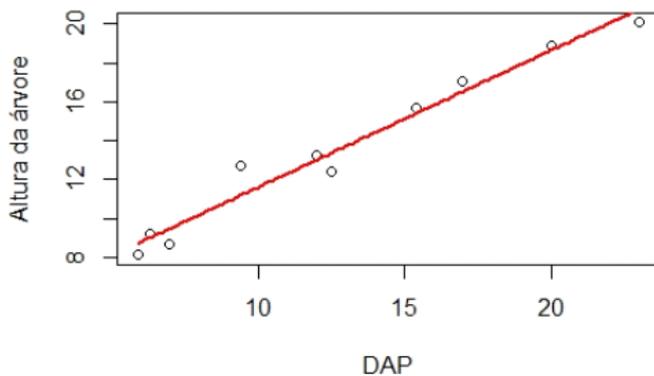


ASSOCIAÇÃO ENTRE VARIÁVEIS QUANTITATIVAS

Ajuste de uma reta

- Equação matemática linear;
- Representação de um conjunto de dados;
- Relação de causa e efeito;
- Interpolação e Extrapolação.



Variáveis:

X ⇒ Variável **Independente**
Y ⇒ Variável **Dependente**

Equação matemática:

$$y = \alpha + \beta x,$$

em que α representa o intercepto e β o coeficiente angular.

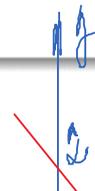
Interpretação prática do parâmetro β : o quanto varia a resposta y para um acréscimo de uma unidade na variável x .

Modelo Estatístico

$$y = \alpha + \beta x + \epsilon$$

(Handwritten red annotations: a cloud around the equation, an arrow pointing to the error term ϵ , and a squiggly line above it.)

Reta ajustada:

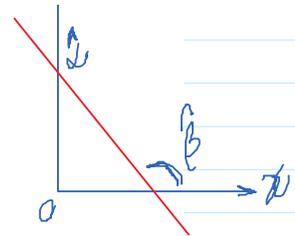


Reta ajustada:

$$\hat{y} = \hat{\alpha} + \hat{\beta}x.$$

ou

$$\hat{y} = a + bx$$



em que $\hat{\alpha}$ (ou a) e $\hat{\beta}$ (ou b) são as estimativas dos parâmetros α e β .

Estimativas pelo método dos mínimos quadrados:

$$\hat{\beta} = \frac{n(\sum_{i=1}^n x_i y_i) - (\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n(\sum_{i=1}^n x_i^2) - (\sum_{i=1}^n x_i)^2}$$

e

$$\hat{\alpha} = \frac{\sum_{i=1}^n y_i - \hat{\beta} \sum_{i=1}^n x_i}{n} = \bar{y} - \hat{\beta} \bar{x},$$

em que n corresponde ao tamanho da amostra.

Exemplo: Considerando-se o exemplo de altura da árvore (Y) e o diâmetro a altura do peito (X):

Tabela: Etapas intermediárias

Observação	x	y	x^2	y^2	xy
1	5,9	8,1	34,8	65,9	47,9
2	6,3	9,2	39,7	84,6	57,9
3	7,0	8,7	49,0	74,9	60,6
4	9,4	12,7	88,4	161,7	119,5
5	12,0	13,2	144,0	174,8	158,6
6	12,5	12,4	156,2	154,0	155,1
7	15,4	15,7	237,2	246,2	241,6
8	17,0	17,0	289,0	290,0	289,5
9	20,0	18,9	400,0	357,4	378,1
10	23,0	20,1	529,0	402,6	461,5
Total	128,5	136,0	1967,23	2011,94	1970,51

$$n = 10$$

$$\hat{\beta} = \frac{n(\sum_{i=1}^n x_i y_i) - (\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n(\sum_{i=1}^n x_i^2) - (\sum_{i=1}^n x_i)^2}$$

$$\hat{\beta} = \frac{10 \cdot 1970,51 - 128,5 \cdot 136,0}{10 \cdot 1967,23 - (128,5)^2}$$

$$\hat{\beta} \approx 0,71$$

$$\sum_{i=1}^{10} x_i$$
$$\sum_{i=1}^{10} x_i \cdot y_i = x_1 y_1 + x_2 y_2 + \dots + x_{10} y_{10}$$

Na calculadora:

$$(10 \times 1970,51 - 128,5 \times 136) \div (10 \times 1967,23 - 128,5^2) =$$

$$\hat{\alpha} = \frac{\sum_{i=1}^n y_i - \hat{\beta} \sum_{i=1}^n x_i}{n} = \bar{y} - \hat{\beta} \bar{x},$$

$$\bar{x} = \frac{128,5}{10} \quad \bar{y} = 12,85$$

$$\bar{y} = \frac{136,0}{10} \quad \bar{y} = 13,6$$

$$\hat{\alpha} = 13,6 - 0,71 \cdot 12,85$$

$$\hat{\alpha} = 4,48$$

$$\hat{y} = \hat{\alpha} + \hat{\beta}x.$$

$$\hat{y} = 4,48 + 0,71x$$

Na calculadora:

$$13,6 - 0,71 \times 12,85 =$$

Conferindo...

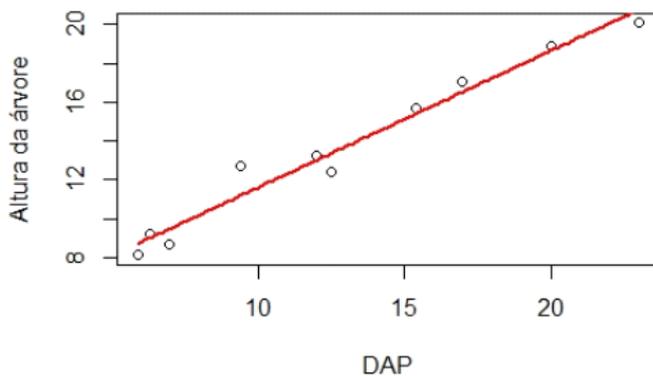
$$\hat{\beta} = \frac{10(1970,51) - (128,5)(136,0)}{10(1967,23) - (128,5)^2} = 0,7053$$

$$\hat{\alpha} = \frac{136,0 - 0,7053(128,5)}{10} = 4,5368$$

Exemplo: Considerando-se o exemplo de altura da árvore (Y) e o diâmetro a altura do peito (X):

Reta ajustada

$$\hat{y}_i = 4,5368 + 0,7053x_i.$$



Verificação da qualidade do ajuste

RESÍDUO:

Diferença entre o valor observado (y_i) e o valor predito (\hat{y}_i), para um determinado valor x_i :

$$e_i = y_i - \hat{y}_i.$$

Tabela: Etapas intermediárias

Observação	x	y	x ²	y ²	xy
1	5,9	8,1	34,8	65,9	47,9
2	6,3	9,2	39,7	84,6	57,9
3	7,0	8,7	49,0	74,9	60,6
4	9,4	12,7	88,4	161,7	119,5
5	12,0	13,2	144,0	174,8	158,6
6	12,5	12,4	156,2	154,0	155,1
7	15,4	15,7	237,2	246,2	241,6
8	17,0	17,0	289,0	290,0	289,5
9	20,0	18,9	400,0	357,4	378,1
10	23,0	20,1	529,0	402,6	461,5
Total	128,5	136,0	1967,23	2011,94	1970,51

$$\hat{y}_i = 4,5368 + 0,7053x_i.$$

resíduo
altura da árvore
DAP

Estime a altura de uma árvore cujo DAP é igual a 25 cm.

$$\hat{y} = 4,5368 + 0,7053 \cdot 25$$
$$\hat{y} = 22,17 \text{ m}$$

O primeiro resíduo (simples) é dado por:

$$e_1 = 8,1 - (4,5368 + 0,7053 \times 5,9) = 8,1 - 8,7 = -0,6$$

Modelo bem ajustado:

é aquele que apresenta resíduos pequenos.

Resíduo simples \Rightarrow depende das unidades de medida

\Downarrow

$$\text{Resíduos Padronizados} \Rightarrow z_i = \frac{e_i}{\sqrt{\sum_{i=1}^n e_i^2 / (n-2)}}$$

Na prática: erro pequeno \Rightarrow resíduo padronizado entre -2 e 2.

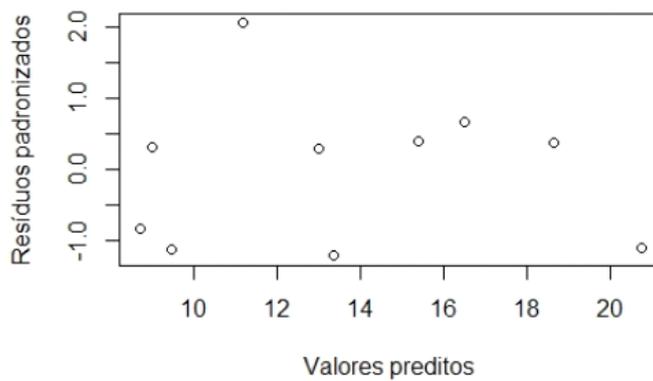


Figura: Gráfico dos valores preditos *versus* resíduos padronizados

Ideal: Gráfico sem padrão!

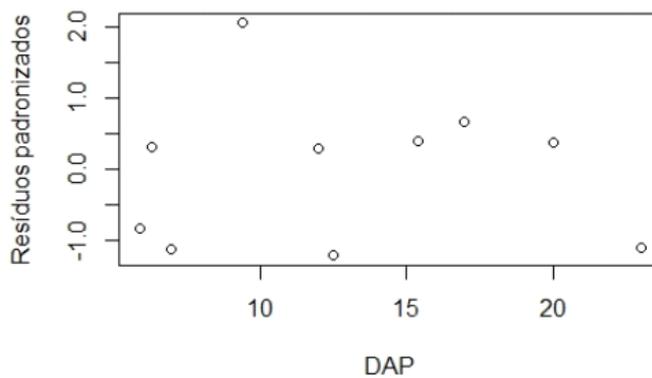


Figura: Gráfico dos valores de DAP *versus* resíduos padronizados

Ideal: Gráfico sem padrão!

ASSOCIAÇÃO ENTRE VARIÁVEIS QUALITATIVAS

Tabelas de contingência

Duas variáveis categorizadas:

- A : com s categorias $\Rightarrow A_1, A_2, \dots, A_s$;
- B : com r categorias $\Rightarrow B_1, B_2, \dots, B_r$.

Tabela: Distribuição conjunta de frequências das variáveis A e B , observados em n elementos

A	B				Total
	B_1	B_2	\dots	B_r	
A_1	n_{11}	n_{12}	\dots	n_{1r}	$n_{1\cdot}$
A_2	n_{21}	n_{22}	\dots	n_{2r}	$n_{2\cdot}$
\cdot	\cdot	\cdot	\dots	\cdot	\cdot
A_s	n_{s1}	n_{s2}	\dots	n_{sr}	$n_{s\cdot}$
Total	$n_{\cdot 1}$	$n_{\cdot 2}$	\dots	$n_{\cdot r}$	n

Exemplo: Na Tabela a seguir apresentamos a distribuição conjunta do comportamento de 59 capivaras com relação ao ambiente.

Tabela: Distribuição conjunta das frequências das variáveis comportamento e ambiente para 59 capivaras

Ambiente	Comportamento		Total
	Agressivo	Não Agressivo	
Restrito	22	5	27
Amplio	20	12	32
Total	42	17	59

Tabela: Distribuição conjunta das frequências das variáveis comportamento e ambiente para 59 capivaras

Ambiente	Comportamento		Total
	Agressivo	Não Agressivo	
Restrito	22	5	27
Amplio	20	12	32
Total	42	17	59

- **Distribuição marginal da variável Ambiente;**
- **Distribuição marginal da variável Comportamento;**

Totais marginais diferentes \Rightarrow difícil visualização da associação



Porcentagens: linhas, colunas, total

Tabela: Distribuição conjunta das frequências das variáveis comportamento e ambiente para 59 capivaras

Ambiente	Comportamento		Total
	Agressivo	Não Agressivo	
Restrito	81,5	18,5	100
Amplio	62,5	37,5	100
Total	71,2	28,8	100

Exemplo: Os dados da tabela a seguir têm por objetivo verificar se os caracteres ciclo (Tardio e Precoce) e virescência (Normal e Virescente), de uma progênie da espécie "X", segregam de forma independente

Tabela: Contagem de plantas segregando para dois caracteres

Ciclo	Virescência		Total
	Normal	Virescente	
Tardio	3470	910	4380
Precoce	1030	290	1320
Total	4500	1200	5700

Fonte: Andrade e Ogliari, 2007

A virescência caracteriza-se pelo desenvolvimento de cloroplastos nas pétalas, resultando no aparecimento de flores verdes

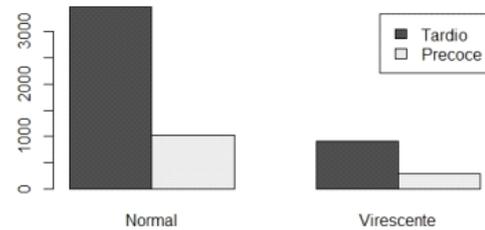


Figura: Contagem de plantas segregando para dois caracteres numa progênie da espécie "X"

Perfis-coluna

Tabela: Contagem de plantas segregando para dois caracteres

Ciclo	Virescência		Total
	Normal	Virescente	
Tardio	77,11%	75,83%	76,84%
Precoce	22,89%	24,17%	23,16%
Total	100%	100%	100%

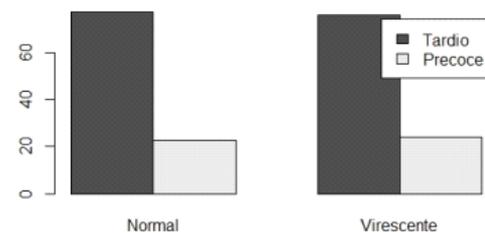


Figura: Distribuição de precocidade segundo a virescência

Exemplo: Os dados da tabela a seguir referem-se às coletas de insetos em armadilhas adesivas de duas cores, em que os indivíduos coletados de uma determinada espécie foram sexados, tendo como objetivo verificar se havia influência da cor da armadilha sobre a atração de machos e fêmeas dessa espécie.

Tabela: Números de insetos coletados em armadilhas adesivas e sexados.

Armadilha	Machos	Fêmeas	Totais
Alaranjada	246	17	263
Amarela	458	32	490
Totais	704	49	753

Fonte: Cordeiro, G.M.; Demétrio, C.G.B. Modelos Lineares Generalizados e Extensões

Tabela: Números de insetos coletados em armadilhas adesivas e sexados.

Armadilha	Machos	Fêmeas	Totais
Alaranjada	246 (32,7%)	17 (2,3%)	263 (36,0%)
Amarela	458 (60,8%)	32 (4,2%)	490 (65,0%)
Totais	704 (93,5%)	49 (6,5%)	753 (100%)

Fonte: Cordeiro, G.M.; Demétrio, C.G.B. Modelos Lineares Generalizados e Extensões

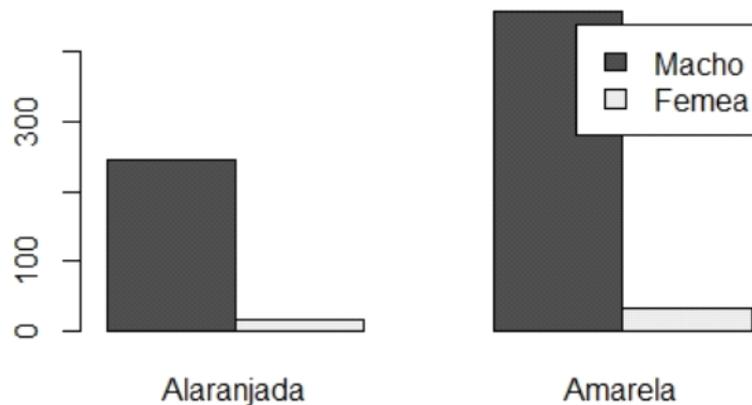


Figura: Gráfico de distribuição conjunta da cor da armadilha e sexagem dos insetos

Exemplo: A tabela a seguir refere-se ao número de pássaros de uma particular espécie, classificados de acordo com o local da floresta onde se alimentam, para duas estações do ano.

Estação do ano	Local da floresta			Total
	Árvores	Arbusto	Chão	
Primavera	30	20	9	59
Outono	13	22	26	61
Total	43	42	35	120

Fonte: Andrade e Ogliari, 2007

Perfil linha:

Estação do ano	Local da floresta			Total
	Árvores	Arbusto	Chão	
Primavera	30 (50,8%)	20 (33,9%)	9 (15,3%)	59 (100%)
Outono	13 (21,3%)	22 (36,1%)	26 (42,6%)	61 (100%)
Total	43 (35,8%)	42 (35,0%)	35 (29,2%)	120 (100%)

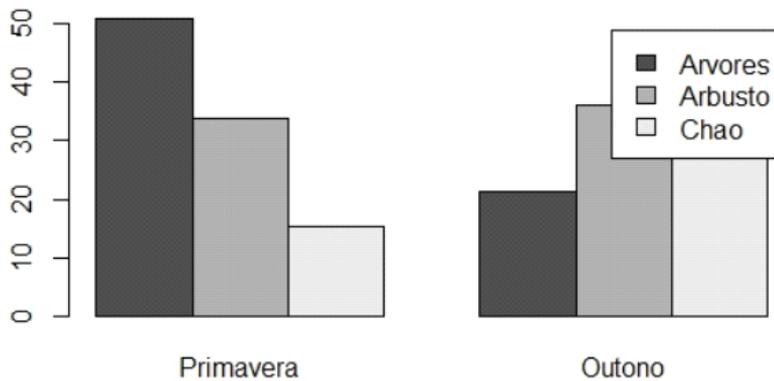


Figura: Associação entre local e estação

Estadística χ^2

Comparar a frequência observada com a frequência esperada!

Frequência esperada

Considerando-se a independência entre as variáveis,

$$fe_{ij} = \frac{n_{i.} \cdot n_{.j}}{n_{..}}$$

$n_{i.}$ → total linha
 $n_{.j}$ → total coluna
 $n_{..}$ → total

Estadística χ^2

$$\chi^2 = \sum_{i=1}^s \sum_{j=1}^r \frac{(n_{ij} - fe_{ij})^2}{fe_{ij}}$$

i → linha
 j → coluna

Considerando o exemplo do hábito alimentar dos pássaros e local

Estação do ano	Local da floresta			Total
	Árvores	Arbusto	Chão	
Primavera	30 (50,8%)	20 (33,9%)	9 (15,3%)	59 (100%)
Outono	13 (21,3%)	22 (36,1%)	26 (42,6%)	61 (100%)
Total	43 (35,8%)	42 (35,0%)	35 (29,2%)	120 (100%)

Estação do ano	Local da floresta			Total
	Árvores	Arbusto	Chão	
Primavera	30	20	9	59
Outono	13	22	26	61
Total	43	42	35	120

Fonte: Andrade e Ogliari, 2007

$$fe_{ij} = \frac{n_i \cdot n_j}{n..}$$

$$\frac{59 \cdot 43}{120} = 21,14$$

$$\frac{59 \cdot 42}{120} = 20,65$$

$$\frac{59 \cdot 35}{120} = 17,21$$

... e assim por diante!

Considerando o exemplo do hábito alimentar dos pássaros e local

⇒ Frequências esperadas

Estação do ano	Local da floresta			Total
	Árvores	Arbusto	Chão	
Primavera	30 (21,14)	20 (20,65)	9 (17,21)	59
Outono	13 (21,86)	22 (21,35)	26 (17,79)	61
Total	43	42	35	120

⇒ Diferenças

Estação do ano	Local da floresta		
	Árvores	Arbusto	Chão
Primavera	8,86	-0,65	-8,21
Outono	-8,86	0,65	8,21

$$\chi^2 = \sum_{i=1}^s \sum_{j=1}^r \frac{(n_{ij} - fe_{ij})^2}{fe_{ij}}$$

$$= \frac{(8,86)^2}{21,14} = 3,7133$$

$$= \frac{(-0,65)^2}{20,65} = 0,0205$$

Estatística:

$$\begin{aligned} \chi^2 &= \frac{(8,86)^2}{21,14} + \frac{(-0,65)^2}{20,65} + \frac{(-8,21)^2}{17,21} + \frac{(-8,86)^2}{21,86} + \frac{(0,65)^2}{21,35} + \frac{(8,21)^2}{17,79} \\ &= 3,7133 + 0,0205 + 3,9166 + 3,5910 + 0,0198 + 3,7889 \\ &= 15,0501 \end{aligned}$$

$\sqrt{15}$ graus quadrados

liberdade = 2

15,0501

χ^2 Qui-Quorum

$L = \text{nr linhas} = 2$

$C = \text{nr colunas} = 3$

$t = \min(L, C) = 2$

Coefficiente de Contingência (Pearson)

$$C = \sqrt{\frac{\chi^2}{\chi^2 + n}}$$

No exemplo:

$$C = \sqrt{\frac{15,0501}{15,0501 + 120}} = 0,3338$$

↓

Existe associação!

Forte ou fraca?



$t = 2$

Depende o limite superior do coeficiente de contingência!!!

$$LSC = \sqrt{(2-1)/2} = 0,707$$

Limite superior de $C \Rightarrow \sqrt{(t-1)/t}$, em que t é o mínimo entre o número de linhas e o número de colunas.

Modificação do coeficiente de contingência

$$C^* = \frac{C}{\sqrt{(t-1)/t}}$$

entre 0 e 1
menor a associação entre as variáveis

No exemplo: $t = 2$,

$$C^* = \frac{0,3338}{0,707} = 0,4721$$

$$C^* = \frac{0,3338}{\sqrt{(2-1)/2}} = 0,4721$$

1^o
Análise

análise
as variáveis

Existe uma associação entre as duas variáveis
mas é de fraca a moderada

ASSOCIAÇÃO ENTRE VARIÁVEIS QUALITATIVAS E QUANTITATIVAS

- Análise da variável quantitativa dentro de cada nível da variável qualitativa:

- medidas resumo
- histogramas
- box plots
- diagrama de ramos e folhas

→ quartis (Q₁, Q₂, Q₃)

Q₂ = mediana

Exemplo: O dados apresentados a seguir correspondem à variável diâmetro da árvore avaliada em duas florestas (Floresta A e Floresta B).

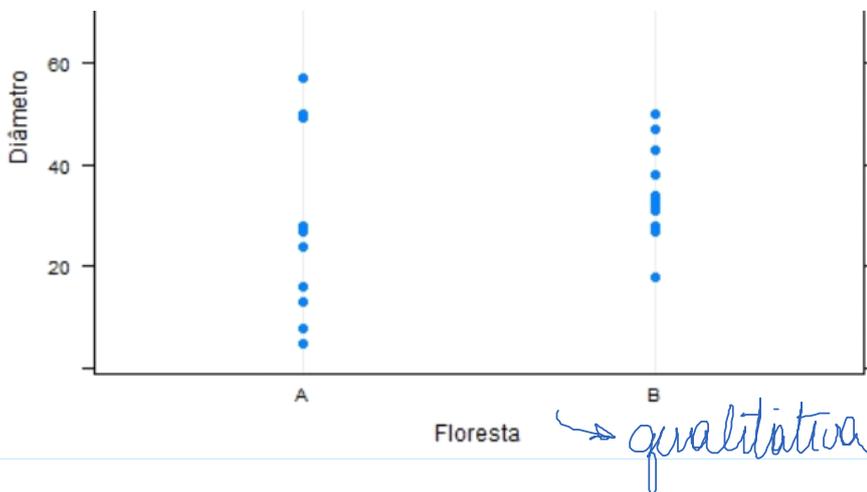
Tabela: Diâmetro das árvores

Floresta A	16	50	13	8	5	77	93
	27	57	28	24	16	49	
Floresta B	38	43	32	18	47	33	38
	27	50	34	34	31	28	

Exemplo: O dados apresentados a seguir correspondem à variável diâmetro da árvore avaliada em duas florestas (Floresta A e Floresta B).



Quantitativa



→ qualitativa

Exemplo: Os dados apresentados na tabela a seguir são referentes ao volume de madeira por árvore de *Eucalyptus camaldulensis*, em $m^3 10^{-4}$. São apresentados os dados de 5 progênes avaliadas.

Tabela: Volume de madeira, em $m^3 10^{-4}$

A	B	C	D	E
212	108	63	175	133
206	194	77	239	106
224	163	100	100	185
289	111	99	104	136
324	236	68	256	147
219	146	76	267	210

Exemplo: Os dados apresentados são referentes ao volume de madeira por árvore de *Eucalyptus camaldulensis*, em $m^3 10^{-4}$. São apresentados os dados de 5 progênes avaliadas.

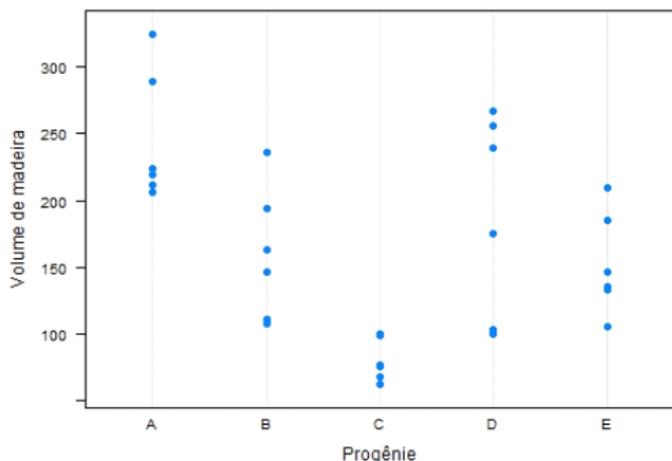


Figura: Gráfico de pontos para a variável volume de madeira por progênia

Exemplo: Os dados apresentados são referentes ao volume de madeira por árvore de *Eucalyptus camaldulensis*, em $m^3 10^{-4}$. São apresentados os dados de 5 progênes avaliadas.

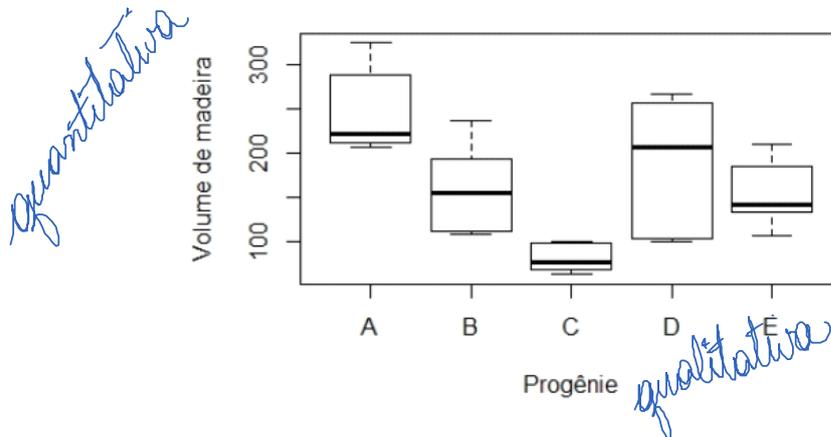


Figura: Box plot para a variável volume de madeira por progênie

Exercícios

Exercício 1:

Considerando o consumo individual diário de proteínas de origem animal, em gramas, e o coeficiente de natalidade, em 14 países.

País	Consumo diário	Coeficiente de Natalidade			
Formosa	4,7	45,6			
Malásia	7,5	39,7			
Índia	8,7	33,0			
Japão	9,7	27,0			
Iugoslávia	11,2	25,9			
Grécia	15,2	23,5			
Itália	15,2	23,4			
Bulgária	16,8	22,2			
Alemanha	37,3	20,0			
Irlanda	46,7	19,1			
Dinamarca	56,1	18,3			
Austrália	59,9	18,0			
Estados Unidos	61,4	17,9			
Suécia	62,6	15,0			

Fonte: VIEIRA, Sônia. **Introdução à Bioestatística**. Rio de Janeiro: Campus, p.80, 1989.

Calcule o coeficiente de correlação de Pearson e escreva o que se pode dizer sobre isso, encontre a equação da reta e estime o coeficiente de natalidade para um país cujo consumo diário de proteína seja igual a 65,0.

Exercício 2: Considerando a prevalência de anemia em catadores de material reciclável no município de Santos em julho de 2005, e o seu consumo de ovos, verifique se existe associação entre essas variáveis. O que se pode dizer com os valores obtidos.

Consumo de Ovos	Anemia		
	Sem anemia	Com anemia	Total
Nunca	42	32	74
1x / semana	25	19	44
2 a 3x /semana	64	30	94
Diariamente	18	11	29
Total	149	92	241

Fonte: PEREZ JUNIOR, Valmir, *et al.* Anemia em catadores de material reciclável que utilizam carrinho de propulsão humana no município de Santos. Santos: Núcleo de Estudos Epidemiológicos, Universidade Católica de Santos, **SciELO - Scientific Electronic Library Online**. 2010. Disponível em: <https://www.scielosp.org/article/rbepid/2010.v13n2/326-336/>. Acesso em: 10 set. 2020.