



UNIVERSIDADE DE SÃO PAULO  
Faculdade de Zootecnia e Engenharia de Alimentos

## ZAB1111 – ESTATÍSTICA BÁSICA

Aula 17

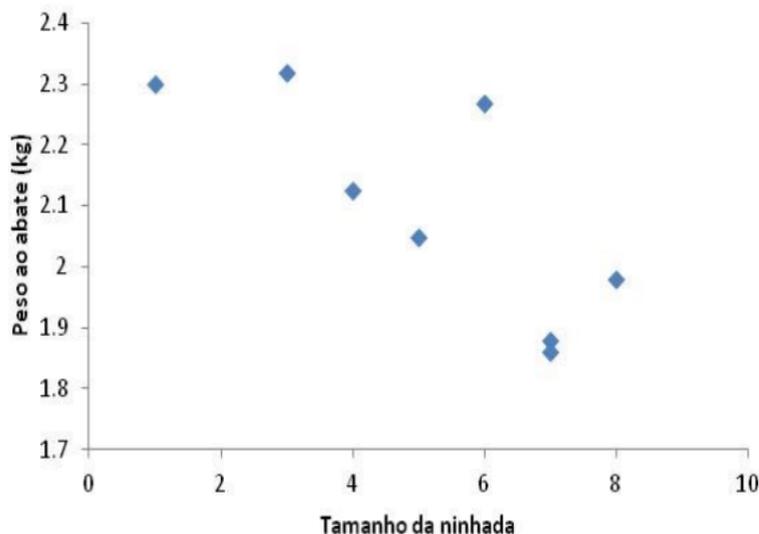
### CORRELAÇÃO E REGRESSÃO LINEAR SIMPLES

A **análise de correlação** visa quantificar o **grau** de relacionamento entre duas variáveis quantitativas, como por exemplo:

- Qual o grau de relacionamento entre o nível energético da ração consumida e o peso dos frangos de corte?
- E entre o número de horas de estudos e a nota de uma avaliação?
- E entre os pesos de frangos de corte avaliados aos 7, 14, 21, 28 e 35 dias de idade nas mesmas aves?
- E entre a o pH do solo e a produção de cana de açúcar?
- E entre a idade de um imóvel e o valor do seu aluguel?
- E entre a estatura dos pais e a estatura dos filhos?

**Ferramenta útil:** gráfico de dispersão!

Exemplo 1. Existe alguma relação entre o peso médio de coelhos ao abate (Y) e o tamanho da ninhada (X)?



O aumento no tamanho da ninhada tende a provocar uma diminuição no peso dos coelhos ao abate.

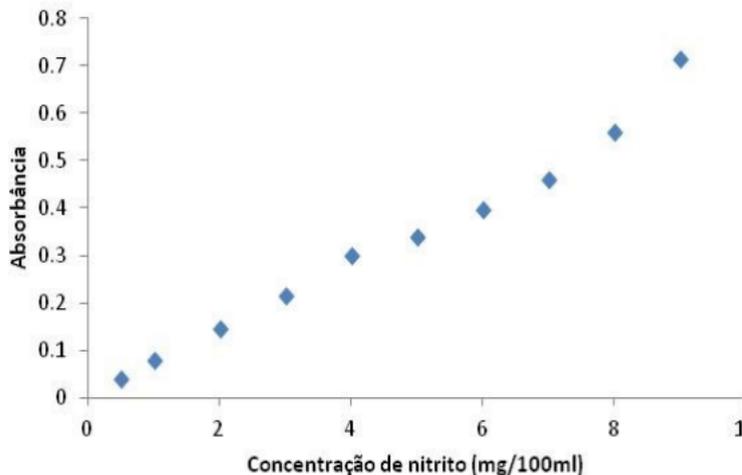
Coelhos de ninhadas maiores tendem a alcançar pesos menores ao abate.

## Correlação linear simples

A **análise de regressão** é um método simples e muito utilizado no estabelecimento de fórmulas empíricas envolvendo duas ou mais variáveis.

- Como expressar o relacionamento entre duas características através de uma fórmula matemática?
- Consigo determinar o valor de uma grandeza, partindo do conhecimento dos valores de outras grandezas?
- Consigo fazer previsões conhecendo a relação funcional entre as variáveis?
- Ferramenta importante: **gráfico de dispersão**.

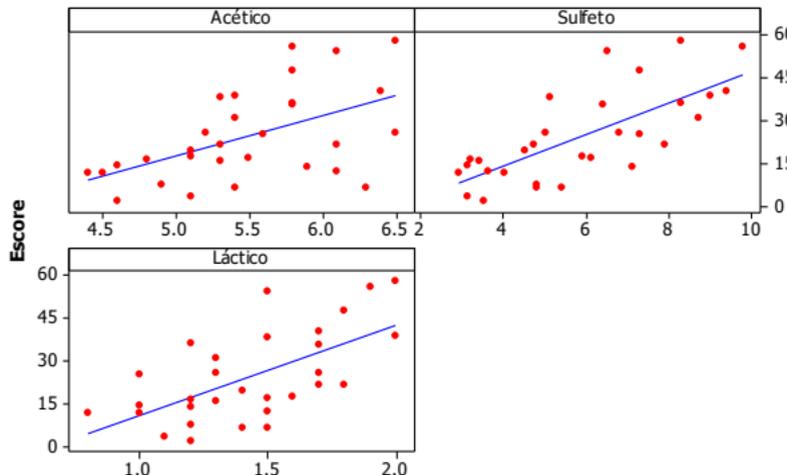
**Exemplo 2 (Regressão linear simples)** Como explicar a relação entre a absorbância (Y) e a concentração de nitrito (X, em mg/100ml) em amostras de mortadela?



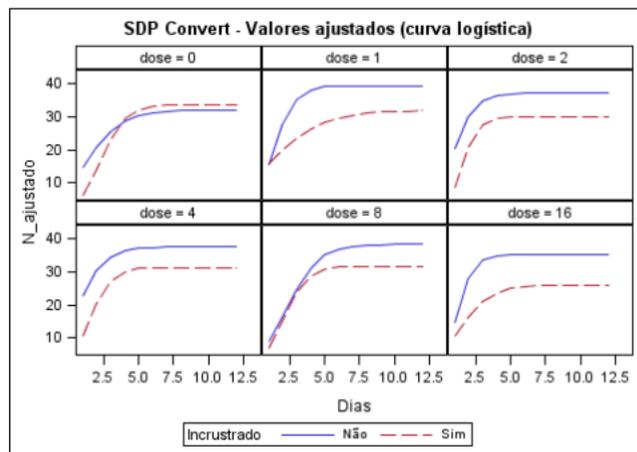
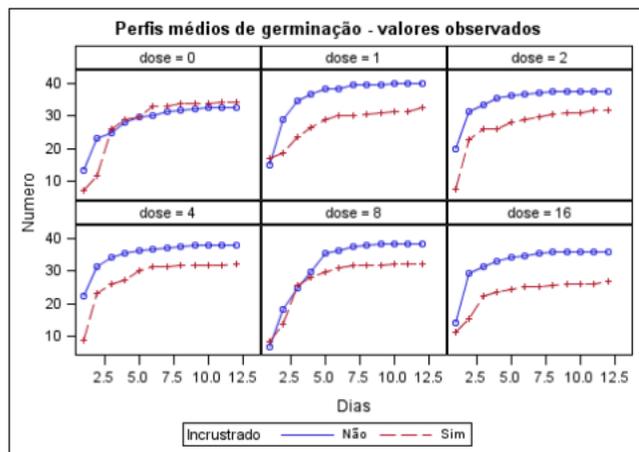
Uma reta parece explicar bem a relação entre a absorbância e o aumento na concentração de nitrito.

**Exemplo 3. (Regressão linear múltipla)** Podemos relacionar o escore obtido na análise sensorial ( $y$ ) do queijo Cheddar com a concentração de ácido acético ( $x_1$ ), de sulfeto de hidrogênio ( $x_2$ ) e de ácido láctico ( $x_3$ ) na sua composição química?

**Gráficos de dispersão: Escore vs Acético, Sulfeto e Láctico (queijos Cheddar)**



## Exemplo 4. (Regressão não linear) Como explicar a porcentagem de germinação de sementes do capim Marandú ao longo do tempo?



A germinação de sementes do capim Marandú ao longo do tempo tem um comportamento similar nos diferentes tratamentos.

**Curvas logísticas** podem explicar bem o processo de germinação de sementes de capim Marandú.

## 6.1. CORRELAÇÃO LINEAR

Queremos saber se existe alguma relação de dependência entre um par de variáveis quantitativas e, ao invés de procurarmos um modelo que as relacionem, buscamos **somente quantificar o grau do possível relacionamento linear existente entre elas.**

**Exemplo.** Quantificar o grau de relacionamento entre:

- i)* O consumo de fumo e a incidência de doenças do coração.
- ii)* O peso ao nascer e o peso ao abate de coelhos.
- iii)* A pressão arterial e o índice de massa corpórea (IMC).
- iv)* O número de horas de estudo e a nota de prova *etc.*

Ferramenta importante: **gráfico de dispersão**

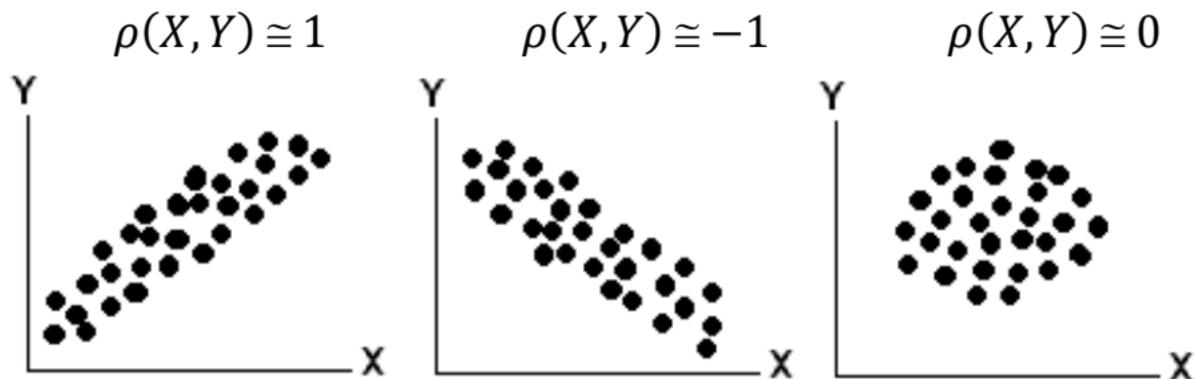
O coeficiente de correlação linear de Pearson é uma medida do grau de relacionamento linear entre duas variáveis quantitativas  $X$  e  $Y$  e é definido como:

$$\rho(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X) var(Y)}} \quad -1 \leq \rho(X, Y) \leq 1$$

O sinal de  $\rho(X, Y)$  indica o sentido da dependência entre  $X$  e  $Y$ :

- O sinal positivo indica que os valores de  $X$  e  $Y$  crescem no mesmo sentido ou que são grandezas diretamente proporcionais.
- O sinal negativo indica que os valores de  $X$  e  $Y$  crescem em sentidos opostos ou que são grandezas inversamente proporcionais.
- Um valor  $\rho(X, Y) = 0$  indica que não existe qualquer relação de dependência linear entre estas variáveis.

Situações comuns podem ser visualizadas nos gráficos apresentados a seguir:



**Figura 11.** Gráficos de dispersão e coeficientes de correlação.

Nas inferências sobre o parâmetro  $\rho(X, Y)$  nós usaremos o valor do coeficiente de correlação linear amostral de Pearson,  $r(X, Y)$ , para obter sua melhor estimativa.

O coeficiente de correlação linear amostral de Pearson é calculado pela expressão:

$$\begin{aligned} r(X, Y) &= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \\ &= \frac{\sum x_i y_i - \frac{1}{n} \sum x_i \sum y_i}{\sqrt{\left[ \sum x_i^2 - \frac{1}{n} (\sum x_i)^2 \right] \left[ \sum y_i^2 - \frac{1}{n} (\sum y_i)^2 \right]}} \end{aligned}$$

**Não se preocupem!**  
**A calculadora pode fazer esses cálculos de graça!**

Nas pesquisas em que se busca quantificar o grau de relacionamento entre variáveis utilizam-se dados amostrais.

Para inferir sobre esse relacionamento nas populações de onde foram extraídos os dados, podem ser usados testes de hipóteses para o coeficiente de correlação, como os apresentados a seguir.

### 1) Teste de independência das variáveis X e Y

- Hipóteses:  $H_0: \rho(X, Y) = 0$  (as variáveis são independentes)  
 $H_a: \rho(X, Y) \neq 0$  (as variáveis são dependentes)
- Estatística:  $T = \frac{r(X, Y)\sqrt{n-2}}{\sqrt{1-r^2(X, Y)}}$  que sob  $H_0$  tem distribuição  $t_{(n-2)}$ .

## 2) Teste $H_0: \rho(X, Y) = \rho_0$ (onde $-1 < \rho_0 < 1$ e $\rho_0 \neq 0$ )

$$H_0: \rho(X, Y) = \rho_0$$

$$H_a: \rho(X, Y) \neq \rho_0 \quad (H_a: \rho(X, Y) > \rho_0 \text{ ou } H_a: \rho(X, Y) < \rho_0)$$

- Estatística:  $Z = \frac{z - \mu_z}{\sigma_z}$ , que sob  $H_0$  tem distribuição  $N(0,1)$  e onde:

$$z = \frac{1}{2} \ln \left[ \frac{1+r(X,Y)}{1-r(X,Y)} \right], \quad \mu_z = \frac{1}{2} \ln \left[ \frac{1+\rho_0}{1-\rho_0} \right] \quad \text{e} \quad \sigma_z = \frac{1}{\sqrt{n-3}}$$

**Exemplo 6.1.** Com o objetivo de estudar a relação entre o peso médio de coelhos ao abate ( $Y$ ), em quilogramas, e o tamanho de ninhada ( $X$ ), foram coletados na granja do Campus os seguintes dados:

$x$	4	8	6	1	7	3	7	5
$y$	2.125	1.980	2.270	2.300	1.880	2.320	1.860	2.050

- Calcular o coeficiente de correlação e interpretar o seu valor.
- Testar a independência entre as variáveis  $X$  e  $Y$ , ao nível de significância de 5%, ou seja, testar se o peso médio de coelhos ao abate, independe do tamanho da ninhada onde ele nasceu.

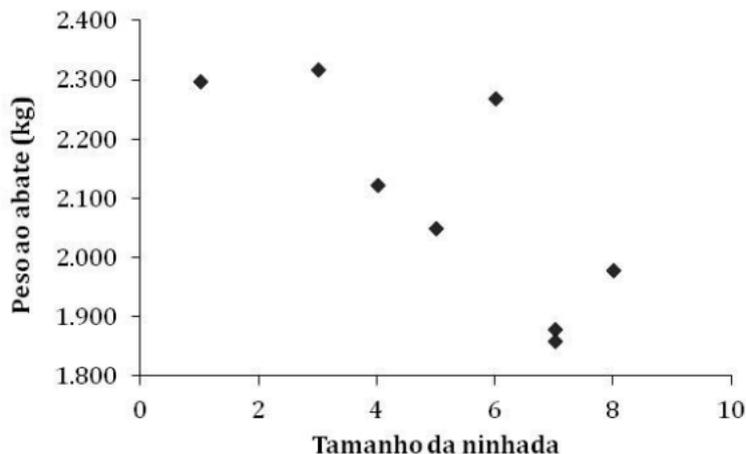
**Resolução:**

O coeficiente de correlação amostral é calculado como:

$$r(X, Y) = \frac{83,650 - \frac{(41)(16,785)}{8}}{\sqrt{\left[249 - \frac{(41)^2}{8}\right]\left[35,458 - \frac{(16,785)^2}{8}\right]}} = \frac{-2,373}{3,061} = -0,775$$

O coeficiente de correlação ( $-0,775$ ) mostra a existência da dependência linear negativa e relativamente alta entre o peso médio de coelhos ao abate e o tamanho de ninhada, indicando que “quanto maior o tamanho da ninhada menor será o peso médio dos coelhos ao abate”.

O peso médio de coelhos ao abate e o tamanho da ninhada são grandezas inversamente proporcionais!



**Figura 12.** Gráfico de dispersão do peso médio de coelhos ao abate e tamanho de ninhada.

b)  $H_0: \rho(X, Y) = 0$  (peso independente do peso da ninhada)

$H_a: \rho(X, Y) \neq 0$  (peso dependente do peso da ninhada)

- Estatística do teste:  $T = \frac{r(X,Y)\sqrt{6}}{\sqrt{1-r^2(X,Y)}} \sim t_{(6)}$ .
- Da Tábua III,  $\alpha = 5\%$ , obtemos  $t_c = 2,45 \Rightarrow RC(5\%) = \{|t| > 2,45\}$
- Da amostra:  $T_{calc} = \frac{-0,775\sqrt{6}}{\sqrt{1-(-0,775)^2}} = -3,00 \in RC(5\%)$

Rejeitamos a hipótese  $H_0$  e concluimos que existe uma dependência linear negativa e significativa entre o peso médio de coelhos ao abate e o tamanho da ninhada.

**Exemplo 6.2.** Com o intuito de testar a hipótese de que a correlação entre o ganho de peso e a quantidade de matéria seca ingerida por bovinos da raça Nelore é superior a 0,70, foram utilizados os dados de um experimento com 18 desses animais, resultando em  $r(X, Y) = 0,81$ . O que podemos concluir sobre a hipótese, ao nível de significância de  $\alpha = 1\%$ ?

**Resolução:**

- $H_0: \rho(X, Y) = 0,70$   
 $H_a: \rho(X, Y) > 0,70$
- Estatística do teste:  $Z = \frac{z - \mu_z}{\sigma_z} \sim N(0,1)$
- Da Tábua I, para  $\alpha = 1\%$ ,  $z_{tab} = 2,33 \Rightarrow RC(1\%) = \{z > 2,33\}$

- Da amostra de  $n = 18$  animais temos  $r(X, Y) = 0,81$ . Então:

$$z = \frac{1}{2} \ln \left[ \frac{1+0,81}{1-0,81} \right] = 1,1270, \quad \mu_z = \frac{1}{2} \ln \left[ \frac{1+0,70}{1-0,70} \right] = 0,8673 \text{ e}$$

$$\sigma_z = \frac{1}{\sqrt{18-3}} = 0,2582$$

$$\Rightarrow z_{calc} = \frac{1,1270 - (0,8673)}{0,2582} = 1,01 \notin RC(1\%)$$

Não rejeitamos  $H_0$  e concluímos que podemos admitir que a correlação entre o ganho de peso e a quantidade de matéria seca ingerida por bovinos da raça Nelore não é superior a 0,70.

## 6.2. REGRESSÃO LINEAR SIMPLES

Desejamos estudar o comportamento conjunto de duas ou mais variáveis, como por exemplo:

- i)* O peso do animal com sua idade.
- ii)* A quantidade de adubo com a produção de matéria seca.
- iii)* A digestibilidade de um alimento com o tempo.
- iv)* O índice de inflação e os preços de diversos itens da cesta básica, etc.

Quando o interesse está em procurar expressar essa relação sob a forma de uma equação matemática estamos fazendo uma **Análise de Regressão**.

A equação de regressão pode ser um polinômio (reta, parábola ou um polinômio de grau mais elevado), uma função do tipo exponencial (curva logística, de Gompertz, von Bertalanfy *etc.*), uma função sigmoidal *etc.*

Estudaremos somente o ajuste de uma reta em problemas envolvendo duas variáveis:

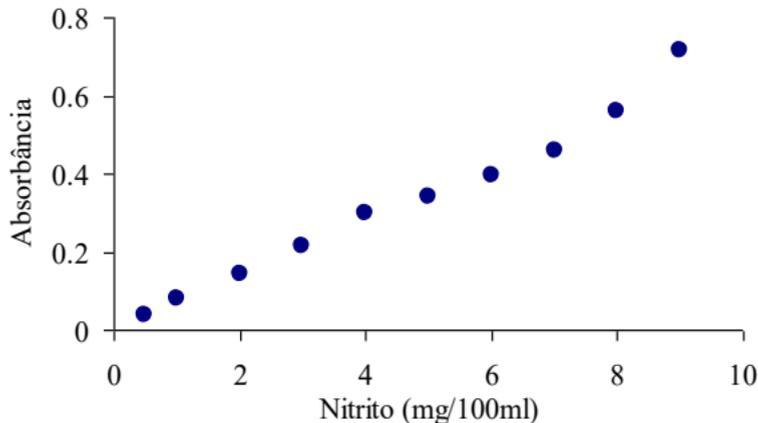
$Y$ : variável resposta ou variável dependente

$X$ : variável regressora, covariada ou variável independente.

**O Gráfico de dispersão** facilita a visualização da relação funcional entre as variáveis. A distribuição dos pontos no gráfico pode sugerir qual função explica melhor o comportamento dos dados.

**Exemplo 6.3** Determinar a reta que relaciona a Absorbância (Y) com a concentração de nitrito (X, em mg/100ml) em amostras de mortadela. Os dados experimentais são:

$x_i$	$y_i$
0.5	0.040
1.0	0.078
2.0	0.145
3.0	0.215
4.0	0.300
5.0	0.340
6.0	0.395
7.0	0.460
8.0	0.560
9.0	0.715



**Figura 13.** Gráfico de dispersão dos dados de absorbância e quantidade de nitrito.

- Percebe-se que a relação entre  $X$  e  $Y$  pode ser bem explicada por uma reta (função linear), cuja equação é  $y = a + bx$ .
- Teoricamente, esta reta deve passar pela origem, pois para uma solução sem nitrito espera-se uma absorbância nula.
- Inicialmente, precisamos estimar o valor do intercepto e do coeficiente angular da reta de regressão.

Isso pode ser feito à mão livre, traçando-se uma reta que “passe pelo meio dos pontos” e pela origem ( $a = 0$ ). O coeficiente angular pode ser calculado como  $b = \Delta y / \Delta x$ .

**Inconveniente** desta solução: Observadores diferentes podem obter valores diferentes para os coeficientes  $a$  e  $b$  da reta.

**Indicado:** Usar o Método dos Mínimos Quadrados Ordinários - MQO

### 6.2.1. O MODELO PARA REGRESSÃO LINEAR SIMPLES

A partir de uma amostra de  $n$  pares de valores  $(x_1, y_1), \dots, (x_n, y_n)$  nós podemos estabelecer o modelo de regressão linear simples:

$$y_i = a + bx_i + e_i$$

onde  $a$  e  $b$  são os parâmetros da reta e  $e_i$  é um erro associado aos valores de  $y_i$ .

O **erro** ( $e_i$ ) pode resultar de erros de medidas e de digitação, da heterogeneidade das matérias primas utilizadas no experimento, da imprecisão dos equipamentos utilizados nas medições *etc.*

Para estabelecer o modelo de regressão linear estabelecemos alguns pressupostos que são indicados a seguir:

Pressuposições do modelo de regressão linear simples:

- a) A relação entre as variáveis X e Y é linear.
- b) Os valores da variável X não estão sujeitos a erros (são fixos).
- c) A média dos erros é nula, isto é,  $E(e_i) = 0$ .
- d) Para um dado valor  $x_i$ , a variância do erro é constante e igual a  $\sigma^2$ , isto é,  $var(e_i) = \sigma^2$ .
- e) A correlação entre os erros de duas observações quaisquer é nula, isto é,  $corr(e_i, e_j) = 0$ , para  $i \neq j$ .
- f) Os erros têm distribuição normal, isto é,  $e_i \sim N(0, \sigma^2)$ .

O **Método dos Mínimos Quadrados Ordinários** (MQO) consiste em obter estimativas dos parâmetros  $a$  e  $b$  que minimizem a soma dos quadrados dos erros, ou seja, que minimizem a função:

$$SQE = \sum_{i=1}^n (y_i - a - bx_i)^2$$

Para obter o mínimo desta função (de duas variáveis) derivamos parcialmente  $SQE$  em relação aos parâmetros  $a$  e  $b$ :

$$\frac{\partial SQE}{\partial a} = \sum_{i=1}^n (y_i - a - bx_i)(-2)$$

$$\frac{\partial SQE}{\partial b} = \sum_{i=1}^n (y_i - a - bx_i)(-2x_i)$$

Para obter os estimadores de  $a$  e  $b$ , denotados por  $\hat{a}$  e  $\hat{b}$ , igualamos as derivadas parciais a zero:

$$\sum_{i=1}^n (y_i - \hat{a} - \hat{b}x_i) = 0$$

$$\sum_{i=1}^n (y_i - \hat{a} - \hat{b}x_i)(x_i) = 0$$

Este sistema é chamado **Sistema de Equações Normais** (S.E.N.) e pode ser simplificado como:

$$\begin{cases} n\hat{a} + \hat{b} \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \\ \hat{a} \sum_{i=1}^n x_i + \hat{b} \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i y_i \end{cases}$$

Matricialmente:

$$\begin{bmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{bmatrix} \begin{bmatrix} \hat{a} \\ \hat{b} \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i y_i \end{bmatrix}$$

Resolvendo o sistema, nós obtemos:

$$\hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n x_i y_i - \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}}$$

$$\hat{a} = \bar{y} - \hat{b}\bar{x}$$

**Não se preocupem!**  
**A calculadora científica pode obter  $\hat{a}$  e  $\hat{b}$  facilmente!**

O **modelo ajustado** pode ser escrito como:

$$\hat{y}_i = \hat{a} + \hat{b}x_i$$

O **resíduo** da regressão pode ser calculado como:

$$\hat{e}_i = y_i - \hat{y}_i$$

Quando a reta descreve bem a relação entre Y e X, esperamos que os valores observados ( $y_i$ ) e os valores estimados pela reta ( $\hat{y}_i$ ) estejam próximos, o que produz resíduos ( $\hat{e}_i$ ) muito próximos de zero.

Podemos calcular os **resíduos padronizados** utilizando:

$$\hat{e}_i^* = \hat{e}_i / \sqrt{s_{y/x}^2} \quad (41)$$

onde  $s_{y/x}^2 = \frac{1}{(n-2)} \sum_{i=1}^n (y_i - \hat{y}_i)^2$  é a variância da regressão.

**Infelizmente a calculadora não fornece esta variância ( $s_{y/x}^2$ ) facilmente...**

## Regra simples para identificar pontos atípicos:

Se  $|\hat{e}_i^*| > 2 \Rightarrow$  o ponto  $(x_i, y_i)$  deve ser considerado um ponto atípico, discrepante (*outlier*) e merece ser estudado com atenção.

O gráfico de dispersão dos resíduos padronizados serve para:

- i) Evidenciar a presença de pontos atípicos (resultantes de erros de medidas, de digitação etc.) que, após um estudo mais detalhado, poderão ser excluídos do conjunto de dados originais.
- ii) Visualizar a possível fuga da suposição de variância constante.

Espera-se que os pontos do gráfico de dispersão dos resíduos estejam distribuídos aleatoriamente ao longo da reta  $y = 0$ , não mostrem nenhuma tendência nem variabilidades diferentes ao longo do eixo das abcissas.

A qualidade do ajuste de uma regressão pode ser avaliada através de gráficos de resíduos e do **coeficiente de determinação**:

$$R^2 = (\hat{b})^2 \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = [r(X, Y)]^2 \quad (41)$$

Como  $0 \leq R^2 \leq 1$  o ajuste do modelo será tanto melhor quanto mais próximo de 1 estiver o valor de  $R^2$ .

O coeficiente de terminação ( $R^2$ ) deve ser usado com cautela como medida de uma boa qualidade do ajuste.

As pressuposições do modelo também devem ser avaliadas após o ajuste do modelo. Por exemplo: esperamos que os pontos  $(x_i; \hat{e}_i)$  ou  $(x_i; \hat{e}_i^*)$  estejam distribuídos aleatoriamente em relação à reta  $y = 0$ , sem apresentar qualquer tendência ou aumento de variabilidade.

**Exemplo:** Se os resíduos apresentarem uma tendência quadrática, deveremos incluir no modelo um componente quadrático, do tipo  $cx_i^2$  e estudar se esta inclusão foi importante.

Vamos ajustar a reta do Exemplo 6.3:

$$n = 10 \quad \sum x_i = 45,5 \quad \sum x_i^2 = 285,25 \quad \sum y_i = 3,248$$

$$\sum y_i^2 = 1,473 \quad \sum x_i y_i = 20,438$$

Com esses valores podemos estimar os parâmetros da reta:

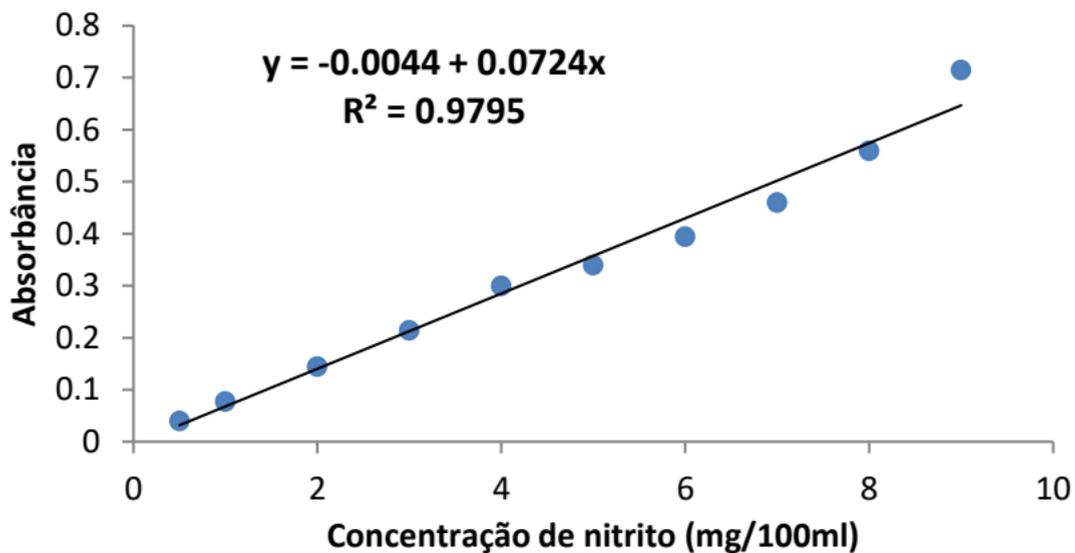
$$\hat{b} = \frac{20,438 - (45,5)(3,248)/10}{285,25 - (45,5)^2/10} = \frac{5,6596}{78,2250} = 0,0724$$

$$\hat{a} = \frac{3,248}{10} - (0,0724)(4,55) = -0,0044$$

Reta ajustada:  $\hat{y}_i = -0,0044 + 0,0724x_i$

### Comentários:

- O intercepto (-0,0044) não tem um sentido prático (absorbância negativa para uma amostra sem nitrito !?!?)
- O coeficiente angular da reta (0,0724) pode ser entendido como o número de unidades que será acrescentado a absorbância, quando a concentração de nitrito sofrer um acréscimo de 1mg/100ml.
- $R^2 = (0,0724)^2 (78,2250 / 0,4232) = 0,98$ , indica que a relação entre a concentração de nitrito e a absorbância está muito bem explicada pela reta.



**Figura.** Reta de regressão ajustada aos dados do Exemplo 6.3

$x_i$	$y_i$	$\hat{y}_i$	$\hat{e}_i$	$\hat{e}_i^*$
0,5	0,040	0,032	0,008	0,241
1,0	0,078	0,068	0,010	0,301
2,0	0,145	0,140	0,005	0,151
3,0	0,215	0,213	0,002	0,060
4,0	0,300	0,285	0,015	0,452
5,0	0,340	0,357	-0,017	-0,512
6,0	0,395	0,430	-0,035	-1,054
7,0	0,460	0,502	-0,042	-1,265
8,0	0,560	0,574	-0,014	-0,422
9,0	0,715	0,647	0,068	<b>2,048</b>

Para construir o gráfico de dispersão  $(x_i; \hat{e}_i^*)$ , calculamos os valores ajustados  $(\hat{y}_i)$  e os resíduos ordinários  $(\hat{e}_i)$ .

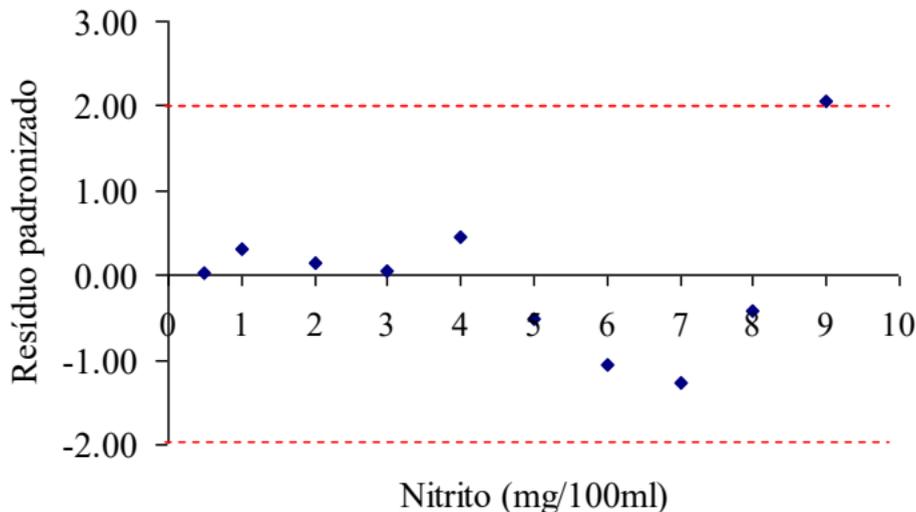
Com esses resíduos calculamos a variância:

$$s_{y/x}^2 = 0,0011$$

e os resíduos padronizados:

$$\hat{e}_i^* = \frac{\hat{e}_i}{\sqrt{0,0011}}$$

Com os resíduos padronizados podemos construir o seguinte gráfico de dispersão:



**Figura 14.** Gráfico de dispersão dos resíduos padronizados em função da concentração de nitrito.

Observe que:

- Os resíduos (Figura 14) não apresentam um comportamento aleatório (sequência de resíduos positivos e de resíduos negativos)
- O ponto  $(9,0; 0,715)$  tem um resíduo padronizado superior a 2 e merece atenção, podendo ser considerado um ponto atípico (!?)

Para melhorar a análise nós podemos tentar:

- i)* Excluir o ponto  $(9,0; 0,715)$  do conjunto de dados e ajustar uma nova reta aos dados (Fica como exercício!).
- ii)* Manter este ponto no conjunto e tentar ajustar outro modelo, como um polinômio de 2º grau. (Solução mais trabalhosa!).

**CUIDADO:** Devemos usar o  $R^2$  com cautela!

Ajustar uma reta a cada conjunto de dados:

$x_1$	$y_1$	$x_2$	$y_2$	$x_3$	$y_3$	$x_4$	$y_4$
10	8.04	10	9.14	10	7.46	8	6.58
8	6.95	8	8.14	8	6.77	8	5.76
13	7.58	13	8.74	13	12.74	8	7.74
9	8.81	9	8.77	9	7.11	8	8.84
11	8.33	11	9.26	11	7.81	8	8.47
14	9.96	14	8.10	14	8.84	8	7.04
6	7.24	6	6.13	6	6.08	8	5.25
4	4.26	4	3.10	4	5.39	19	12.50
12	10.84	12	9.13	12	8.15	8	5.56
7	4.82	7	7.26	7	6.42	8	7.91
5	5.68	5	4.74	5	5.73	8	6.89

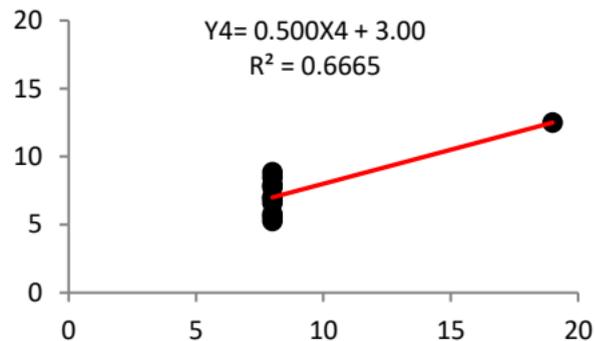
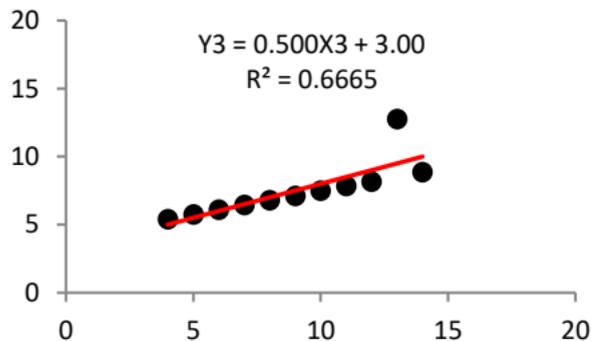
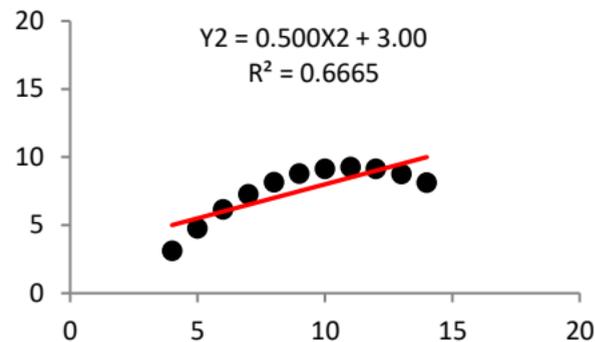
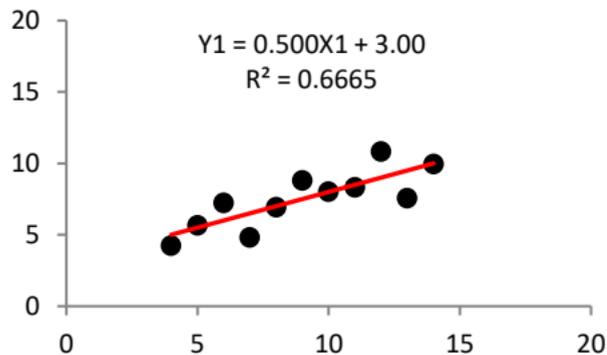
*In:* Chatterjee, S.; Price, B. **Regression analysis by Example**. Wiley, 1977, p. 8.

O que podemos comentar sobre os ajustes das retas?

Conjunto	Reta ajustada	$R^2$
1	$\hat{y}_1 = 3,00 + 0,500x_1$	0,67
2	$\hat{y}_2 = 3,00 + 0,500x_2$	0,67
3	$\hat{y}_3 = 3,00 + 0,500x_3$	0,67
4	$\hat{y}_4 = 3,00 + 0,500x_4$	0,67

Perceba que:

- Os coeficientes de determinação de todos os ajustes são iguais a 0,67, indicando uma boa qualidade do ajuste.
- Avaliando somente o valor do  $R^2$  concluiríamos que uma reta se ajusta bem a todos os quatro conjuntos de dados. Será???



## INFERÊNCIA SOBRE OS PARÂMETROS DA RETA DE REGRESSÃO

Pode-se provar que  $\hat{a}$  e  $\hat{b}$  são estimadores não viesados de  $a$  e  $b$ , respectivamente, ou seja,  $E(\hat{a}) = a$  e  $E(\hat{b}) = b$ .

Os erros padrões associados a  $\hat{a}$  e  $\hat{b}$  podem ser calculados por:

$$ep(\hat{a}) = \sqrt{s_{y/x}^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right)} \quad ep(\hat{b}) = \sqrt{\frac{s_{y/x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

$$\text{onde } s_{y/x}^2 = \frac{1}{(n-2)} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \frac{1}{(n-2)} \sum_{i=1}^n \hat{e}_i^2.$$

Os  $ep$ 's medem a variabilidade das estimativas dos parâmetros da reta e serão usados na construção de  $IC$ 's e nos testes de hipóteses. No cálculo dos  $ep$ 's sempre aparece a variância  $s_{y/x}^2$ .

**Intervalo de Confiança para o intercepto da reta:**

$$IC(a, 100\gamma\%) = \hat{a} \pm t_{tab} ep(\hat{a}) \quad (42)$$

onde  $t_{tab}$  é obtido da Tábua III, tal que  $\gamma = P(-t_{tab} \leq T \leq t_{tab})$  e  $T \sim t_{(n-2)}$ .

**Intervalo de Confiança para o coeficiente angular da reta:**

$$IC(b, 100\gamma\%) = \hat{b} \pm t_{tab} ep(\hat{b}) \quad (43)$$

onde  $t_{tab}$  é obtido da Tábua III, tal que  $\gamma = P(-t_{tab} \leq T \leq t_{tab})$  e  $T \sim t_{(n-2)}$ .

**Intervalo de Predição** para  $y_p$ , em que  $x_p$  pertence ao domínio da variável X, mas não foi usado na estimação dos parâmetros da reta.

$$IC(y_p, 100\gamma\%) = \hat{y}_p \pm t_{tab} ep(\hat{y}_p) \quad (44)$$

Onde  $\hat{y}_p = \hat{a} + \hat{b}x_p$  e  $ep(\hat{y}_p) = \sqrt{s_{y/x}^2 \left( \frac{1}{n} + \frac{(x_p - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right)}$

### Teste de hipótese para o intercepto da reta

- $H_0: a = a_0$  vs.  $H_a: a \neq a_0$  (ou  $H_a: a < a_0$  ou  $H_a: a > a_0$ )
- Estatística do teste:  $T = \frac{\hat{a} - a_0}{ep(\hat{a})} \sim t_{(n-2)}$ .

## Teste de hipótese para o coeficiente angular da reta

- $H_0: b = b_0$  vs.  $H_a: b \neq b_0$  (ou  $H_a: b < b_0$  ou  $H_a: b > b_0$ )
- Estatística do teste:  $T = \frac{\hat{b} - b_0}{ep(\hat{b})} \sim t_{(n-2)}$ .

Aproveitando os dados do Exemplo 6.3 vamos calcular um *IC* para a inclinação da reta ( $\gamma = 95\%$ ), um *IC* para  $x_p = 9,5$  mg/100ml e testar a hipótese de que o intercepto da reta é nulo, ao nível de significância  $\alpha = 5\%$ .

- $IC(b; 95\%) = 0,07235 \pm 2,306 \sqrt{\frac{0,0011}{78,2250}} = 0,0724 \pm 0,0087$

O intervalo  $IC(b; 95\%) = [0,064; 0,081]$  contém o verdadeiro valor da inclinação da reta com uma confiança de 95%.

- O intervalo de predição para  $x_p = 9,5$  é:

$$IC(y_p; 95\%) = 0,6832 \pm 2,306 \sqrt{\left[ \frac{1}{10} + \frac{(9,5 - 4,55)^2}{78,2250} \right] 0,0011}$$

$$= 0,6832 \pm 0,0492$$

$\Rightarrow IC(y_p; 95\%) = [0,634; 0,733]$  contém o verdadeiro valor previsto para a absorvância de uma amostra com 9,5mg/100 ml de nitrito, com 95% de confiança.

- Testar a hipótese que a reta passa pela origem dos eixos.

Hipóteses:  $H_0: a = 0$  versus  $H_a: a \neq 0$

Estatística do teste:  $T = \frac{\hat{a} - a_0}{ep(\hat{a})} \sim t_{(8)}$

Para  $\alpha = 5\%$ ,  $t_{tab} = 2,306 \Rightarrow RC = \{T \in R: |T| > 2,306\}$

$$\text{Da amostra: } t_{calc} = \frac{-0,0044 - 0}{\sqrt{\left[\frac{1}{10} + \frac{4,55^2}{78,2250}\right]} 0,0011} = \frac{-0,0044}{0,0200} = -0,22$$

Como  $t_{calc} \notin RC(5\%)$  não rejeitamos  $H_0$  ( $\alpha = 5\%$ ) e concluímos que o intercepto da reta pode ser considerado nulo (ou seja, a reta passa pela origem dos eixos).

**Conclusão:** Diante deste resultado, devemos ajustar uma nova reta que não tenha o intercepto, ou seja, uma reta  $y_i = bx_i + \varepsilon_i$ .

O estimador de Mínimos Quadrados do novo coeficiente angular da reta que passa pela origem dos eixos é dado por:

$$\hat{b} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$$

Com os dados do Exemplo temos:

$$\hat{b} = \frac{20,438}{285,25} = 0,0716$$

A *nova* reta ajustada pode ser escrita como:

$$\hat{y}_i = 0,0716x_i$$

Vale a pena lembrar que após o ajuste, é necessário fazer um novo estudo diagnóstico para verificar se as pressuposições do modelo estão satisfeitas.

Os softwares estatísticos (*R, SAS, Statistica etc*) têm ferramentas de uso simples que auxiliam nessa verificação das pressuposições.