0.204=116.07$
Motorista (B: aleatório)	3	280.285	93.428	$93.428/0.204=457.98$
Carros*Motorista	12	2.446	0.204	$0.204/0.176=1.159$
Residuals	20	3.515	0.176	

Significância dos Componentes de variância (CV)

CV	Estimativa	vapor-p	valor-p ajustado.fdr
Fator A	2.934	$1.745695e-09$	$5.237085e-09^*$
Fator B	9.322	$1.226574e-12$	$3.679723e-12^*$
Fator AB	0.014	$3.714839e-01$	$1.000000e+00$

Rejeitar $\sigma_A^2 = 0$
Rejeitar $\sigma_B^2 = 0$
Não Rejeitar $\sigma_{AB}^2 = 0$

$$\hat{\mu} = 30.05 \quad dp(\hat{\mu}) = 1.7096$$

Modelo com Três Fatores Aleatórios

Quadrado Médio Esperado

Source	<i>EMS</i>
A	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2 + nc\sigma_{\alpha\beta}^2 + nb\sigma_{\alpha\gamma}^2 + nbc\sigma_{\alpha}^2$
B	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2 + nc\sigma_{\alpha\beta}^2 + na\sigma_{\beta\gamma}^2 + nac\sigma_{\beta}^2$
C	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2 + nb\sigma_{\alpha\gamma}^2 + na\sigma_{\beta\gamma}^2 + nab\sigma_{\gamma}^2$
AB	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2 + nc\sigma_{\alpha\beta}^2$
AC	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2 + nb\sigma_{\alpha\gamma}^2$
BC	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2 + na\sigma_{\beta\gamma}^2$
ABC	$\sigma^2 + n\sigma_{\alpha\beta\gamma}^2$
Error	σ^2

Há **Testes F exatos** para testar os efeitos aleatórios ABC, AB, AC e BC. MAS não há testes exatos para testar os Efeitos Principais A, B e C. **Testes aproximados** precisam ser obtidos no caso de modelos com 3 ou mais fatores aleatórios.

Modelo Misto: Um Fator Fixo e Um Fator Aleatório

A eficiência de três Métodos de Ensino (I, II e III) foi avaliada por meio do desempenho do aluno. Cinco instrutores habilitados a conduzir tais Métodos foram aleatoriamente escolhidos de um cadastro para fazerem parte do estudo. Quinze grupos de quatro alunos considerados homogêneos segundo o conhecimento do assunto foram então

Método de Ensino	I				II				III			
Instr. 1	65	68	56	45	74	69	52	73	69	63	81	67
Instr. 2	58	62	65	56	81	76	56	78	83	70	72	79
Instr. 3	63	75	58	54	76	80	62	83	74	72	73	73
Instr. 4	57	64	70	48	80	78	58	75	78	68	76	77
Instr. 5	66	70	64	60	68	73	51	76	80	75	70	71

Considere a análise destes dados: há diferença no desempenho esperados dos alunos de acordo com os três Métodos de Ensino?

Método de Ensino deve ser modelado como Fator Fixo ou Aleatório? E Instrutor?

Proponha outras situações experimentais em que um modelo misto desse tipo seria útil.

Modelo Misto

Componente
fixo

Componente
aleatório

$$y_{ijk} = \mu_{jk} + e_{ijk} = \mu + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad i = 1, \dots, n_{jk}; j = 1, \dots, a; k = 1, \dots, b$$

$$\sum_{j=1}^a \tau_j = 0; \quad \beta_k \sim N(0; \sigma_B^2);$$

Formulação restrita do modelo misto

$$\gamma_{jk} \sim N\left(0; \frac{a-1}{a} \sigma_{AB}^2\right); \quad \sum_{j=1}^a \gamma_{jk} = 0; \quad \text{Cov}(\gamma_{jk}; \gamma_{j'k}) = -\frac{1}{a} \sigma_{AB}^2 \quad j \neq j'$$

$$e_{ijk} \sim N(0; \sigma_e^2); \quad \beta_k \perp \gamma_{jk} \perp e_{ijk}$$

$$y_{ijk} \sim N\left(\mu + \tau_i; \sigma_B^2 + \frac{a-1}{a} \sigma_{AB}^2 + \sigma_e^2\right)$$

$$\text{Cov}(y_{ijk}; y_{i'j'k'}) =$$

$$\begin{cases} \sigma_B^2 + \frac{a-1}{a} \sigma_{AB}^2 + \sigma_e^2 & i = i' \\ \sigma_B^2 + \frac{a-1}{a} \sigma_{AB}^2 & i \neq i', j = j'; k = k' \\ \sigma_B^2 - \frac{1}{a} \sigma_{AB}^2 & i \neq i', j \neq j'; k = k' \\ 0 & k \neq k' \end{cases}$$

Modelos Lineares Mistos

Delineamentos com Dois Fatores Cruzados AxB: A de Efeito Fixo e B de Efeito Aleatório

FV	#g.l.	E(QM)
A	$a - 1$	$\sigma_e^2 + rb \frac{\sum_j \tau_j^2}{a - 1} + r\sigma_{AB}^2$
B	$b - 1$	$\sigma_e^2 + ra\sigma_B^2$
AB	$(a - 1)(b - 1)$	$\sigma_e^2 + r\sigma_{AB}^2$
Resíduo	$n - ab = ab(r - 1)$	σ_e^2

Neter et al., 2005

SQ, QM e número de g.l. são calculados como no caso de um modelo ANOVA de efeitos fixos. O denominador da estatística F mudará de acordo com o valor esperado do QM, isto é, E(QM).

Modelo Linear Misto

Tabela de ANOVA - Modelo Misto

	Df	Sum Sq	Mean Sq	F value
Método (A:Fixo)	2	1695.63	847.82	FA: 847.82/27.75=30.55 <0.001*
Instrutor (B:Aleatório)	4	190.57	47.64	FB: 47.64/66.50= 0.72 0.5851
Método*Instrutor (AB:Aleat)	8	222.03	27.75	FAB: 27.75/66.50=0.42 0.9045
Residuals	45	2992.50	66.50	

$$H_{0AB} : \sigma_{AB}^2 = 0 \Rightarrow F_{AB} = \frac{QM(AB)}{QM Res} \sim F_{8,45}$$

Método de Ensino e Instrutor não interagem

$$H_{0B} : \sigma_B^2 = 0 \Rightarrow F_B = \frac{QM(B)}{QM Res} \sim F_{4,45}$$

A variabilidade entre instrutores não é significativa

$$H_{0A} : \tau_j = 0 \Rightarrow F_A = \frac{QM(A)}{QM(AB)} \sim F_{2,4}$$

Há (pelo menos uma) diferença significativa entre o desempenho esperado dos alunos de acordo com Método de Ensino

Modelo Linear Misto

$$y_{ijk} = \mu_{jk} + e_{ijk} = \mu + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad i = 1, \dots, r; j = 1, \dots, a; k = 1, \dots, b$$

$$\mu_j \quad \sum_{j=1}^a \tau_j = 0$$

$$\hat{\mu} = \bar{y}_{...} \quad \hat{\tau}_j = \hat{\mu}_j - \hat{\mu} = \bar{y}_{.j.} - \bar{y}_{...}$$

$$\text{Var}(\hat{\tau}_j) = \frac{\sigma_e^2 + r\sigma_{AB}^2}{br} = \frac{E(QMAB)}{br} \Rightarrow \hat{\text{Var}}(\hat{\tau}_j) = \frac{QMAB}{br}$$

$$H_0 : \tau_j = 0; \quad \frac{\hat{\tau}_j}{\sqrt{\hat{\text{Var}}(\hat{\tau}_j)}} \sim t_{(a-1)(b-1)}$$

Modelo Linear Misto

$$y_{ijk} = \mu_{jk} + e_{ijk} = \mu + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad \sigma_B^2; \quad \sigma_{AB}^2; \quad \sigma_e^2$$

$$\sigma_B^2 = \frac{E(QMB) - E(QM \text{ Res})}{ra} \Rightarrow \hat{\sigma}_B^2 = \frac{QMB - QM \text{ Res}}{ra}$$

$$\sigma_{AB}^2 = \frac{E(QMAB) - E(QM \text{ Res})}{r} \Rightarrow \hat{\sigma}_{AB}^2 = \frac{QMAB - QM \text{ Res}}{r}$$

$$\sigma_e^2 = E(QM \text{ Res}) \Rightarrow \hat{\sigma}_e^2 = QM \text{ Res}$$

Intervalos de Confiança aproximados para Componentes de Variância em modelos balanceados podem ser obtidos por meio do procedimento de Satterthwaite que identifica os estimadores desses CV como combinações lineares de Quadrados Médios.

Modelo Linear Misto

Tabela de ANOVA - Modelo Misto

	Df	Sum Sq	Mean Sq	F value
Método (A:Fixo)	2	1695.63	847.82	FA: 847.82/27.75=30.55 <0.001*
Instrutor (B:Aleatório)	4	190.57	47.64	FB: 47.64/66.50= 0.72 0.5851
Método*Instrutor (AB:Aleat)	8	222.03	27.75	FAB: 27.75/66.50=0.42 0.9045
Residuals	45	2992.50	66.50	

Médias por Método de Ensino

	1	2	3	
	61.20	70.95	73.55	68.57


$$\hat{\tau}_j = \bar{y}_{.j} - \bar{y}_{...}$$

$$\hat{\tau}_1 = -7,37 \quad t_1 = -6,26$$

$$\hat{\tau}_2 = -7,37 \quad t_2 = 2,02$$

$$\hat{\tau}_3 = -7,37 \quad t_3 = 4,22$$

$$\hat{Var}(\hat{\tau}_j) = \frac{27.75}{5*4} = 1,388$$



Valor-p ajustado	1	2	3
Bonferroni	0.0007343535	0.2330218528	0.0086255918
FDR	0.0007343535	0.0776739509	0.0043127959

Conclusão sobre o efeito de Método de Ensino?

Modelo Linear Misto

Tabela de ANOVA - Modelo Misto

	Df	Sum Sq	Mean Sq	F value
Método (A:Fixo)	2	1695.63	847.82	FA: 847.82/27.75=30.55 <0.001*
Instrutor (B:Aleatório)	4	190.57	47.64	FB: 47.64/66.50= 0.72 0.5851
Método*Instrutor (AB:Aleat)	8	222.03	27.75	FAB: 27.75/66.50=0.42 0.9045
Residuals	45	2992.50	66.50	

$$\hat{\sigma}_B^2 = \frac{QMB - QM Res}{ra} = -1,57$$

$$\hat{\sigma}_{AB}^2 = \frac{QMAB - QM Res}{r} = -9.69$$

Não significantes. Podem ser considerados nulos.

$$\hat{\sigma}_e^2 = QM Res = 66.5$$

Modelos Lineares Mistos

Delineamentos com Dois Fatores

Expected Mean Squares for Balanced Two-Factor ANOVA Models.

Mean Square	<i>df</i>	Fixed ANOVA Model (A and B fixed)	Random ANOVA Model (A and B random)	Mixed ANOVA Model (A fixed, B random)
<i>MSA</i>	$a - 1$	$\sigma^2 + nb \frac{\sum \alpha_i^2}{a - 1}$	$\sigma^2 + nb\sigma_\alpha^2 + n\sigma_{\alpha\beta}^2$	$\sigma^2 + nb \frac{\sum \alpha_i^2}{a - 1} + n\sigma_{\alpha\beta}^2$
<i>MSB</i>	$b - 1$	$\sigma^2 + na \frac{\sum \beta_j^2}{b - 1}$	$\sigma^2 + na\sigma_\beta^2 + n\sigma_{\alpha\beta}^2$	$\sigma^2 + na\sigma_\beta^2$
<i>MSAB</i>	$(a - 1)(b - 1)$	$\sigma^2 + n \frac{\sum \sum (\alpha\beta)_{ij}^2}{(a - 1)(b - 1)}$	$\sigma^2 + n\sigma_{\alpha\beta}^2$	$\sigma^2 + n\sigma_{\alpha\beta}^2$
<i>MSE</i>	$(n - 1)ab$	σ^2	σ^2	σ^2

n: número de réplicas
Neter et al., 2005

Modelo Misto: Um Fator Fixo e Um Fator Aleatório

Um nutricionista está interessado no consumo de 5 tipos de Menus. Restaurantes foram amostrados de um município e o consumo dos Menus (número de pedidos) foi avaliado.

Restaurante	Tipo de Menu					Restaurante	Tipo de Menu				
	1	2	3	4	5		1	2	3	4	5
1	11	13	10	18	15	5	14	16	13	22	16
2	20	28	15	30	18	6	25	27	26	33	25
3	8	10	8	16	12	7	43	46	41	55	42
4	30	35	27	41	28	8	13	14	12	20	13

Considere a análise destes dados supondo que existe correlação entre pedidos feitos em um mesmo restaurante.

Modelagem: Tipo de Menu como Fator Fixo e Restaurante como Fator Aleatório.
Como fica definida a estrutura de correlação entre as observações?

Qual é a diferença dos modelos se Restaurante for assumido como Fator Bloco?

Modelo Linear Misto – Formulação Matricial

$$y_{ijk} = \mu + \tau_j + u_{1k} + u_{2jk} + e_{ijk}$$

$$\sum_j \tau_j = 0,$$

$$u_{1k} \sim N(0; \sigma_1^2), \quad u_{2jk} \sim N(0; \sigma_{12}^2), \quad \sum_j u_{2jk} = 0$$

$$e_{ijk} \sim N(0; \sigma_e^2), \quad u_{1k} \perp u_{2jk} \perp e_{ijk}$$

Formulação com
restrição

$$y_{ijk} \sim N(\mu + \tau_i; \sigma_1^2 + \sigma_{12}^2 + \sigma_e^2) \quad \text{Cov}(y_{ijk}; y_{i'j'k'}) = \begin{cases} \sigma_1^2 + \sigma_{12}^2 + \sigma_e^2 & i = i' \\ \sigma_1^2 + \sigma_{12}^2 & i \neq i', j = j'; k = k' \\ \sigma_1^2 - \sigma_{12}^2 & i \neq i', j \neq j'; k = k' \\ 0 & k \neq k' \end{cases}$$

$$Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + Z_{n \times q} u_{q \times 1} + e_{n \times 1}$$

$$E(Y) = X \beta$$

$$\text{Cov}(Y) = Z' \Delta Z + \Sigma$$

Modelo Linear Misto – Formulação Matricial

$$Y_{n \times 1} = X_{n \times p} \beta_{p \times 1} + Z_{n \times q} u_{q \times 1} + e_{n \times 1}$$

$$E(Y) = X \beta$$

$$\text{Cov}(Y) = Z' \Delta Z + \Sigma$$

Delineamento Fatorial 2x2 com r=2 replicas, fator A fixo e fator B aleatório

$$\begin{matrix}
 i=1,2 \\
 j=1,2 \\
 k=1,2
 \end{matrix}
 Y_{8 \times 1} = \begin{pmatrix} y_{111} \\ y_{211} \\ y_{121} \\ y_{221} \\ y_{112} \\ y_{212} \\ y_{122} \\ y_{222} \end{pmatrix} Y_{n \times 1}, \quad X_{8 \times 2} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \\ 1 & -1 \\ 1 & -1 \\ 1 & 1 \\ 1 & 1 \\ 1 & -1 \\ 1 & -1 \end{pmatrix}, \quad \beta_{2 \times 1} = \begin{pmatrix} \mu \\ \tau_1 \end{pmatrix}, \quad Z_{8 \times 4} = \begin{pmatrix} 1 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & -1 & 0 \\ 1 & 0 & -1 & 0 \\ 0 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 \\ 0 & 1 & -1 & -1 \\ 0 & 1 & -1 & -1 \end{pmatrix}, \quad u_{4 \times 1} = \begin{pmatrix} u_{11} \\ u_{12} \\ u_{211} \\ u_{212} \end{pmatrix}$$

$$\text{Cov}(Y)_{8 \times 8} = Z' \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_{12}^2 \end{pmatrix} Z + I_8 \sigma_e^2$$

Delineamentos SpliPlot

Parcela subdividida

Em muitas situações, os tratamentos em estrutura fatorial podem ser alocados em configurações de blocagem e unidades experimentais que levam à ideia de **dois ou mais tamanhos de unidades experimentais no mesmo delineamento**.

Isso ocorre devido a restrições práticas, de forma que para aplicar os níveis de alguns fatores é necessário o uso de parcelas “grandes” enquanto que os níveis dos outros fatores podem ser aplicados em parcelas “menores” ⇒ **restrição na aleatorização**.

Qual é a definição de uma unidade experimental?

Exemplo (Agronomia): avaliar os efeitos de 4 variedades e 3 níveis de irrigação na produção de feijão. Plantas de uma variedade podem ser alocadas em canteiros não muito grandes, ou até mesmo em vasos. Mas na irrigação, a área irrigada, fixando um dos níveis desejados deste fator, deve ser bem maior.



Fatorial 4x3

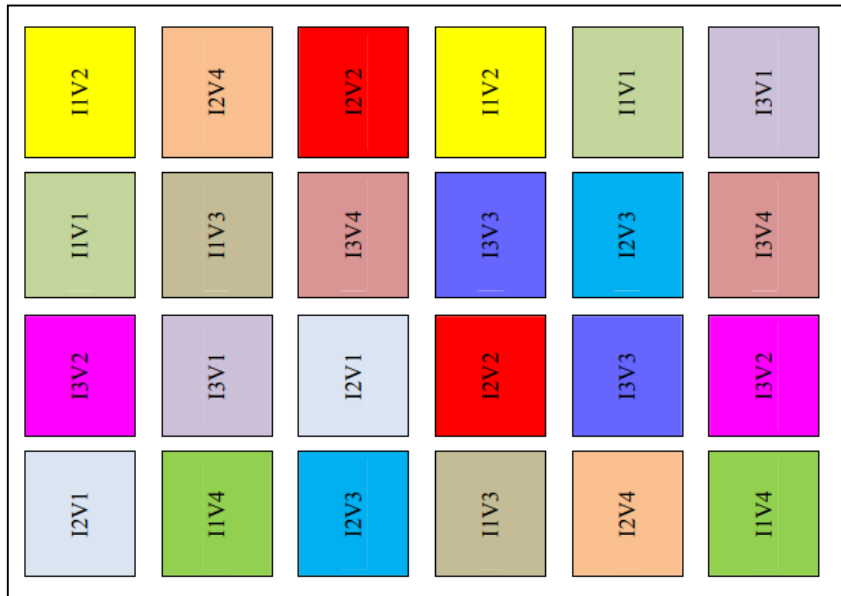


Como deve ser particionada a área do estudo?

Delineamentos SpliPlot


Parcela subdividida

Alternativa 1: DCA com 24 unidades experimentais

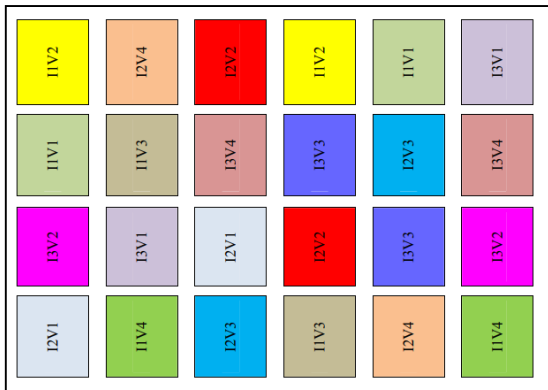


Os 12 tratamentos são aleatorizados a 24 u.e.
(replicas = 2)

Alternativa 2: As irrigações (I1, I2 e I3) são aleatorizadas aos 24 canteiros (u.e.1). Em cada canteiro, as variaedades (V1, V2, V3 e V4) são aleatorizadas às sub-parcelas (u.e.2 dentro da u.e.1).



Delineamentos SpliPlot




Alternativa 1: Modelo

$$y_{ijk} = \mu + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}$$

$$j = 1, 2, 3; \quad k = 1, 2, 3, 4; \quad i = 1, 2$$

$$\sum_j \tau_j = \sum_k \beta_k = \sum_j \gamma_{jk} = \sum_k \gamma_{jk} = 0$$

$$e_{ijk} \sim N(0; \sigma^2) \quad n=24$$



Alternativa 2: Modelo

$$y_{ijk} = \mu + \tau_j + u_{ij} + \beta_k + \gamma_{jk} + e_{ijk}$$

$$u_{ij} \sim N(0; \sigma_1^2) \quad \perp \quad e_{ijk} \sim N(0; \sigma_e^2)$$

Covariância entre respostas da mesma parcela: simetria composta (uniforme)

$$\text{Cov}(y_{ijk}, y_{i'jk'}) = \begin{pmatrix} \sigma_1^2 + \sigma_e^2 & \sigma_1^2 & \sigma_1^2 & \sigma_1^2 \\ & \sigma_1^2 + \sigma_e^2 & \sigma_1^2 & \sigma_1^2 \\ \sim & & \sigma_1^2 + \sigma_e^2 & \sigma_1^2 \\ & & & \sigma_1^2 + \sigma_e^2 \end{pmatrix}$$

$$n_1=24, n_{2(1)}=4 \Rightarrow n=96 \quad (3*4*8)$$

Delineamentos SplitPlot

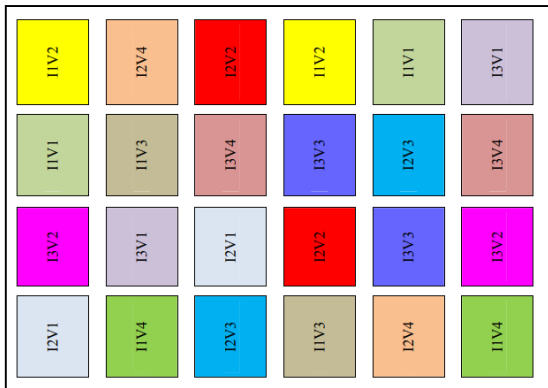



Tabela de ANOVA

Alternativa 1	
Fontes de Variação	GL
Irrigação	2
Variedade	3
Interação	6
Resíduo	19
Total	23



$n_1=24$
 $r_1=8$

Tabela de ANOVA

Alternativa 2		
Fontes de Variação	GL	
Irrigação	2	a-1
Resíduo 1	21	$a(r_1-1)$
Sub-total	23	(n_1-1)
Variedade	3	b-1
Interação	6	$(a-1)(b-1)$
Resíduo 2	63	$a(b-1)(r_1-1)$
Total	95	$(n-1)$

Delineamentos SpliPlot




Tabela de ANOVA

Alternativa 2	
Fontes de Variação	GL
Irrigação	2
Resíduo 1	21
Sub-total	23
Variedade	3
Interação	6
Resíduo 2	63
Total	95

O delineamento pode ser reduzido para $r=5$ réplicas no primeiro nível de aleatorização

$24=3 \times 8$
3 níveis de irrigação cada um com $r=8$

Fontes de Variação	GL
Irrigação	2
Resíduo 1	12
Sub-total	14
Variedade	3
Interação	6
Resíduo 2	36
Total	59

Delineamentos SpliPlot ou Delineamentos Multi-Estratificados

Muitas fontes de variação

O exemplo Fatorial 3x4 (Irrigação e Variedades) ilustra um **delineamento balanceado em parcelas-subdivididas com dois fatores**.

O balanceamento pode ficar mais difícil de ser garantido quando o número de fatores aumenta devido a restrições no número de sub-parcelas.

Cada **Parcela Principal** pode ser vista como um **Bloco** para o delineamento referente aos fatores nas sub-parcelas. CONTUDO, neste caso, as observações dentro do bloco apresentam covariâncias (não são assumidas independentes).







Delineamentos SplitPlot

Experimento industrial: Verificar a resistência à corrosão de barras de aço revestidas com 4 materiais diferentes (C1, C2, C3, C4) e submetidas a 3 diferentes temperaturas (360°C, 370°C e 380°C).

Condição experimental: existem 6 fornos com 4 colunas de aquecimento.

Aleatorização 1: aleatorizar as 3 temperaturas aleatoriamente aos 6 fornos.

Aleatorização 2: aleatorizar os 4 tratamentos nas posições de cada forno.



Delineamentos SplitPlot


Experimento industrial: Verificar a resistência à corrosão de barras de aço revestidas com 4 materiais diferentes (C1, C2, C3, C4) e submetidas a 3 diferentes temperaturas (360°C, 370°C e 380°C).

Condição experimental: existem 6 fornos com 4 colunas de aquecimento.

Aleatorização 1: aleatorizar as 3 temperaturas aleatoriamente aos 6 fornos.

Aleatorização 2: aleatorizar os 4 tratamentos nas posições de cada forno.

Temp	C1	C2	C3	C4
360	67	73	83	89
	33	8	46	54
370	65	91	87	86
	140	142	121	150
380	155	127	147	212
	108	100	90	153



Delineamentos SpliPlot

Esqueleto da ANOVA


$n1=6, r1=2, a=3, b=4, n=24$	
FV	nGL
Temp	$(3-1)=2$
Res1	$3(2-1)=3$
SubTotal	$(6-1)=5$
Trat	$(4-1)=3$
Temp*trat	$(3-1)(4-1)=6$
Res2	$3(4-1)(2-1)=9$
Total	$24-1=23$

Tabela de ANOVA

	npar	Sum Sq	Mean Sq	F value
factor(temp)	2	686.2	343.09	2.7548
factor(trat)	3	4289.1	1429.71	11.4798
factor(temp):factor(trat)	6	3269.8	544.96	4.3757

Efeitos aleatórios

Groups	Name	Std.Dev.
u1	(Intercept)	34.24
Residual		11.16



IC Bootstrap

	2.5 %	97.5 %
.sig01	12.301025	85.66795
.sigma	5.882823	15.18173
(Intercept)	1.175311	106.38312
factor(temp) 2	-16.959406	125.83224
factor(temp) 3	15.263402	149.43436
factor(trat) 2	-31.416970	13.16407
factor(trat) 3	-8.594895	36.83418
factor(trat) 4	-1.077222	42.24273
factor(temp) 2:factor(trat) 2	-8.613674	54.12488
factor(temp) 3:factor(trat) 2	-39.112258	24.33737
factor(temp) 2:factor(trat) 3	-43.131832	18.57100
factor(temp) 3:factor(trat) 3	-57.476223	2.43436
factor(temp) 2:factor(trat) 4	-36.182818	27.38706
factor(temp) 3:factor(trat) 4	-1.716140	60.24685

Não há ef. Interação ⇒ Modelo reduzido


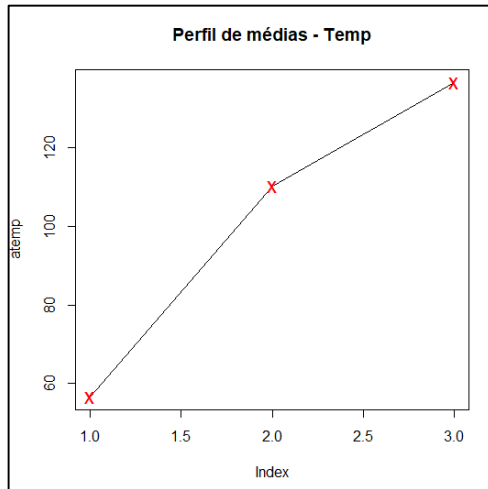
Delineamentos SpliPlot

Tabela de ANOVA - Modelo reduzido (aditivo)

	npar	Sum Sq	Mean Sq	F value
factor(temp)	2	1612.7	806.36	2.7548
factor(trat)	3	4289.1	1429.71	4.8844

Efeitos aleatórios

Groups	Name	Variance	Std.Dev.
u1	(Intercept)	1130.1	33.62
Residual		292.7	17.11




Efeito de Temp (valor-p ajustado)

contrast	estimate	SE	df	t.ratio	p.value
1 - 2	-53.6	34.7	3	-1.546	0.3896
1 - 3	-79.9	34.7	3	-2.303	0.1987
2 - 3	-26.2	34.7	3	-0.757	0.7512

Efeito de Trat (valor-p ajustado)

contrast	estimate	SE	df	t.ratio	p.value
1 - 2	4.5	9.88	15	0.456	0.9675
1 - 3	-1.0	9.88	15	-0.101	0.9996
1 - 4	-29.3	9.88	15	-2.970	0.0424
2 - 3	-5.5	9.88	15	-0.557	0.9432

Delineamentos SpliPlot



Descrever a estrutura deste delineamento Spli-Plot.

n1=8: número de plotes completos do primeiro nível de aleatorização

r1= 4

a = 2, b=4

n=32

Ohelert (2010): john

	plot	fertilizer	variety	mass
1	7	control	A	11.6
2	7	control	B	7.7
3	7	control	C	12.0
4	7	control	D	14.0
5	5	control	A	8.9
6	5	control	B	9.5
7	5	control	C	11.7
8	5	control	D	15.0
9	6	control	A	10.8
10	6	control	B	11.0
11	6	control	C	12.1
12	6	control	D	12.9
13	1	control	A	10.0
14	1	control	B	9.3
15	1	control	C	12.4
16	1	control	D	15.0
17	8	new	A	16.7
18	8	new	B	14.6
19	8	new	C	18.2
20	8	new	D	18.1
21	2	new	A	15.1
22	2	new	B	11.6
23	2	new	C	15.3
24	2	new	D	16.7
25	4	new	A	18.0
26	4	new	B	11.5
27	4	new	C	16.9
28	4	new	D	20.6
29	3	new	A	15.9
30	3	new	B	17.4
31	3	new	C	17.1
32	3	new	D	18.6

Delineamentos SpliPlot


Tabela de ANOVA - Dados Oehlert (2010)

	npar	Sum Sq	Mean Sq	F value
fertilizer	1	137.413	137.413	68.2395
variety	3	96.431	32.144	15.9627
fertilizer:variety	3	4.173	1.391	0.6907

Efeitos aleatórios

Groups	Name	Variance	Std.Dev.
plot	(Intercept)	0.2003	0.4475
Residual		2.0137	1.4190

Number of obs: 32, groups: plot, 8



IC (method="Wald")

	2.5 %	97.5 %
(Intercept)	8.8668479	11.7831521
fertilizernew	4.0378616	8.1621384
varietyB	-2.9166559	1.0166559
varietyC	-0.2416559	3.6916559
varietyD	1.9333441	5.8666559
fertilizernew:varietyB	-4.4812715	1.0812715
fertilizernew:varietyC	-4.0562715	1.5062715
fertilizernew:varietyD	-4.6062715	0.9562715

Não há ef. Interação \Rightarrow Modelo reduzido

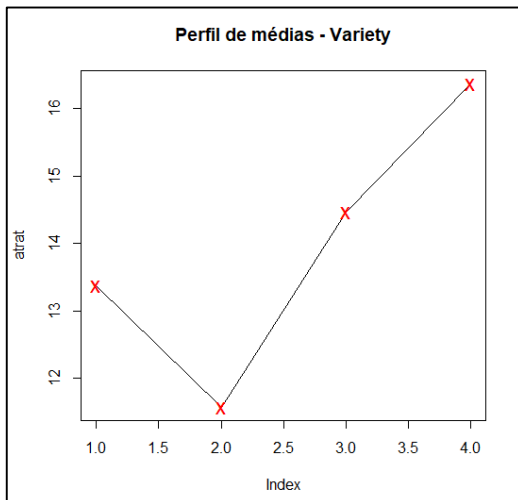
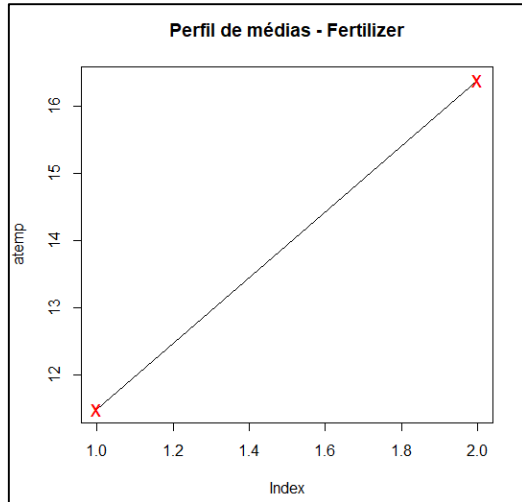
Delineamentos SpliPlot

Tabela de ANOVA - Modelo reduzido (aditivo)

	npar	Sum Sq	Mean Sq	F value
fertilizer	1	131.341	131.341	68.240
variety	3	96.431	32.144	16.701

Efeitos aleatórios

Groups	Name	Variance	Std.Dev.
plot	(Intercept)	0.2225	0.4717
Residual		1.9247	1.3873



IC (method="bootstrap")

	2.5 %	97.5 %
.sig01	0.0000000	1.2245619
.sigma	0.9498976	1.7605467
(Intercept)	9.7869441	12.1378883
fertilizernew	3.7030075	6.0429866
varietyB	-3.1827331	-0.5035862
varietyC	-0.3277087	2.4025891
varietyD	1.6860275	4.3465932

Ajustar o
modelo sem o
efeito aleatório

Efeito de Fertilizer

	estimate	SE	df	t.ratio	p.value
control - new	-4.9	0.593	6	-8.261	0.0002

Efeito de Variety

contrast	estimate	SE	df	t.ratio	p.value
A - B	1.80	0.694	21	2.595	0.0739
A - C	-1.09	0.694	21	-1.568	0.4174
A - D	-2.99	0.694	21	-4.307	0.0016
B - C	-2.89	0.694	21	-4.163	0.0023
B - D	-4.79	0.694	21	-6.902	<.0001
C - D	-1.90	0.694	21	-2.739	0.0552

Delineamento Split-Split-Plot

Split-split-plot

A partição (split) é nas Unidades Experimentais

Tecido	MP	Técnica 1					Técnica 2				
		R1	R2	R3	R4	R5	R6	R7	R8	R9	R10
T1	Gel										
	Sol										
	Filt										
	Pip										
T2	Gel										
	Sol										
	Filt										
	Pip										
T3	Gel										
	Sol										
	Filt										
	Pip										
T4	Gel										
	Sol										
	Filt										
	Pip										

Quantificação de proteínas em Tecidos Tumoriais de acordo com o Método de Preparação (MP) das amostras e Técnica de leitura

Estrutura das Unidades Experimentais:

- Cada amostra de tecido é particionada (**split**) em 4 pedaços que são aleatorizados aos MP
- Cada solução preparada é particionada (**split**) em 10 alíquotas, metade das quais é aleatorizada às Técnicas 1 ou 2.

Estrutura de Tratamentos:

Dois fatores (Método de Preparação e Técnica) cruzados (Fatorial 2x4) hierárquicos dentro de Tecido.

Quais são as unidades amostrais, experimentais e de mensuração? Há possível dependência entre observações dentro do mesmo tecido? E entre as réplicas do mesmo tecido e do mesmo MP?

Delineamentos com Medidas Repetidas

Os fatores sob estudo (Tratamentos) são aplicados à **mesma unidade experimental**. Neste tipo de delineamento o sujeito (u.e.) é considerado um fator **aleatório**

Motivação

Delineamento com Um Único Fator
Medidas Repetidas em Um Único Fator (J=4, r=5)

Sujeito 1	T4	T3	T2	T1
Sujeito 2	T3	T4	T1	T2
Sujeito 3	T4	T3	T1	T2
Sujeito 4	T2	T1	T4	T3
Sujeito 5	T1	T2	T4	T3

- ⇒ Há Aleatorização da ordem dos tratamentos dentro dos sujeitos
- ⇒ Delineamento com Medidas Repetidas é um Delineamento em Blocos Randomizados (Bloco é Fator Aleatório)
- ⇒ Uma alternativa é o **Delineamento Quadrado Latino – CrossOver** em que há balanceamento do número de vezes que um tratamento é precedido pelo outro. Neste caso o paciente é modelado como fator fixo (Fator Linha)

Exemplo de “sujeitos (u.e.)”: pacientes, juiz

Delineamentos com Medidas Repetidas

Medidas repetidas em Um Único Fator
($a=4, r=5$)

Sujeito 1 T4 T3 T2 T1

Sujeito 2 T3 T4 T1 T2

Sujeito 3 T4 T3 T1 T2

Sujeito 4 T2 T1 T4 T3

Sujeito 5 T1 T2 T4 T3

Juízes avaliam vinhos

Juiz	V1	V2	V3	V4
1	20	24	28	28
2	15	18	23	24
3	18	19	24	23
4	26	26	30	30
5	22	24	28	26

$$y_{ij}, \quad i = 1, \dots, n_j = r; \quad j = 1, \dots, a$$

j-ésima resposta avaliada no sujeito *i*
(*unidade experimental i*)

Delineamentos com Medidas Repetidas

Medidas repetidas em Um Único Fator (a níveis do Fator, r réplicas)

Sujeito 1	T4	T3	...	Ta
Sujeito 2	Ta	T1	...	T2
...				
Sujeito r	T1	T2	...	T3

Suposição: aditividade entre u.e. e Trat!

$$y_{ij} = \mu + \rho_i + \tau_j + e_{ij}; \quad i = 1, \dots, r; \quad j = 1, \dots, a$$

Variáveis aleatórias


$$\sum_j \tau_j = 0; \quad \rho_i \sim N(0; \sigma_\rho^2) \quad \perp \quad e_{ijk} \sim N(0; \sigma_e^2)$$

Fator fixo: restrição de identificabilidade
(parametrização de desvios)

$$\Rightarrow y_{ij} \sim N(\mu + \tau_j; \sigma_\rho^2 + \sigma_e^2)$$

$$Cov(y_{ij}; y_{i'j'}) = \begin{cases} \sigma_\rho^2 + \sigma_e^2 & i = i'; j = j' \\ \sigma_\rho^2 & i = i'; j \neq j' \\ 0 & c.c. \end{cases}$$

Modelo de
componentes de
variância e estrutura
de correlação
uniforme



$$Cor(y_{ij}; y_{ij'}) = \frac{\sigma_\rho^2}{\sigma_\rho^2 + \sigma_e^2}$$

Coefficiente de
correlação intra-
classe (uniforme para
todos os sujeitos)

Delineamentos com Medidas Repetidas

Medidas repetidas em Um Único Fator

Juízes avaliam vinhos

Juiz	V1	V2	V3	V4
1	20	24	28	28
2	15	18	23	24
3	18	19	24	23
4	26	26	30	30
5	22	24	28	26

FV	GL	E(QM)
Sujeito	r-1	$\sigma_e^2 + a\sigma_\rho^2$
A	a-1	$\sigma_e^2 + r \frac{\sum \tau_j^2}{a-1}$
Resíduo	(r-1)(a-1)	σ_e^2
Total	ra-1	

$$y_{ij} = \mu + \rho_i + \tau_j + e_{ij}; \quad i = 1, \dots, r; \quad j = 1, \dots, a$$

Suposição: aditividade entre u.e. e Trat!
Como em Blocos (fixo) o resíduo é a interação.

$$SQ_{Total} = SQ_{Sujeitos} + SQ_{Fator} + SQ_{Resíduo}$$

$$\sum_{ij} (y_{ij} - \bar{y}_{..})^2 = \sum_i (\bar{y}_{i.} - \bar{y}_{..})^2 + \sum_j (\bar{y}_{.j} - \bar{y}_{..})^2 + \sum_{ij} (y_{ij} - \bar{y}_{i.} - \bar{y}_{.j} + \bar{y}_{..})^2$$

Delineamentos com Medidas Repetidas

Medidas repetidas em Um Único Fator

Juízes avaliam vinhos

Juiz	V1	V2	V3	V4
1	20	24	28	28
2	15	18	23	24
3	18	19	24	23
4	26	26	30	30
5	22	24	28	26

Tabela de ANOVA

	npar	Sum Sq	Mean Sq	F value
factor(trat)	3	145.6	48.533	40.444

Efeitos Aleatórios


Groups	Name	Variance	Std.Dev.
ue	(Intercept)	10.4	3.225
Residual		1.2	1.095

IC Bootstrap

	2.5 %	97.5 %
.sig01	1.0680623	5.999450
.sigma	0.6510461	1.549515
(Intercept)	17.2063768	23.455585
factor(trat)2	0.5959574	3.314128
factor(trat)3	5.0644990	7.730844
factor(trat)4	4.7236146	7.279308

Contrast

	estimate	SE	df	t.ratio	p.value
1 - 2	-2.0	0.693	12	-2.887	0.0576
1 - 3	-6.4	0.693	12	-9.238	<.0001
1 - 4	-6.0	0.693	12	-8.660	<.0001
2 - 3	-4.4	0.693	12	-6.351	0.0002
2 - 4	-4.0	0.693	12	-5.774	0.0004
3 - 4	0.4	0.693	12	0.577	0.9370



Suposição:
aditividade entre
u.e. e Trat!

$$(\mu_1 = \mu_2) < (\mu_3 = \mu_4)$$

Delineamentos com Medidas Repetidas

Delineamento Fatorial axb
 Medidas repetidas em 2 Fatores
 ($a=2, b=2, r=5$)

Sujeito 1 A1B2 A2B2 A1B1 A2B1

Sujeito 2 A1B2 A2B2 A1B1 A2B1

Sujeito 3 A1B2 A2B2 A1B1 A2B1

Sujeito 4 A1B2 A2B2 A1B1 A2B1

Sujeito 5 A1B2 A2B2 A1B1 A2B1

Juízes avaliam vinhos produzidos segundo o Tipo de Uva (Fator A: A1 e A2) e o Tempo de Armazenamento (Fator B: B1 e B2)

Juiz	A1B1	A1B2	A2B1	A2B2
1	20	24	28	28
2	15	18	23	24
3	18	19	24	23
4	26	26	30	30
5	22	24	28	26

$$y_{ijk}, \quad i = 1, \dots, r; \quad j = 1, \dots, a; \quad k = 1, \dots, b$$

*jk-ésima resposta avaliada no sujeito i
 (unidade experimental i)*

Delineamentos com Medidas Repetidas

Em Dois Fatores

Suposição: aditividade entre u.e. e Tratamentos!

$$y_{ijk} = \mu + \rho_i + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad i = 1, \dots, r; j = 1, \dots, a; k = 1, \dots, b$$



Variáveis aleatórias

$$\sum_j \tau_j = \sum_k \beta_k = \sum_j \gamma_{jk} = \sum_k \gamma_{jk} = 0;$$

$$\rho_i \sim N(0; \sigma_\rho^2) \perp e_{ijk} \sim N(0; \sigma_e^2)$$



Fatores fixos: restrição de identificabilidade
(parametrização de desvios)

$$\Rightarrow y_{ij} \sim N(\mu + \tau_j + \beta_k + \gamma_{jk}; \sigma_\rho^2 + \sigma_e^2)$$

Modelo de
componentes de
variância e estrutura
de correlação
uniforme



$$Cov(y_{ijk}; y_{i'j'k'}) = \begin{cases} \sigma_\rho^2 + \sigma_e^2 & i = i'; j = j'; k = k' \\ \sigma_\rho^2 & i = i'; j \neq j' \vee k \neq k' \\ 0 & c.c. \end{cases}$$

Delineamentos com Medidas Repetidas

Juízes avaliam vinhos produzidos segundo o Tipo de Uva (A1 e A2) e o Tempo de Armazenamento (B1 e B2)

Juiz	A1B1	A1B2	A2B1	A2B2
1	20	24	28	28
2	15	18	23	24
3	18	19	24	23
4	26	26	30	30
5	22	24	28	26

FV	GL	E(QM)
A	a-1	$\sigma_e^2 + br \frac{\sum \tau_j^2}{a-1}$
B	b-1	$\sigma_e^2 + ar \frac{\sum \beta_k^2}{b-1}$
A*B	(a-1)(b-1)	$\sigma_e^2 + r \frac{\sum_{jk} \gamma_{jk}^2}{(a-1)(b-1)}$
Sujeito	r-1	$\sigma_e^2 + ab\sigma_\rho^2$
Resíduo	(r-1)(ab-1)	σ_e^2
Total	ra-1	Suposição: aditividade entre u.e. e Trat. Resíduo é a interação!

$$y_{ijk} = \mu + \rho_i + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad i = 1, \dots, r; \quad j = 1, \dots, a; \quad k = 1, \dots, b$$

$$SQ_{Total} = SQA + SQB + SQA * B + SQ_{Sujeitos} + SQ_{Resíduo}$$

$$\sum_{ijk} (y_{ijk} - \bar{y}_{...})^2 = br \sum_j (\bar{y}_{.j} - \bar{y}_{..})^2 + ar \sum_k (\bar{y}_{..k} - \bar{y}_{..})^2 + r \sum_{ijk} (\bar{y}_{.jk} - \bar{y}_{.j} - \bar{y}_{..k} + \bar{y}_{...})^2 + ab \sum_{ij} (\bar{y}_{i..} - \bar{y}_{...})^2 + \sum_{ijk} (y_{ijk} - \bar{y}_{i..} - \bar{y}_{.jk} + \bar{y}_{...})^2$$

Delineamentos com Medidas Repetidas

Juízes avaliam vinhos segundo o Tipo de Uva (A1 e A2) e o Tempo de Armazenamento (B1 e B2)

Juiz	A1B1	A1B2	A2B1	A2B2
1	20	24	28	28
2	15	18	23	24
3	18	19	24	23
4	26	26	30	30
5	22	24	28	26




Tabela de ANOVA

	npar	Sum Sq	Mean Sq	F value
factor (A)	1	3.2000	3.2000	0.2655
factor (B)	1	0.1333	0.1333	0.0111
factor (A) : factor (B)	1	0.1130	0.1130	0.0094

Efeitos Aleatórios

Groups	Name	Variance	Std.Dev.
ue	(Intercept)	11.21	3.348
Residual		12.05	3.471

IC Bootstrap

	2.5 %	97.5 %
.sig01	0.000000	6.800032
.sigma	2.128055	4.775678
(Intercept)	18.743120	28.159854
factor (A) 2	-6.015514	8.311324
factor (B) 2	-7.429784	7.006444
factor (A) 2 : factor (B) 2	-14.031180	13.644585

Sob o ajuste do modelo reduzido, sem a interação, não há evidência de efeito significativo dos fatores A e B e a variância entre juízes não é significativa.
 \Rightarrow Média geral = 23.8 (sd=4.18)

Delineamentos com Medidas Repetidas

Delineamento Fatorial $a \times b$ Medidas repetidas em um Único Fator

Tratamento A	Sujeito	Ordem do Tratamento B	
		1	2
A1	1	A1B1	A1B2
	
	
	r	A1B2	A1B1
A2	r+1	A1B1	A1B2
	
	
	2r	A1B2	A1B1

Score de habilidade em solucionar problemas de acordo com o tipo de estímulo (A) e o tipo de problema (B)

Tipo de Estímulo (A)	Volunt.	Tipo de Problema (B)	
		Abstrato	Concreto
A1	1	10	18
	2	14	19
	3	17	18
	4	8	12
	5	12	14
	6	15	20
A2	7	16	25
	8	19	22
	9	22	27
	10	20	23
	11	24	29
	12	21	22

Delineamentos Fatoriais axb com Medidas Repetidas em Um Único Fator

$$y_{ijk} = \mu + \rho_{i(j)} + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad i = 1, \dots, r; j = 1, \dots, a; k = 1, \dots, b$$



Variáveis aleatórias

$$\sum_j \tau_j = \sum_k \beta_k = \sum_j \gamma_{jk} = \sum_k \gamma_{jk} = 0; \quad \rho_{i(j)} \sim N(0; \sigma_\rho^2) \perp e_{ijk} \sim N(0; \sigma_e^2)$$



Fatores fixos: restrição de identificabilidade

$$\Rightarrow y_{ij} \sim N(\mu + \tau_j + \beta_k + \gamma_{jk}; \sigma_\rho^2 + \sigma_e^2)$$

$$Cov(y_{ijk}; y_{i'j'k'}) = \begin{cases} \sigma_\rho^2 + \sigma_e^2 & i = i'; j = j'; k = k' \\ \sigma_\rho^2 & i = i'; j = j'; k \neq k' \\ 0 & \text{c.c.} \end{cases}$$

Delineamento Fatorial axb
Medidas repetidas em um Único Fator

Tratamento A	Sujeito	Ordem do Tratamento B	
		1	2
A1	1	A1B1	A1B2
	⋮	⋮	
	r	A1B2	A1B1
A2	r+1	A2B1	A2B2
	⋮	⋮	
	2r	A2B2	A2B1

Medidas Repetidas

FV	GL	E(QM)
A	a-1	$\sigma_e^2 + b\sigma_\rho^2 + br \frac{\sum \tau_j^2}{a-1}$
B	b-1	$\sigma_e^2 + ar \frac{\sum \beta_k^2}{b-1}$
A*B	(a-1)(b-1)	$\sigma_e^2 + r \frac{\sum_{jk} \gamma_{jk}^2}{(a-1)(b-1)}$
Sujeito(A)	a(r-1)	$\sigma_e^2 + b\sigma_\rho^2$
Resíduo	a(r-1)(b-1)	σ_e^2
Total	rab-1	

$$y_{ijk} = \mu + \rho_i + \tau_j + \beta_k + \gamma_{jk} + e_{ijk}; \quad i = 1, \dots, r; \quad j = 1, \dots, a; \quad k = 1, \dots, b$$

$$SQ_{Total} = SQ_A + SQ_B + SQ_{A*B} + SQ_{Sujeitos} + SQ_{Resíduo}$$

$$\sum_{ijk} (y_{ijk} - \bar{y}_{...})^2 = br \sum_j (\bar{y}_{.j} - \bar{y}_{..})^2 + ar \sum_k (\bar{y}_{..k} - \bar{y}_{..})^2 + r \sum_{ijk} (\bar{y}_{.jk} - \bar{y}_{.j} - \bar{y}_{..k} + \bar{y}_{..})^2 + b \sum_{ij} (\bar{y}_{ij} - \bar{y}_{.j})^2 + \sum_{ijk} (y_{ijk} - \bar{y}_{.jk} - \bar{y}_{ij} + \bar{y}_{.j})^2$$

Escore de habilidade em solucionar problemas

Medidas Repetidas

Tipo de Estímulo (A)	Tipo de Problema (B)		
	Volunt.	Abstrato	Concreto
A1	1	10	18
	2	14	19
	3	17	18
	4	8	12
	5	12	14
	6	15	20
A2	7	16	25
	8	19	22
	9	22	27
	10	20	23
	11	24	29
	12	21	22

Tabela de ANOVA


	npar	Sum Sq	Mean Sq	F value
factor (A)	1	82.573	82.573	24.227
factor (B)	1	108.375	108.375	31.797
factor (A) : factor (B)	1	0.042	0.042	0.012

Efeitos Aleatórios

Groups	Name	Variance	Std.Dev.
ue	(Intercept)	5.733	2.394
Residual		3.408	1.846

IC Bootstrap

	2.5 %	97.5 %
.sig01	1.0824305	3.965197
.sigma	0.9897631	2.553271
(Intercept)	9.8980374	15.240212
factor (A) 2	4.3546959	11.106053
factor (B) 2	2.1452564	6.354115
factor (A) 2 : factor (B) 2	-2.9590180	3.107374



Não há interação significativa entre os fatores.

Escore de habilidade em solucionar problemas

Medidas Repetidas

Tipo de Estímulo (A)	Tipo de Problema (B)		
	Volunt.	Abstrato	Concreto
A1	1	10	18
	2	14	19
	3	17	18
	4	8	12
	5	12	14
	6	15	20
A2	7	16	25
	8	19	22
	9	22	27
	10	20	23
	11	24	29
	12	21	22

Tabela de ANOVA


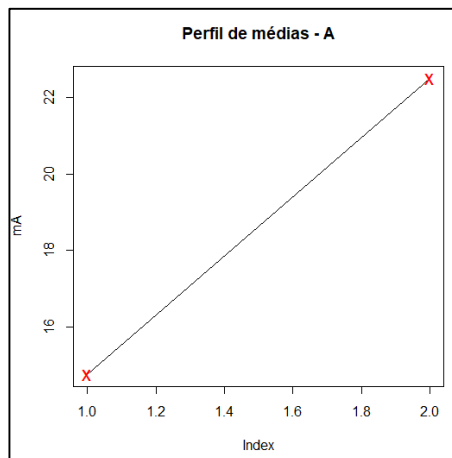
	npar	Sum Sq	Mean Sq	F value
factor (A)	1	75.158	75.158	24.227
factor (B)	1	108.375	108.375	34.934

Efeitos Aleatórios

Groups	Name	Variance	Std.Dev.
ue	(Intercept)	5.886	2.426
Residual		3.102	1.761

IC Bootstrap

	2.5 %	97.5 %
.sig01	0.9748833	3.923982
.sigma	0.9909851	2.413254
(Intercept)	10.4423068	15.154680
factor (A) 2	4.7729733	10.757464
factor (B) 2	2.8121401	5.563659



Delineamentos com Medidas Repetidas no Tempo

Dados Longitudinais

ou Medidas Repetidas no Espaço:
diferentes profundidades de um rio

Tipo de Propaganda	Ponto de Venda	Período de Tempo		
		T1	T2	T3
A1	1	958	1047	933
	2	1005	1122	986
	3	351	436	339
	4	549	632	512
	5	730	784	707
A2	6	780	897	718
	7	229	275	202
	8	883	964	817
	9	624	695	599
	10	375	436	351

Os dados podem ser modelados como Medidas Repetidas

- Neste caso, é suposto que os Tempos foram aleatorizados (!!)
- Além disso, é preciso atenção ao tipo de correlação entre as observações dentro dos sujeitos que pode não seguir um padrão uniforme e homocedástico.

Modelos mais gerais de covariância (dentro de sujeitos): Independência, Uniforme (simetria composta, permutável), autocorrelação, não estruturada.

Dados Longitudinais

Estruturas de Covariância e Correlação entre observações no mesmo nível de um “fator”

$$Cov = \begin{pmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \dots & 0 & \dots & \dots \\ 0 & 0 & 0 & \sigma^2 \end{pmatrix}; \quad Cor = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Independência e homocedasticidade

$$Cov = \begin{pmatrix} \sigma^2 & \rho\sigma^2 & \dots & \rho\sigma^2 \\ \rho\sigma^2 & \sigma^2 & \dots & \rho\sigma^2 \\ \dots & 0 & \dots & \dots \\ \rho\sigma^2 & \rho\sigma^2 & \dots & \sigma^2 \end{pmatrix}; \quad Cor = \begin{pmatrix} 1 & \rho & \dots & \rho \\ \rho & 1 & \dots & \rho \\ \dots & \dots & \dots & \dots \\ \rho & \rho & \dots & 1 \end{pmatrix}$$

Uniforme (permutável, simetria composta)

$$Cov = \begin{pmatrix} \sigma^2 & \rho\sigma^2 & \dots & \rho^{t-1}\sigma^2 \\ \rho\sigma^2 & \sigma^2 & \dots & \rho^{t-2}\sigma^2 \\ \dots & 0 & \dots & \dots \\ \rho\sigma^2 & \rho\sigma^2 & \dots & \sigma^2 \end{pmatrix}; \quad Cor = \begin{pmatrix} 1 & \rho & \dots & \rho^{t-1} \\ \rho & 1 & \dots & \rho^{t-2} \\ \dots & \dots & \dots & \dots \\ \rho & \rho & \dots & 1 \end{pmatrix}$$

Autocorrelação

$$Cov = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1t} \\ & \sigma_{22} & \dots & \sigma_{2t} \\ \sim & & \dots & \dots \\ & & & \sigma_{tt} \end{pmatrix}; \quad Cor = \begin{pmatrix} 1 & \rho_{12} & \dots & \rho_{1p} \\ & 1 & \dots & \rho_{2p} \\ \sim & & \dots & \dots \\ & & & 1 \end{pmatrix}$$

Não Estruturada

Dados Longitudinais

Tipo de Propaganda	Ponto de Venda	Período de Tempo		
		T1	T2	T3
A1	1	958	1047	933
	2	1005	1122	986
	3	351	436	339
	4	549	632	512
	5	730	784	707
A2	6	780	897	718
	7	229	275	202
	8	883	964	817
	9	624	695	599
	10	375	436	351

Tabela de ANOVA


	npar	Sum Sq	Mean Sq	F value
factor(A)	1	263	263	0.733
factor(temp)	2	67073	33537	93.686
factor(A) : factor(temp)	2	391	196	0.546

Efeitos Aleatórios

Groups	Name	Variance	Std.Dev.
ue	(Intercept)	76284	276.20
Residual		358	18.92

IC Bootstrap

	2.5 %	97.5 %
.sig01	158.86962	452.743546
.sigma	11.64586	24.428591
(Intercept)	482.31009	953.999558
factor(A) 2	-490.79094	218.344657
factor(temp) 2	62.58739	108.872318
factor(temp) 3	-47.42476	2.960969
factor(A) 2 : factor(temp) 2	-43.59394	22.059591
factor(A) 2 : factor(temp) 3	-51.72853	15.861192



O efeito de interação não é significativo


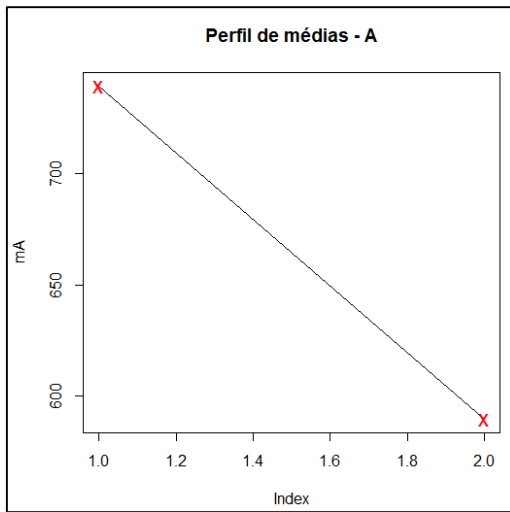


Tabela de ANOVA

	npair	Sum Sq	Mean Sq	F value
factor(A)	1	249	249	0.7336
factor(temp)	2	67073	33537	98.6541

Efeito Aleatório

Groups	Name	Variance	Std.Dev.
ue	(Intercept)	76290.1	276.21
Residual		339.9	18.44

IC Bootstrap

	2.5 %	97.5 %
.sig01	148.34683	433.26199
.sigma	12.32876	23.78043
(Intercept)	469.13611	965.17837
factor(A) 2	-477.83692	196.09751*
factor(temp) 2	64.28092	97.25089
factor(temp) 3	-47.62181	-15.80675

Fator Temp

Contrast	estimate	SE	df	t.ratio	p.value
1 - 2	-80.4	8.25	18	-9.751	<.0001
1 - 3	32.0	8.25	18	3.881	0.0030
2 - 3	112.4	8.25	18	13.632	<.0001

- Não há efeito significativo de A*
- Há efeito significativo de Temp: $\mu_2 > \mu_1 > \mu_3$