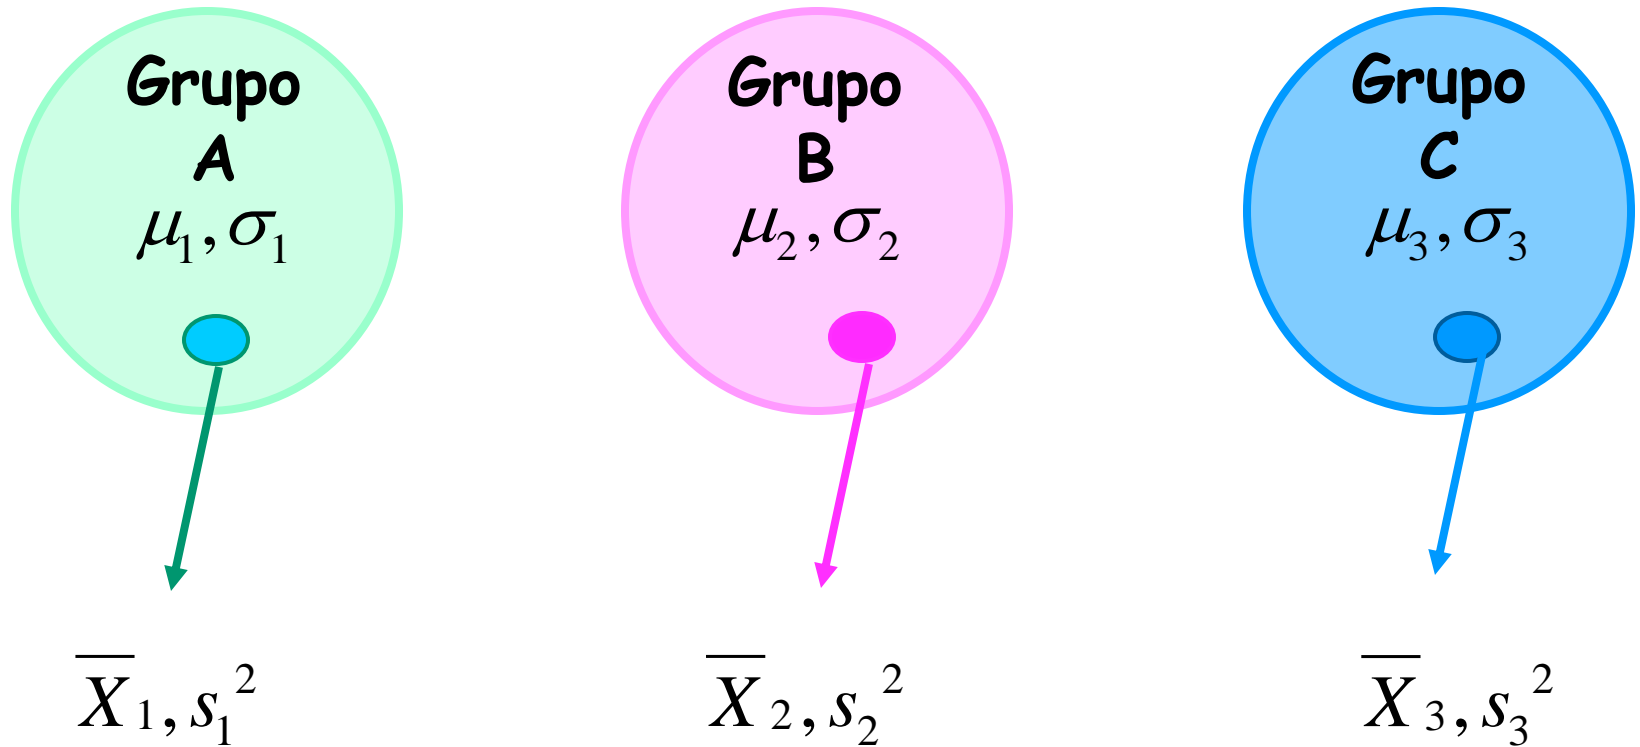


8. Análise de variância

USP – ICMC – SME

2013

Comparando três populações



Populações independentes e normalmente distribuídas.

Como comparar as médias?

Teste z ou t duas a duas:

Para 3 amostras teremos $\binom{3}{2} = \frac{3!}{2!1!} = 3 \text{ testes}$

Para 6 amostras teremos $\binom{6}{2} = \frac{6!}{2!4!} = 15 \text{ testes}$

Problemas ...

- A quantidade de testes “explode”, quando a quantidade de amostras aumenta.
- A condução de múltiplos testes t para duas amostras, duas a duas, pode levar a uma conclusão incorreta.

Suponha que $\mu_1 = \mu_2 = \mu_3$ e $\alpha = 0,05$ em cada teste t .
Então, supondo independência entre os testes,


$$p(\text{conclusão correta em todos os testes}) = 0,95^3 = 0,857$$

e

$$p(\text{rejeitar } H_0 \text{ em pelo menos um teste}) = 1 - 0,857 = 0,143.$$

Portanto, ao realizar múltiplos testes t , aumentamos a probabilidade de cometer um erro do tipo I.

Deseja-se um teste para comparar as diversas médias, no qual a probabilidade de cometermos um erro tipo I seja igual a um valor predeterminado α .



ANOVA


Exemplo 1

Um experimento foi conduzido com a finalidade de verificar se existem diferenças significativas entre as médias da dureza de peças de aço (em HB) de quatro fornecedores (A, B, C e D).

	Fornecedor de aço				
	A	B	C	D	
	64	78	75	55	
	72	91	93	66	
	68	97	78	49	
	77	82	71	64	
	56	85	63	70	
	95	77	76	68	
Total	432	510	456	372	1770
Média	72	85	76	62	73.75

Exemplo 1

Desenho esquemático da medida de dureza das molas produzidas com o aço de cada fornecedor .



- Existe uma forte suspeita de que há diferença entre os quatro fornecedores.
- Distribuições assimétricas.
- Valor discrepante.

Modelo de análise de variância (ANOVA)

Para descrever situações como apresentado neste exemplo, adota-se o modelo

$$y_{ij} = \mu_i + \varepsilon_{ij} = \underbrace{\mu + \tau_i}_{\mu_i} + \varepsilon_{ij} \quad \begin{array}{l} i=1,2,\dots,4, \\ j=1,2,\dots,6. \end{array}$$

y_{ij} é a j -ésima medida de dureza das molas produzidas com o aço do i -ésimo fornecedor.

μ_i é média do i -ésimo fornecedor,

μ é uma constante para todas as observações (média geral),

τ_i é o efeito do i -ésimo fornecedor e

ε_{ij} é o erro aleatório (combina erros de medida, fatores não controláveis, diferenças entre as unidades experimentais, etc.).

Objetivo: Testar se existem diferenças entre as durezas médias do aço vendido pelos quatro fornecedores .

Hipóteses: $H_0: \mu_1 = \mu_2 = \dots = \mu_4 = \mu$

$H_1: \mu_i \neq \mu_j$ para pelo menos um par (i,j) sejam diferentes, $(i \neq j = 1, 2, 3, 4)$.

Em geral,

Dados gerais de um experimento com um único fator								
Tratamentos (níveis)	Observações						Totais	Médias
1	y_{11}	y_{12}	.	.	.	y_{1r}	$y_{1.}$	\bar{y}_1
2	y_{21}	y_{22}	.	.	.	y_{2r}	$y_{2.}$	\bar{y}_2
.
.
a	y_{a1}	y_{a2}	.	.	.	y_{ar}	$y_{a.}$	\bar{y}_a

Modelo estatístico (one-way):

$$y_{ij} = \mu_i + \varepsilon_{ij} = \underbrace{\mu + \tau_i}_{\mu_i} + \varepsilon_{ij} \quad \begin{array}{l} i=1,2,\dots,a, \text{ (tratamentos)} \\ j=1,2,\dots,r \text{ (observações)} \end{array}$$

y_{ij} é a j -ésima observação do i -ésimo tratamento,

μ_i é média do i -ésimo tratamento ,

μ é uma constante para todas as observações (média geral),

τ_i é o efeito do i -ésimo tratamento e

ε_{ij} é o erro aleatório (erros de medida, fatores não controláveis, diferenças entre as unidades experimentais, etc.).

Suposições:

- 1) os erros aleatórios são independentes,
- 2) os erros aleatórios são *normalmente* distribuídos
- 3) e os erros aleatórios têm média 0 e variância σ^2 ,

ou seja, $y_{ij} \sim N(\mu + \tau_i; \sigma^2)$ e independentes.

Hipóteses: $H_0: \mu_1 = \mu_2 = \dots = \mu_a = \mu$

$H_1: \mu_i \neq \mu_j$ para pelo menos um par (i,j) , $i \neq j$.

Equivalentemente,

Hipóteses: $H_0: \tau_1 = \tau_2 = \dots = \tau_a = 0$

$H_1: \tau_i \neq 0$ para pelo menos um i .

Análise de Variância

A denominação análise de variância resulta de decompor a variabilidade total dos dados em suas componentes. A soma de quadrados totais (SQT) em relação à média

$$SQT = \sum_{i=1}^a \sum_{j=1}^r (y_{ij} - \bar{y}_{..})^2,$$

é usada como medida de variabilidade total dos dados.

Pode-se mostrar que a soma de quadrados total pode ser escrita como

$$\underbrace{\sum_{i=1}^a \sum_{j=1}^r (y_{ij} - \bar{y}_{..})^2}_{SQT} = \underbrace{r \sum_{i=1}^a (\bar{y}_{i.} - \bar{y}_{..})^2}_{SQ_{trat}} + \underbrace{\sum_{i=1}^a \sum_{j=1}^r (y_{ij} - \bar{y}_{i.})^2}_{SQ_E}.$$

$$SQT = SQ_{Trat} + SQ_E.$$

Graus de liberdade:

SQT tem $ar-1$ graus de liberdade; SQTrat tem $a-1$ g.l. e SQE tem $a(r-1)$ g.l.

**Quadrados
médios:**

$$QMTrat = \frac{SQTrat}{a-1}$$

$$QME = \frac{SQE}{a(r-1)}$$

Esperanças dos quadrados médios:

$$E(QME) = \sigma^2$$

$$E(QMTrat) = \sigma^2 + \frac{r \sum_{i=1}^a \tau_i^2}{a-1}$$

Observação.

- Um estimador de σ^2 é QME.
- Se não houver diferenças no nível médio dos tratamentos, QMtrat proporciona outro estimador para σ^2 .
- Entretanto, se observamos diferenças na média dos tratamentos, $E(\text{QMtrat}) > \sigma^2$.

- $\varepsilon_{ij} \sim NID(0; \sigma^2)$
- $y_{ij} \sim NID(\mu + \tau_i; \sigma^2)$
- $y_{i.} = \sum_{j=1}^r y_{ij} \sim NID(r\mu + r\tau_i; r\sigma^2);$
- $\bar{y}_{i.} = \frac{\sum_{j=1}^r y_{ij}}{r} \sim NID(\mu + \tau_i; \sigma^2 / r);$
- $W_1 = \frac{SQE}{\sigma^2} \sim \chi^2_{(a(r-1))};$
- $W_2 = \frac{SQtrat}{\sigma^2} \sim \chi^2_{(a-1)};$
- W_1 e W_2 são independentes.

NID significa normal e identicamente distribuída.

Hipóteses: $H_0: \mu_1 = \mu_2 = \dots = \mu_a$

$H_1: \mu_i \neq \mu_j$ para pelo menos um par (i,j) , $i \neq j$.

Estatística de teste:

$$F_0 = \frac{SQ_{trat} / (a - 1)}{SQE / a(r - 1)} = \frac{QM_{trat}}{QME} \underset{sob H_0}{\sim} F(a - 1, a(r - 1))$$

Se $F_0 > F_{\alpha, a-1, a(r-1)}$ rejeita-se H_0 .

Tabela da análise de variância de um experimento com um fator.

Valor p

Fontes de variação	Soma de quadrados	Graus de liberdade	Quadrados médios	F_0
Entre tratamentos	$SS_{\text{Tratamentos}}$	a-1	$QM_{\text{Tratamentos}}$	$\frac{QM_{\text{Tratamentos}}}{QM_{\text{Erro}}}$
Erro	SS_{Erro}	N-a	QM_{Erro}	
Total	SS_T	N-1		

$N = an$

Exemplo: Considerando o exemplo 1, temos

	Tratamentos (fornecedores)					
	A	B	C	D		
	64	78	75	55	a = 4	
	72	91	93	66	r = 6	
	68	97	78	49	ar = 24=n	
	77	82	71	64		
	56	85	63	70		
	95	77	76	68		
Total ($y_{i.}$)	432	510	456	372	1770	$y_{..}$
Média ($\bar{y}_{i.}$)	72	85	76	62	73.75	$\bar{y}_{..}$
$\sum_j y_{ij}^2$	31994	43652	35144	23402	134192	$\sum_{i,j} y_{ij}^2$

Exemplo 1

$$SQT = 134192 - \underbrace{\frac{(1770)^2}{24}}_{FC} = 134192 - 130558 = 3654,$$


$$SQTrat = \frac{432^2 + 510^2 + 456^2 + 372^2}{6} - FC = 132174 - 130559 = 1636$$

$$\text{e } SQE = SQT - SQTrat = 3654 - 1636 = 2018.$$

Fontes de variação	GL	SQ	QM	F
Fornecedores (entre fornecedores)	3	1636	545,3	5,40**
Erro experimental (intra-fornecedores)	20	2018	100,9	
Total	23	3654		

$$F_{0.01;3,20} = 4,94$$

** Significativo a 1%.



$$F_0 = 5.40 > F_{0.01; 3, 20} = 4.94$$

A diferença entre médias de tratamentos é significativa ($p < 0.01$). Rejeita-se H_0 .

Conclusão

Os quatro fornecedores se diferenciam em termos da medida de dureza do aço vendido a um nível de significância de 1%.


```
>dados = read.table("anovaplicada.txt", header = T)
attach(dados)
# Gráfico de caixas (boxplot)
>boxplot(dureza ~ fornecedor, xlab = "Fornecedor", ylab = "Dureza")
# Tabela de ANOVA
>fit = aov(dureza ~ fornecedor, dados)
> anova(fit)
```

Analysis of Variance Table

Response: dureza

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
fornecedor	3	1636.5	545.5	5.4063	0.006876 **
Residuals	20	2018.0	100.9		


Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Modelo de ANOVA com um fator desbalanceado

Exemplo 2. Um departamento governamental está preocupado com os aumentos dos custos dos projetos encomendados aos institutos A, B, C e D. Por esse motivo, decidiu analisar os custos associados a diferentes projetos, calculando, para cada um deles, a razão entre o custo final incorrido e o custo inicialmente previsto. Para cada projeto, ambos custos foram expressos em uma base constante.

Relação custos incorridos/custos previstos em projetos realizados pelos institutos A, B, C e D.

Instituto A	Instituto B	Instituto C	Instituto D
1,0	1,7	1,0	3,8
0,8	2,5	1,3	2,8
1,9	3,0	3,2	1,9
1,1	2,2	1,4	3,0
2,7	3,7	1,3	2,5
	1,9	2,0	



Obs. O gráfico é apenas ilustrativo, pois os números de observações são pequenos. Qual gráfico você sugere? (vide também lâmina 7).

Modelo estatístico (unbalanced one-way)

$$y_{ij} = \mu_i + \varepsilon_{ij} = \underbrace{\mu + \tau_i}_{\mu_i} + \varepsilon_{ij} \quad \begin{array}{l} i=1,2,\dots,a, \text{ (tratamentos)} \\ j=1,2,\dots,r_i \text{ (observações)} \end{array}$$

y_{ij} é a j -ésima observação do i -ésimo tratamento,

μ_i é média do i -ésimo tratamento,

μ é uma constante para todas as observações (média geral),

τ_i é o efeito do i -ésimo tratamento

e ε_{ij} é o erro aleatório,

com a restrição $\sum_{i=1}^a r_i \tau_i = 0$.

Os estimadores de mínimos quadrados de μ e α_i são obtidos minimizando

$$Q = \sum_{i=1}^a \sum_{j=1}^{r_i} \varepsilon_{ij}^2 = \sum_{i=1}^a \sum_{j=1}^{r_i} (Y_{ij} - \mu - \tau_i)^2 \quad (*)$$

Ao derivar a equação (*) em relação a μ e α_i e igualar a zero, obtemos

$$-2 \sum_{i=1}^a \sum_{j=1}^{r_i} (Y_{ij} - \hat{\mu} - \hat{\tau}_i) = 0,$$

$$-2 \sum_{j=1}^{r_i} (Y_{ij} - \hat{\mu} - \hat{\tau}_i) = 0, \quad i = 1, \dots, a$$

Após simplificar, obtemos as equações normais

$$\begin{aligned}
 N\hat{\mu} + r_1\hat{\tau}_1 + r_2\hat{\tau}_2 + \cdots + r_a\hat{\tau}_a &= Y_{..} \\
 N\hat{\mu} + r_1\hat{\tau}_1 &= Y_{1.} \\
 N\hat{\mu} + r_2\hat{\tau}_2 &= Y_{2.} \\
 \vdots &\vdots \\
 N\hat{\mu} + r_a\hat{\tau}_a &= Y_{a.}
 \end{aligned}$$

sendo $N = \sum_{i=2}^a r_i$, $Y_{..} = \sum_{i=1}^a \sum_{j=1}^{r_i} Y_{ij}$, e $Y_{i.} = \sum_{j=1}^{r_i} Y_{ij}$

Ao usar a restrição restrição $\sum r_i \alpha = 0$, as soluções das equações normais são

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

$$\hat{\tau}_i = \bar{Y}_{i.} - \bar{Y}_{..}, \quad i = 1, \dots, a$$

$$\hat{\mu}_i = \bar{Y}_{i.}, \quad i = 1, \dots, a$$

em que
$$\bar{Y}_{..} = \frac{\sum_{i=1}^a \sum_{j=1}^{r_i} Y_{ij}}{N}.$$

Considerando o exemplo 2, as estimativas dos parâmetros do modelo são

$$\hat{\mu}_1 = \bar{Y}_{1\bullet} = (1,0 + 0,8 + 1,9 + 1,1 + 2,7) / 5 = 1,5$$

$$\hat{\mu}_2 = \bar{Y}_{2\bullet} = (1,7 + 2,5 + 3,0 + 2,2 + 3,7 + 1,9) / 6 = 2,5$$

$$\hat{\mu}_3 = \bar{Y}_{3\bullet} = (1,0 + 1,3 + 3,2 + 1,4 + 1,3 + 2,0) / 6 = 1,7$$

$$\hat{\mu}_4 = \bar{Y}_{4\bullet} = (3,8 + 2,8 + 1,9 + 3,0 + 2,5) / 5 = 2,8$$

$$\hat{\mu} = \bar{Y}_{\bullet\bullet} = 2,12$$

$$\hat{\tau}_1 = 1,5 - 2,12 = -0,62$$

$$\hat{\tau}_2 = 2,5 - 2,12 = 0,38$$

$$\hat{\tau}_3 = 1,7 - 2,12 = -0,42$$

$$\hat{\tau}_4 = 2,8 - 2,12 = 0,67$$

Análise de variância

A denominação de análise de variância resulta de decompor a variabilidade total dos dados em suas componentes. A soma de quadrado total (SQT) corrigido pela média global ,

$$SQT = \sum_{i=1}^a \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{..})^2,$$

usa-se como medida de variabilidade total dos dados.

Pode-se mostrar que a soma de quadrados total pode ser escrita como

$$\underbrace{\sum_{i=1}^a \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{..})^2}_{SQT} = \underbrace{\sum_{i=1}^a r_i (\bar{y}_{i.} - \bar{y}_{..})^2}_{SQ_{trat}} + \underbrace{\sum_{i=1}^a \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i.})^2}_{SQ_E}$$

$$SQT = SQ_{Trat} + SQ_E.$$

$$SQE = \sum_{i=1}^a \sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i\bullet})^2 = \sum_{i=1}^a \left[\sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i\bullet})^2 \right]$$

$$S_i^2 = \frac{\sum_{j=1}^{r_i} (y_{ij} - \bar{y}_{i\bullet})^2}{r_i - 1}, \quad i = 1, \dots, a$$

$$SQE = \sum_{i=1}^a (r_i - 1) S_i^2$$

$$QME = \frac{QME}{N - a} = \frac{\sum_{i=1}^a (r_i - 1) S_i^2}{\sum_{i=1}^a (r_i - 1)} \quad (\text{Variância ponderada})$$

Graus de liberdade:

SQT tem $N-1$ graus de liberdade; SQTrat tem $a-1$ g.l. e SQE tem $N-a$ g.l.

**Quadrados
médios:**

$$QMTrat = \frac{SQTrat}{a-1}$$

$$QME = \frac{SQE}{N-a}$$

Esperanças dos quadrados médios:

$$E(QME) = \sigma^2$$

$$E(QMTrat) = \sigma^2 + \frac{\sum_{i=1}^a r_i \tau_i^2}{a-1}$$

Hipóteses: $H_0: \mu_1 = \mu_2 = \dots = \mu_a$

$H_1: \mu_i \neq \mu_j$ para pelo menos um par (i,j)

Estatística de teste:

$$F_0 = \frac{SQ_{trat} / (a - 1)}{SQE / (N - a)} = \frac{QM_{trat}}{QME} \underset{sob H_0}{\sim} F(a - 1, a(r - 1))$$

Se $F_0 > F_{\alpha, a-1, N-a}$ rejeita-se H_0 .

Tabela da análise de variância de um experimento com um fator.

Fontes de variação	Soma de quadrados	Graus de liberdade	Quadrados médios	F_0
Entre tratamentos	$SS_{\text{Tratamentos}}$	a-1	$QM_{\text{Tratamentos}}$	$\frac{QM_{\text{Tratamentos}}}{QM_{\text{Erro}}}$
Erro	SS_{Erro}	N-a	QM_{Erro}	
Total	SS_T	N-1		

Considerando os dados do exemplo 2:

	Instituto A	Instituto B	Instituto C	Instituto D	
	1,0	1,7	1,0	3,8	
	0,8	2,5	1,3	2,8	
	1,9	3,0	3,2	1,9	
	1,1	2,2	1,4	3,0	
	2,7	3,7	1,3	2,5	
		1,9	2,0		
Total $Y_{i.}$	7,5	15,0	10,2	14,0	$Y_{..} = 46,7$
Média $Y_{i.}$	1,5	2,5	1,7	2,8	$Y_{..} = 2,12$

$$SQT = \sum_{i=1}^a \sum_{j=1}^{r_i} Y_{ij}^2 - \frac{Y_{..}^2}{N}$$

$$= 1,0^2 + 0,8^2 + \dots + 2,5^2 - \frac{46,7^2}{22} = 16,619.$$

$$SQ_{trat} = \sum_{i=1}^4 \frac{Y_{i\cdot}^2}{r_i} - \frac{Y_{\cdot\cdot}^2}{N}$$

$$= \frac{(7,5)^2}{5} + \frac{(15,0)^2}{6} + \frac{(10,2)^2}{4} + \frac{(14,0)^2}{5} - \frac{(46,7)^2}{22} = 6,159$$

$$SQE = SQT - SQ_{trt} = 16,619 - 6,159 = 10,46$$

Fontes de variação	GL	SQ	QM	F
Tratamento (entre institutos)	3	6,159	2,053	3,533*
Erro experimental (intra-institutos)	18	10,460	0,581	
Total	22	16,619		

$$F_{0,01;3,18} = 3,16$$

*Significativo a um nível de 5%.

Conclusão

Concluimos que os institutos têm comportamentos diferentes no que diz respeito à relação custos incorridos/custos previstos dos projetos realizados.

Diagnóstico do modelo

Verificar se as suposições básicas do modelo são válidas. Isso é realizado através de uma análise de resíduos. Define-se o resíduo da ij -ésima observação como

$$e_{ij} = y_{ij} - \hat{y}_{ij},$$

em que $\hat{y}_{ij} = \hat{\mu} + \hat{\tau}_i = \bar{y}_i$ é o valor predito pelo modelo.


Resíduo padronizado:

$$d_{ij} = \frac{e_{ij}}{\sqrt{QME}}.$$


Suposição de normalidade

Utilizamos o gráfico normal de probabilidades para os resíduos padronizados. Sob normalidade dos erros, este gráfico deve apresentar uma forma de reta.


Normal Q-Q Plot



Plot dos residuos vs valores ajustados



Plot dos residuos Padronizados vs valores ajustados



```
## Análise de resíduos
V_ajustados = fitted(fit)      # Valores preditos
res = residuals(fit)          # Valores residuais
padr = rstandard(fit)         # Valores residuais padronizados
# Gráfico de probabilidade
qqnorm(res, pch = 20)
qqline(res)
## Gráfico de valores preditos e resíduos
plot(V_ajustados, res, pch = 20, ylab = "Residuos", xlab = "Valores ajustados")
abline(h = 0, lty = 2)
title(main=" Plot dos residuos vs valores ajustados")
```

Contraste

No [Exemplo 1](#) a hipótese nula foi rejeitada. Deseja-se saber entre quais fornecedores há diferença. Por exemplo, tem-se interesse em verificar se as durezas médias obtidas com o aço dos fornecedores A e D são diferentes.

$$H_0 : \mu_1 = \mu_4$$

$$H_1 : \mu_1 \neq \mu_4$$

Equivalentemente,

$$H_0 : \mu_1 - \mu_4 = 0$$

$$H_1 : \mu_1 - \mu_4 \neq 0$$

Suponha que tem-se interesse em verificar se a dureza média dos itens produzidos com o aço dos fornecedores A e B conjuntamente são as mesmas que a dos fornecedores C e D.

$$H_0 : \mu_1 + \mu_2 = \mu_3 + \mu_4 \Rightarrow H_0 : \mu_1 + \mu_2 - \mu_3 - \mu_4 = 0$$

$$H_1 : \mu_1 + \mu_2 \neq \mu_3 + \mu_4 \Rightarrow H_1 : \mu_1 + \mu_2 - \mu_3 - \mu_4 \neq 0$$

Em geral, um **constraste** é uma combinação linear dos parâmetros da forma

$$\Gamma = \sum_{i=1}^a c_i \mu_i$$

com a restrição $\sum_{i=1}^a c_i = 0$.

As hipóteses acima podem ser escritas em termos de contrastes:.

$$H_0 : \sum_{i=1}^a c_i \mu_i = 0$$

$$H_1 : \sum_{i=1}^a c_i \mu_i \neq 0$$

Uma estimador dos contrastes é dado por

$$C = \sum_{i=1}^a c_i \bar{Y}_i.$$

A variância de C é

$$Var(C) = \frac{\sigma^2}{r} \sum_{i=1}^a c_i^2$$

quando os dados são balanceados.

Sob H_0 ,

$$Z_0 = \frac{\sum_{i=1}^a c_i \bar{Y}_i}{\sqrt{\frac{\sigma^2}{r} \sum_{i=1}^a c_i^2}} \sim N(0,1).$$

Como σ^2 é desconhecido, seu estimador é QME. Sob H_0 ,

$$t_0 = \frac{\sum_{i=1}^a c_i \bar{Y}_i}{\sqrt{\frac{QME}{r} \sum_{i=1}^a c_i^2}} \sim t_{N-a}.$$

Intervalo de confiança para contrastes

$$\Gamma = \sum_{i=1}^a c_i \mu_i$$

$$C = \sum_{i=1}^a c_i \bar{Y}_{i\bullet}$$

$$E(C) = E\left[\sum_{i=1}^a c_i \bar{Y}_{i\bullet}\right] = \sum_{i=1}^a c_i \mu_i \quad \text{e} \quad \text{Var}(C) = \frac{\sigma^2}{r} \sum_{i=1}^a c_i^2$$

$$t = \frac{\sum_{i=1}^a c_i \bar{Y}_{i\bullet} - \sum_{i=1}^a c_i \mu_i}{\sqrt{\frac{QME}{r} \sum_{i=1}^a c_i^2}}$$

Intervalo de 100(1- α)% confiança para o contraste C:

$$\sum_{i=1}^a c_i \bar{Y}_i \pm t_{\alpha/2, N-a} \sqrt{\frac{QME}{r} \sum_{i=1}^a c_i^2}.$$

Método de Scheffe para comparar todos os contrastes

Suponha um conjunto de m contrastes

$$\Gamma_j = c_{1j}\mu_1 + c_{2j}\mu_2 + \cdots + c_{aj}\mu_a, \quad j = 1, \cdots, m.$$

Os estimadores dos contrastes são

$$C_j = c_{1j}\bar{Y}_{1\bullet} + c_{2j}\bar{Y}_{2\bullet} + \cdots + c_{aj}\bar{Y}_{a\bullet}, \quad j = 1, \cdots, m.$$

Erro padrão do estimador do contraste j :

$$SC_j = \sqrt{QME \sum_{i=1}^a c_{ij}^2 / r_i},$$

Em que r_i é o número de observações no i -ésimo tratamento. É possível demonstrar que o valor crítico com o qual C_j deve ser comparado é

$$S_{\alpha,j} = SC_j \sqrt{(a-1)F_{\alpha,a-1,N-a}}.$$

Se $|C_j| > S_{\alpha,u}$ a hipótese nula de que o contraste Γ_u é igual a 0 deve ser rejeitada.

Para ilustrar o procedimento considere os dados do exemplo 1 e suponha que o contraste de interesse é

$$\Gamma_1 : 3\mu_1 - \mu_2 - \mu_3 - \mu_4.$$

Estimativa:

$$C_1 = 3\bar{Y}_{1\bullet} - \bar{Y}_{2\bullet} - \bar{Y}_{3\bullet} - \bar{Y}_{4\bullet}.$$

$$C_1 = 3(72) - 85 - 76 - 62 = -7.$$

Erro padrão:

$$SC_1 = \sqrt{QME \sum_{i=1}^a c_{i1}^2 / r_i} = \sqrt{100,9(9+1+1+1)/6} = 14,2.$$

Valor crítico:

$$S_{0,05,1} = SC_1 \sqrt{(a-1)F_{\alpha,a-1,N-a}} = 14,2 \sqrt{(4-1)(4,3)} = 51,00.$$

Como $|C_1| < S_{0,05;1}$, conclui-se que o contraste Γ_1 é igual a zero a um nível de significância de 5%.

$$H_0 : \mu_i = \mu_j$$

$$H_1 : \mu_i \neq \mu_j, \forall i \neq j$$

Devem ser realizadas após o teste F da análise de variância rejeitar a hipótese nula de igualdade de todas as médias.

Teste de Tukey (1953)

Duas médias são significativamente diferentes se a diferença das médias amostrais (em valor absoluto) for superior a T_α (diferença mínima significativa):

$$T_\alpha = \frac{q_\alpha(a, f)}{\sqrt{2}} \sqrt{QME \left(\frac{1}{r_i} + \frac{1}{r_j} \right)},$$

em que $q_\alpha(a, f)$ é calculado a partir do número de níveis do tratamento (a) e dos graus de liberdade (f).

```
> TukeyHSD(fit, ordered = TRUE)
```

Tukey multiple comparisons of means

95% family-wise confidence level


factor levels have been ordered

Fit: aov(formula = dureza ~ fornecedor, data = dados)

\$Fornecedor

	diff	lwr	upr	p adj
A-D	10	-6.232221	26.23222	0.3378150
C-D	14	-2.232221	30.23222	0.1065573
B-D	23	6.767779	39.23222	0.0039064
C-A	4	-12.232221	20.23222	0.8998057
B-A	13	-3.232221	29.23222	0.1461929
B-C	9	-7.232221	25.23222	0.4270717

95% family-wise confidence level



Comparações com a média de um tratamento controle

Em muitos experimentos, um dos tratamentos é um controle e o pesquisador tem interesse em comparar cada um dos $a-1$ tratamentos restantes com o tratamento controle. Um procedimento para esse caso foi desenvolvido por Dunnett (1964).

$$H_0 : \mu_i = \mu_a$$

$$H_1 : \mu_i \neq \mu_a, i = 1, \dots, a - 1$$

O procedimento de Dunnett é uma modificação do teste t .

Para cada uma das diferenças em H1, obtenha a diferença entre as médias amostrais:

$$|\bar{y}_{i\bullet} - \bar{y}_{a\bullet}|, \quad i = 1, \dots, a - 1$$

A hipótese nula é rejeitado ao nível de significância α se

$$|\bar{y}_{i\bullet} - \bar{y}_{a\bullet}| > d_{\alpha}(a-1, f) \sqrt{\text{QME}(1/r_i + 1/r_a)},$$

sendo que a constante $d_{\alpha}(a-1, f)$ encontra-se tabelada.