



# **REGRESSÃO LINEAR SIMPLES E MÚLTIPLA**

**Curso: Agronomia**

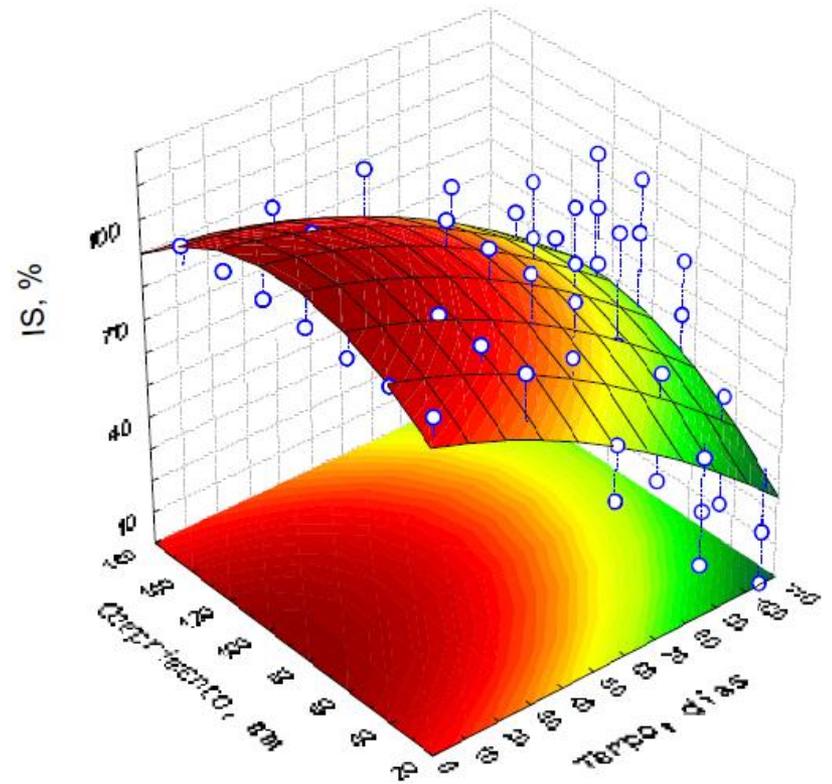
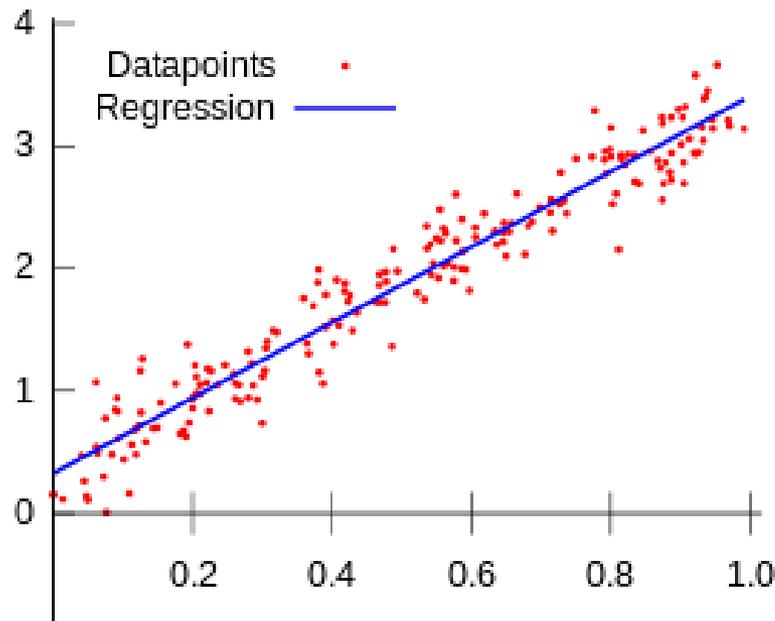
**Matéria: Metodologia e Estatística Experimental**

**Docente: José Cláudio Faria**

**Discente: Michelle Alcântara e João Nascimento**

**UNIVERSIDADE ESTADUAL DE SANTA CRUZ  
DEPARTAMENTO DE CIÊNCIAS AGRÁRIAS E AMBIENTAIS  
2016.1**

# REGRESSÃO



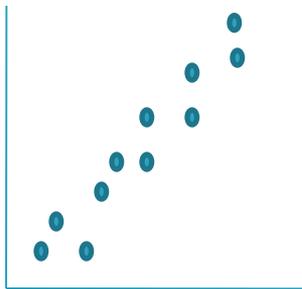
É a relação entre duas ou mais variáveis quantitativas: uma variável dependente, cujo valor deverá ser previsto e uma variável (ou variáveis) independente(s) ou explicativa(s), sobre a(s) qual(is) existe conhecimento teórico disponível.

Estimar uma equação é geometricamente equivalente a ajustar uma curva aos dados dispersos = REGRESSÃO.

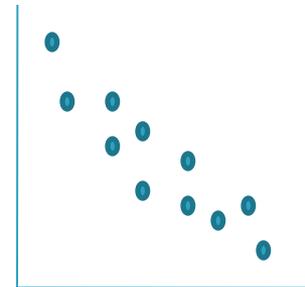
# CORRELAÇÃO

- Quando duas variáveis (X e Y) estão ligadas por uma relação estatística, dizemos que existe correlação entre elas.
- Essa técnica é empregada, especificamente, para se avaliar o grau de covariação entre duas variáveis aleatórias.

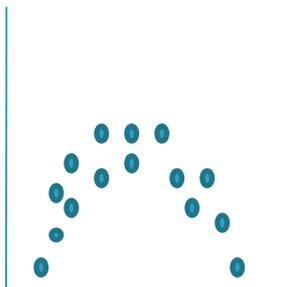
## DIAGRAMA DE DISPERSÃO



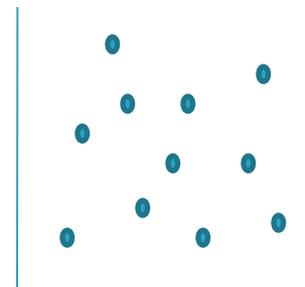
**Linear Positiva**  
(reta ascendente)



**Linear Negativa**  
(reta descendente)



**Não linear**  
(curva)



**Não há correlação**

# Coeficiente de correlação de Pearson

- É um valor que informa a intensidade e a forma da correlação linear entre duas variáveis. A partir da análise do resultado podemos determinar se é adequado ou não a utilização do modelo linear para modelagem do fenômeno.

MODELO MATEMÁTICO:

$$R = \frac{n \cdot \sum xy - (\sum x) \cdot (\sum y)}{\sqrt{[n \cdot \sum x^2 - (\sum x)^2] \cdot [n \sum y^2 - (\sum y)^2]}}$$

Onde **n** é o número de termos

Os valores limites de  $r$  são  $-1$  e  $+1$ :

- Se correlação é perfeita positiva  $r=+1$
- Se correlação é perfeita negativa  $r=-1$ . Isto é, se uma aumenta, a outra diminui linearmente.
- Se não há correlação então  $r=0$ . Significa que as duas variáveis não estão linearmente associadas.

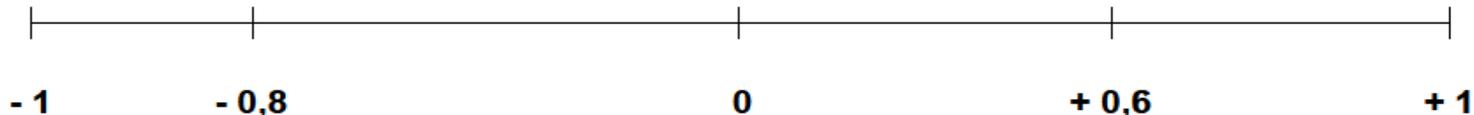
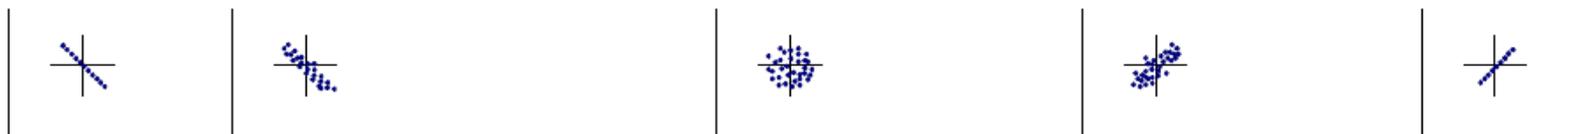
Temos também:

- Se  $0,6 \leq |r| \leq 1$  boa correlação;
- Se  $0,3 \leq |r| \leq 0,6$  correlação fraca;
- Se  $|r| < 0,3$  praticamente não existe correlação.

**Perfeita negativa**

**Não correlacionadas**

**Perfeita positiva**



**Aumenta grau de correlação  
negativa**

**Aumenta grau de correlação  
positiva**

# REGRESSÃO LINEAR

- A análise de regressão linear tem como resultado uma regressão matemática que descreve o relacionamento entre duas variáveis.
- Utiliza-se a Regressão Linear para estimar o valor de uma variável com base em valores conhecidos de outro. Pressupõe-se alguma relação de causa e efeito, de explanação do comportamento entre as variáveis. Ex. a idade e o peso de cada bezerro; a alíquota de imposto e a arrecadação; preço e quantidade.

- 
- ❖ **Regressão Linear Simples:** Relação casual entre duas variáveis, e pode ser descrita por uma reta; Uma variável chamada dependente, e uma outra chamada independente. Também tem por objetivo determinar a equação da reta ajustada(modelo matemático linear).
  - ❖ **Regressão Linear múltipla:** Relação casual com mais de duas variáveis. Isto é, quando o comportamento de **Y** é explicado por mais de uma variável independente **X1, X2, ...Xn**. É a técnica adequada para se utilizar quando se quer investigar simultaneamente os efeitos, sobre **Y**, de 2 ou mais variáveis preditoras.

# AJUSTAMENTO DE RETA

X Nitrogênio kg ha <sup>-1</sup>	Y Safrá kg ha <sup>-1</sup>
10	1.000
20	2.300
30	2.600
40	3.900
50	5.400
60	5.800
70	6.600

Figura1. Relação observada entre a safra e a aplicação de nitrogênio.

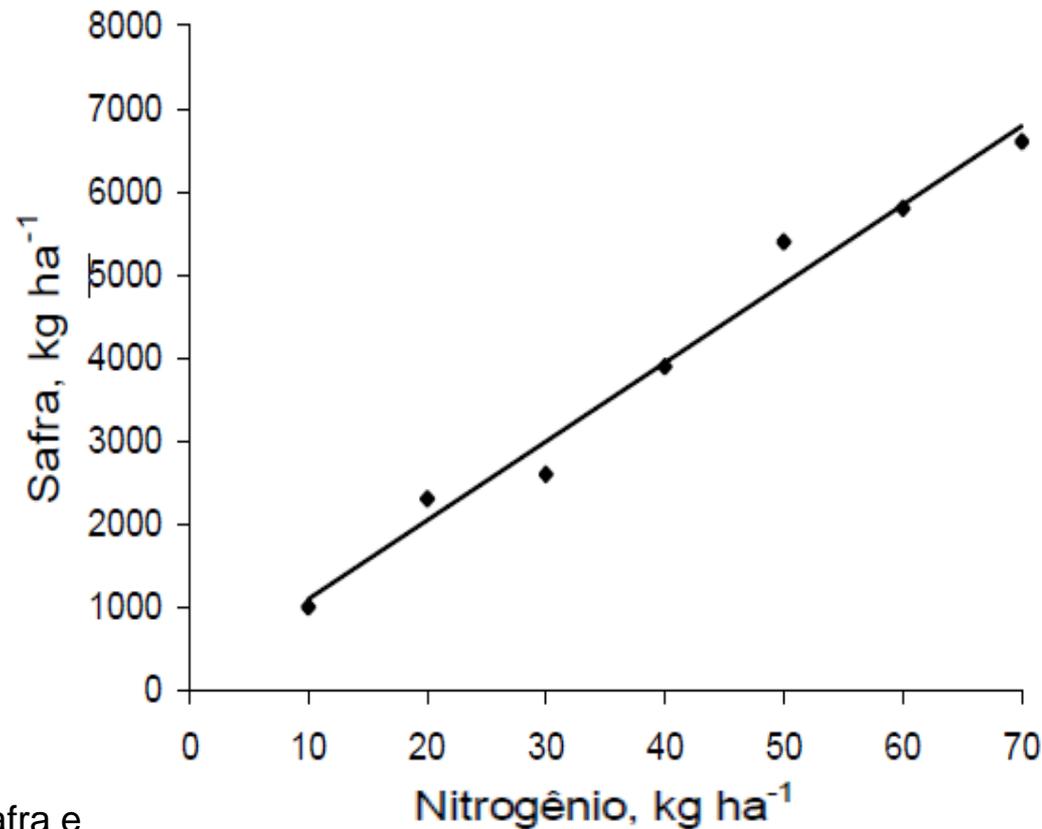


Figura 2. Dados e reta ajustada a olho aos dados apresentados.

# Critérios para o ajustamento da reta

- O que é um bom ajustamento? Um ajustamento que causa pequeno erro total.
- O erro ou a falta de ajustamento é definido como a distância vertical entre o valor observado  $Y_i$  e o valor ajustado  $\hat{Y}_i$  na reta, isto é,  $(Y_i - \hat{Y}_i)$ :

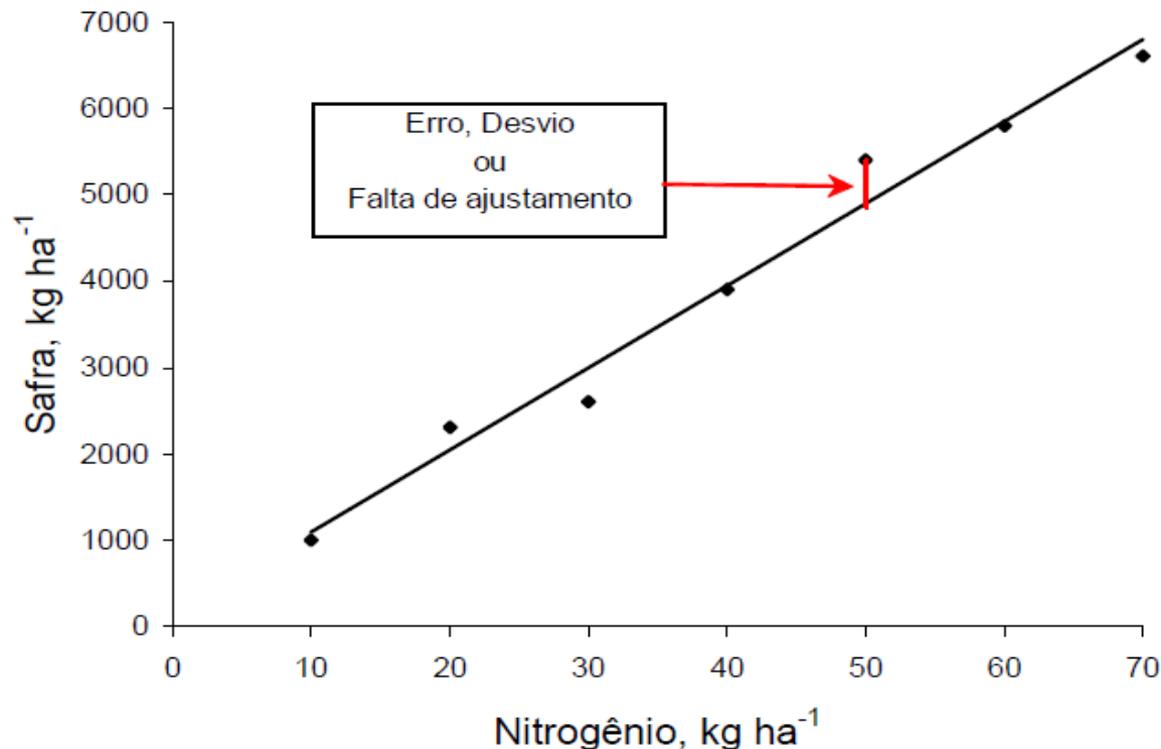


Figura 3. Erro típico no ajustamento de uma reta.

# Método dos Mínimos Quadrados

- O método mais utilizado para ajustar uma reta aos pontos dispersos é o que minimiza a soma de quadrados dos erros:

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

- ❖ O quadrado elimina o problema do sinal, pois torna positivos todos os erros;
- ❖ A álgebra dos mínimos quadrados é de manejo relativamente fácil;
- ❖ O método dos mínimos quadrados permite encontrar as estimativas de  $\alpha$  e  $\beta$ ;
- ❖ Minimizando a soma do quadrado de erros, encontraremos  $\alpha$  e  $\beta$ , que trarão a menor diferença entre a previsão de  $Y_i$  e o  $\hat{Y}_i$ .

- REGRESSÃO = Criar um modelo de *equação de reta* para fazer previsões/estimativas de valores futuros através dos pontos.
- Equação de Reta = **Equação de 1ºGrau**

**OBJETIVO** = Ajustar uma reta

$$\hat{Y} = \hat{\alpha}_0 + \hat{\beta}X$$

Onde:

- X- variável explicativa ou independente;
- Y- variável explicada ou dependente (aleatória);
- $\hat{\alpha}_0$  - coeficiente linear ou constante da regressão, representa o interceptor da reta com o eixo do Y;
- $\hat{\beta}$ - coeficiente de regressão ou coeficiente angular da reta. Representa a variação de Y em função da unitária variável x;
- $\alpha$  e  $\beta$  são parâmetros.

## ❖ Ajustando uma reta : 3 estágios

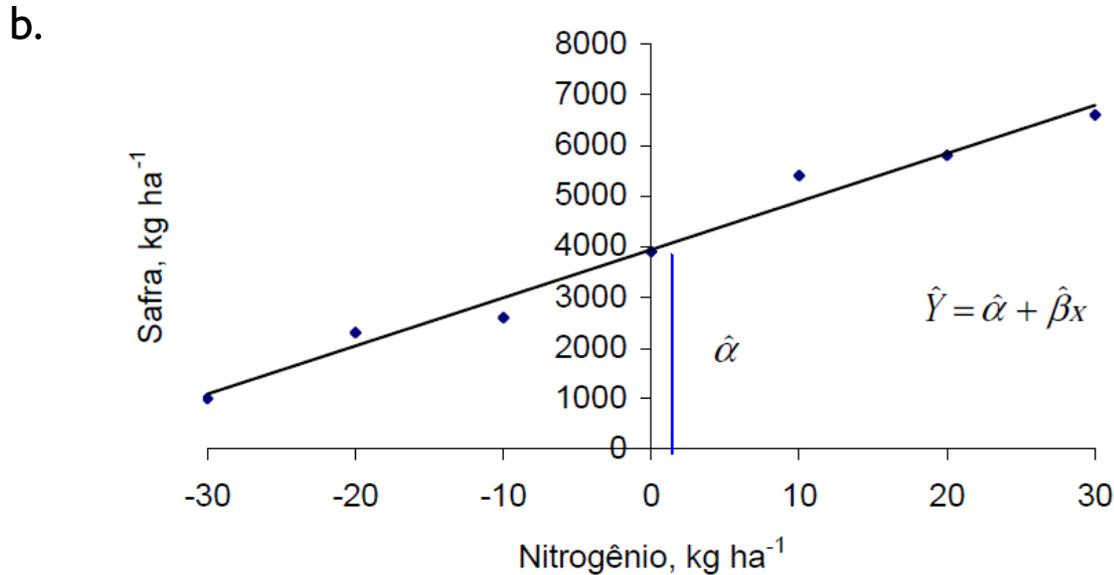
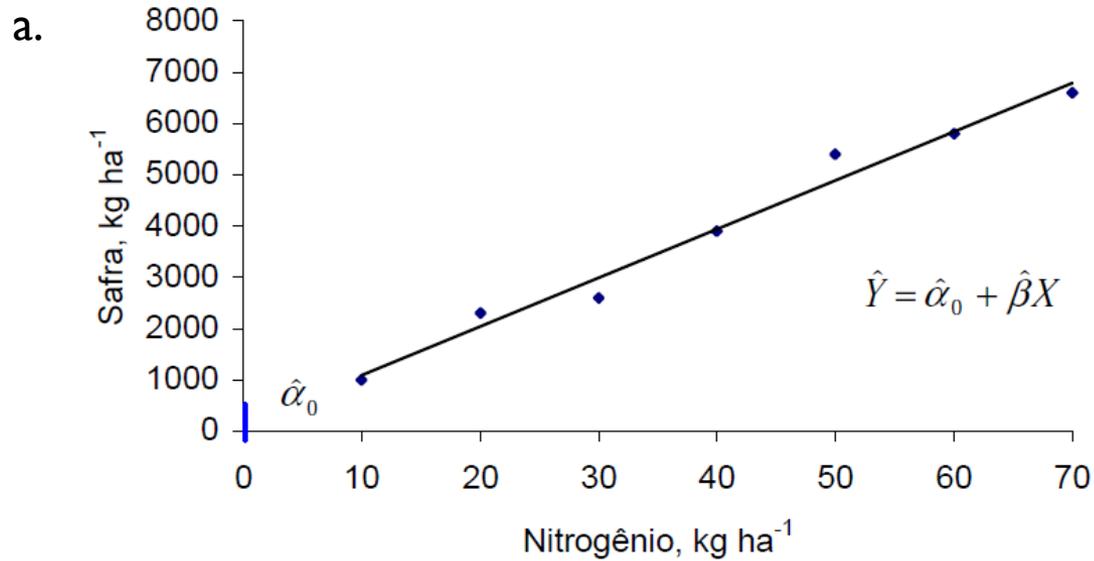
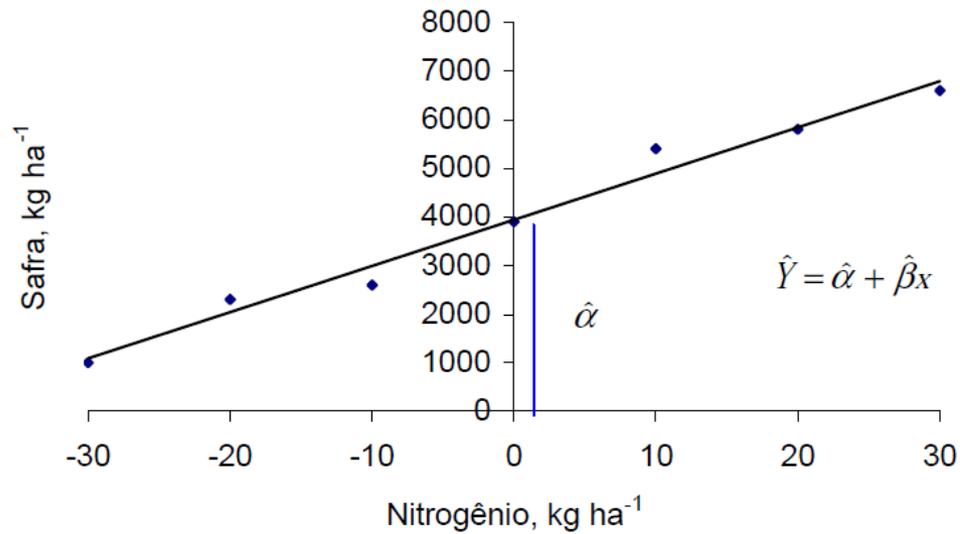


Figura 4. Translação de eixos. (a) Regressão utilizando os valores originais. (b) Regressão após transladar Y.



$X$	$x = X - \bar{X}$
	$x = X - 40$
10	- 30
20	- 20
30	- 10
40	0
50	10
60	20
70	30

$$\sum X = 280$$

$$\bar{X} = \frac{1}{N} \sum X \qquad \sum x = 0$$

$$\bar{X} = \frac{280}{7} = 40$$

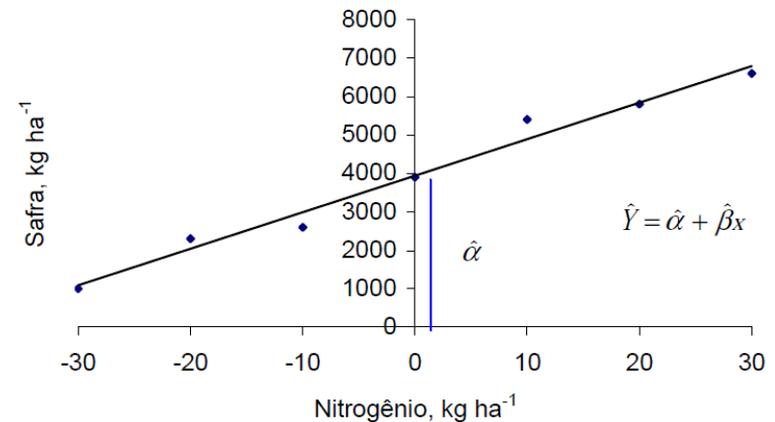
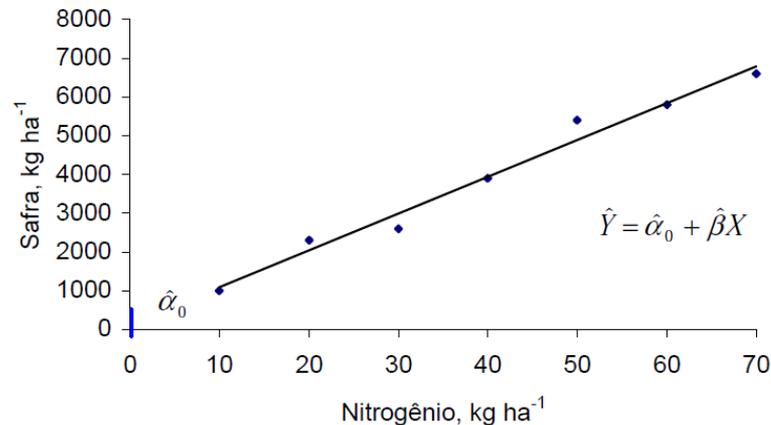
Figura 5. Calculo para encontrar os valores negativos.

# 1º Estágio

- Expressar  $X$  em termos de desvios a contar de sua média, isto é, definir uma nova variável  $x$  (minúsculo), tal que:

$$x = X - \bar{X}$$

- Isto equivale a uma relação geométrica de eixos:



- Observa-se que o eixo Y foi deslocado para a direita, de 0 a  $\bar{X}$
- O novo valor  $x$  torna-se positivo, ou negativo, conforme  $X$  esteja a direita ou a esquerda de  $\bar{X}$ .
- Não há modificação nos valores de  $Y$ .
- O intercepto  $\hat{\alpha}$  difere do intercepto original,  $\hat{\alpha}_0$ , mas o coeficiente angular,  $\hat{\beta}$ , permanece o mesmo.

- Medir  $X$  como desvio a contar de  $\bar{X}$  *simplifica os cálculos porque a soma dos novos valores  $x$  é igual a zero, isto é:*

$$\sum x_i = 0 \quad \therefore \quad \sum x_i = \sum (X_i - \bar{X}) = \sum X_i - n\bar{X} = n\bar{X} - n\bar{X} = 0$$

## 2º Estágio

- Devemos ajustar a reta aos dados, escolhendo valores para  $\hat{\alpha}$  e  $\hat{\beta}$ , que satisfaçam o critério dos mínimos quadrados. Ou seja, escolher valores de  $\hat{\alpha}$  e  $\hat{\beta}$  que minimizem:

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Equação 01

- Cada valor ajustado de  $\hat{Y}_i$  estará sobre a reta estimada:

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta}x_i$$

Equação 02

- Assim, estamos diante da seguinte situação: devemos encontrar os valores  $\hat{\alpha}$  e  $\hat{\beta}$  de modo a minimizar a soma de quadrados dos erros.
- Considerando a equação 1 e 2, isto pode ser expresso algebricamente como:

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad \therefore \quad \hat{Y}_i = \hat{\alpha} + \hat{\beta}x_i$$

$$S(\hat{\alpha}, \hat{\beta}) = \sum (Y_i - (\hat{\alpha} + \hat{\beta}x_i))^2 = \sum (Y_i - \hat{\alpha} - \hat{\beta}x_i)^2$$

- Usamos a notação  $S(\hat{\alpha}, \hat{\beta})$  para enfatizar que esta expressão depende de  $\hat{\alpha}$  e  $\hat{\beta}$ . Ao variarem  $\hat{\alpha}$  e  $\hat{\beta}$  (quando se tem várias retas),  $S(\hat{\alpha}, \hat{\beta})$  variará também.

- Pergunta-se então, para que valores de  $\hat{\alpha}$  e  $\hat{\beta}$  haverá um mínimo de erros?

A resposta a esta pergunta nos fornecerá a reta “ótima” (de mínimos quadrados dos erros).

- A técnica de minimização mais simples é fornecida pelo cálculo. A minimização de  $S(\hat{\alpha}, \hat{\beta})$  exige o anulamento simultâneo de suas derivadas parciais.

Igualando a zero a derivada parcial em relação a  $\hat{\alpha}$  :

$$\frac{\partial}{\partial \hat{\alpha}} \sum (Y_i - \hat{\alpha} - \hat{\beta}X_i)^2 = \sum 2(-1)(Y_i - \hat{\alpha} - \hat{\beta}X_i)^1 = 0$$

- Dividindo ambos os termos por (-2) e reagrupando:

$$\sum Y_i - n\hat{\alpha} - \hat{\beta} \sum x_i = 0 \quad \therefore \quad \sum x_i = 0$$

$$\sum Y_i - n\hat{\alpha} - 0 = 0$$

$$\sum Y_i - n\hat{\alpha} = 0$$

$$n\hat{\alpha} = \sum Y_i$$

$$\hat{\alpha} = \frac{\sum Y_i}{n} = \bar{Y}$$

Verifica-se que isto assegura que a reta de regressão ajustada deve passar pelo ponto  $(x, \bar{Y})$ , que pode ser interpretado como o centro de gravidade da amostra de  $n$  pontos.

- É preciso também anular a derivada parcial em relação a  $\hat{\beta}$ :

$$\frac{\partial}{\partial \hat{\beta}} \sum (Y_i - \hat{\alpha} - \hat{\beta}x_i)^2 = \sum 2(-x_i)(Y_i - \hat{\alpha} - \hat{\beta}x_i) = 0$$

Dividindo ambos os termos por (-2):

$$\sum x_i (Y_i - \hat{\alpha} - \hat{\beta}x_i) = 0$$

- Reagrupando:

$$\sum x_i Y_i - \hat{\alpha} \sum x_i - \hat{\beta} \sum x_i^2 = 0 \quad \therefore \quad \sum x_i = 0$$

$$\sum x_i Y_i - 0 - \hat{\beta} \sum x_i^2 = 0$$

$$\sum x_i Y_i - \hat{\beta} \sum x_i^2 = 0$$

$$\hat{\beta} \sum x_i^2 = \sum x_i Y_i$$

$$\hat{\beta} = \frac{\sum x_i Y_i}{\sum x_i^2}$$

- Podemos sintetizar da seguinte forma :

Com os valores  $x$  medidos como desvios a contar de sua média, os valores  $\hat{\alpha}$  e  $\hat{\beta}$  de mínimos quadrados dos erros são:

$$\hat{\alpha} = \frac{\sum Y_i}{n} = \bar{Y}$$

$$\hat{\beta} = \frac{\sum x_i Y_i}{\sum x_i^2}$$

❖ Dados do exemplo

X	$x = X - \bar{X}$ $x = X - 40$	Y	xY	$x^2$
10	- 30	1.000	- 30.000	900
20	- 20	2.300	- 46.000	400
30	- 10	2.600	- 26.000	100
40	0	3.900	0	0
50	10	5.400	54.000	100
60	20	5.800	116.000	400
70	30	6.600	198.000	900

$$\sum X = 280$$

$$\bar{X} = \frac{1}{N} \sum X$$

$$\bar{X} = \frac{280}{7} = 40$$

$$\sum x = 0$$

$$\sum Y = 27.600$$

$$\bar{Y} = \frac{1}{N} \sum \bar{Y}$$

$$\bar{Y} = \frac{27.600}{7}$$

$$\bar{Y} = 3.942,86$$

$$\sum xY = 266.000$$

$$\sum x^2 = 2.800$$

$$\hat{\alpha} = \frac{\sum Y_i}{n} = \bar{Y} \therefore \hat{\alpha} = \frac{27.600}{7} = 3.942,86$$

$$\hat{\beta} = \frac{\sum x_i Y_i}{\sum x_i^2} \therefore \hat{\beta} = \frac{266.000}{2.800} = 95,00$$

$$\hat{Y} = 3.942,86 + 95x$$

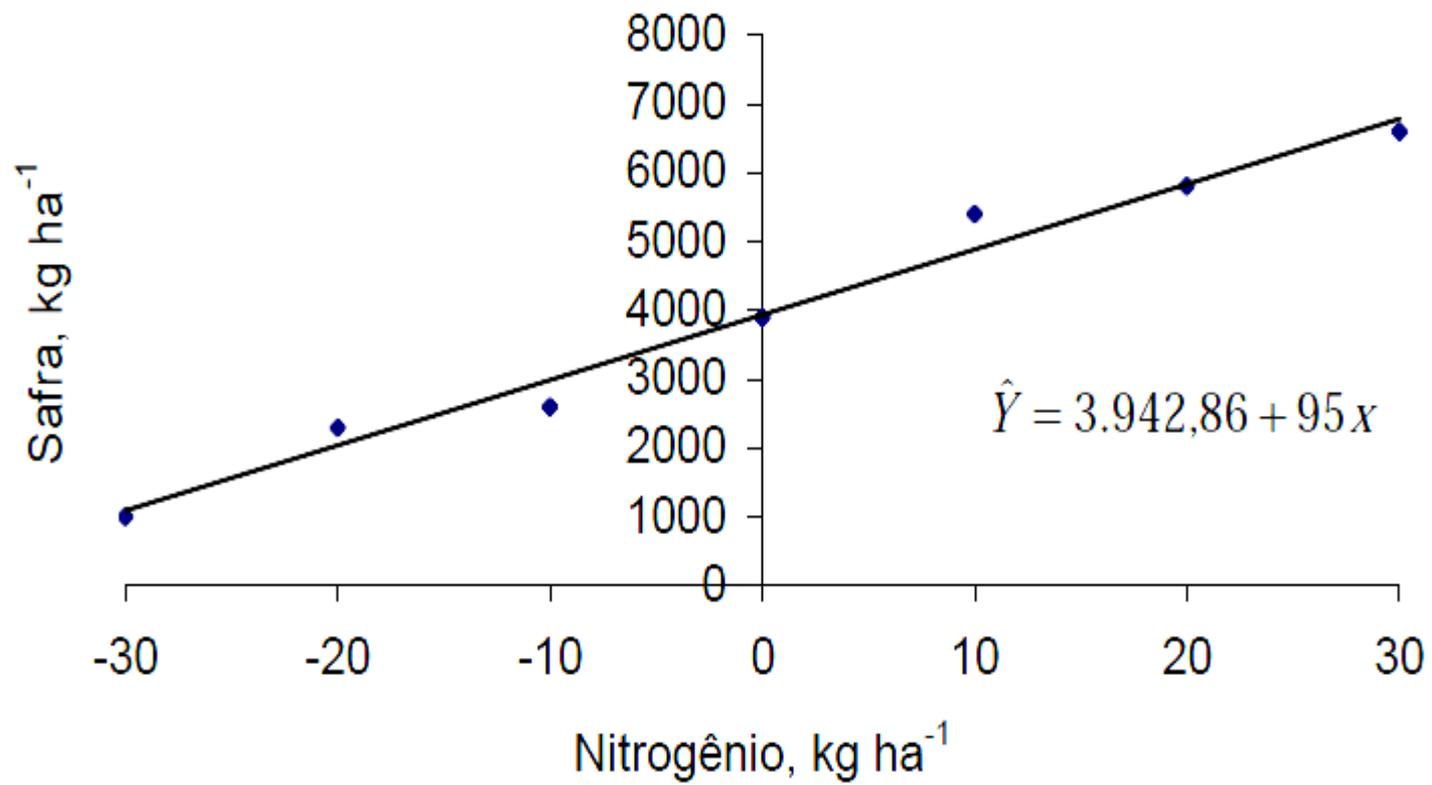


Figura 6. Equação da reta translocada.

Estágio 3 - A regressão pode agora ser transformada para o sistema original de referência:

$$\hat{Y} = 3.942,86 + 95x \quad \therefore \quad x = (X - \bar{X})$$

$$\hat{Y} = 3.942,86 + 95(X - \bar{X})$$

$$\hat{Y} = 3.942,86 + 95(X - 40)$$

$$\hat{Y} = 3.942,86 + 95X - 3.800$$

$$\hat{Y} = 142,86 + 95X$$

O coeficiente angular da reta de regressão ajustada ( $\hat{\beta}_1 = 95X$ ) permanece inalterado.

A única diferença é o intercepto,  $\hat{\alpha}$ , onde a reta tangencia o eixo Y. O intercepto original foi facilmente reobtido.

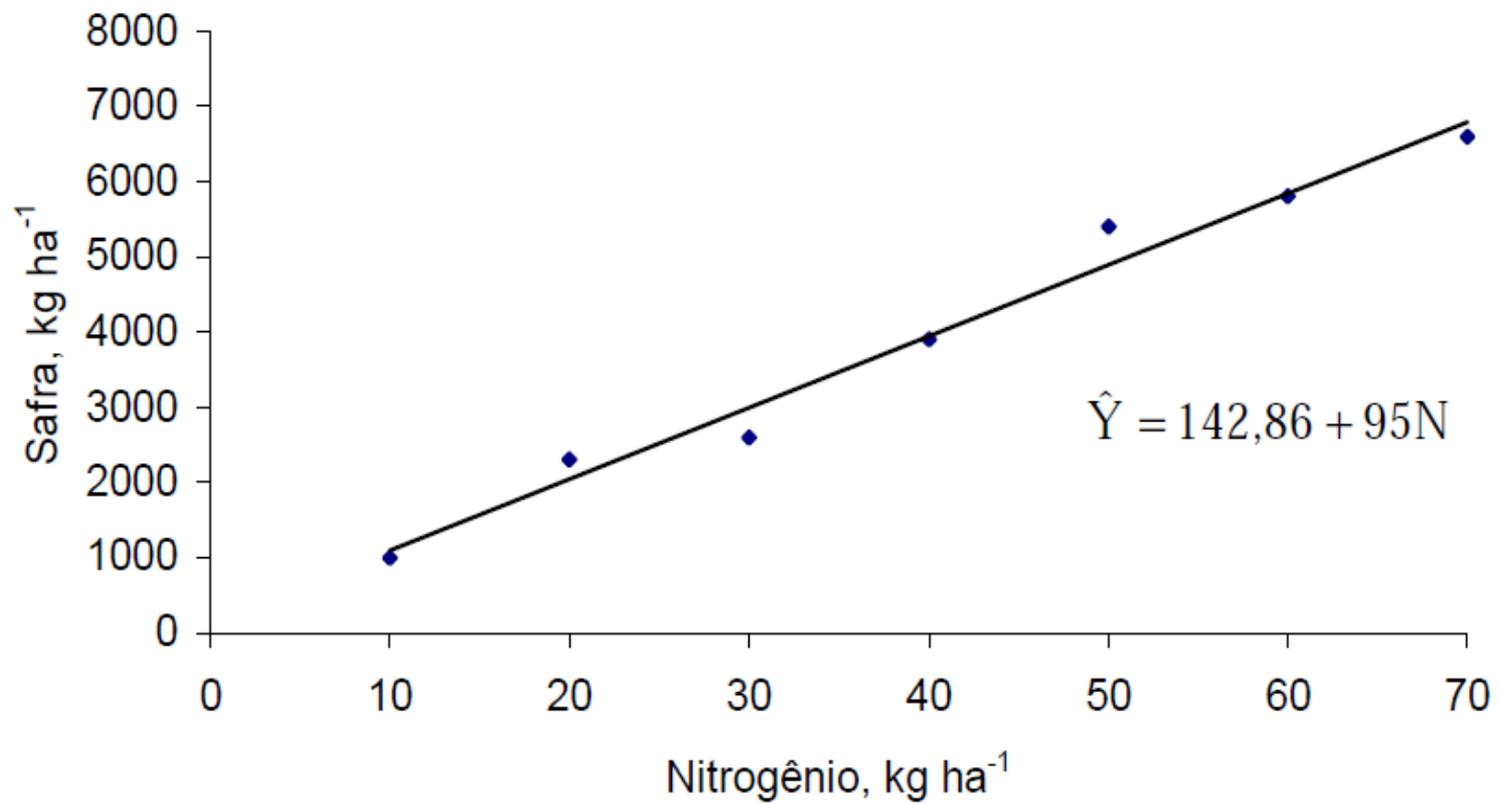


Figura7. Gráfico dos pontos dispersos com a reta ajustada.

# Análise de Variância da Regressão

Para se decidir quão bem o modelo ajustado é adequado à natureza dos dados experimentais, pode-se lançar mão da análise de variância da regressão (ANOVAR).

Para o caso em estudo, a ANOVAR irá particionar a variação total ( $SQD_{tot}$ ) da variável dependente - ou fator resposta - em função das variações nos níveis da variável independente - ou regressor, em duas partes:

- Uma parte associada ao modelo ajustado ( $SQDD_{reg}$ ): soma de quadrados dos desvios devido à regressão, que quantifica o quanto da variação total da safra, provocada pela variação das doses de nitrogênio, é explicada pelo modelo ajustado.
- Uma outra parte associada à falta de ajuste ( $SQDD_{err}$ ): soma de quadrados dos desvios devido ao erro, que quantifica o montante da variação total da safra, provocada pela variação da dose de nitrogênio, que não é explicada pelo modelo ajustado.

Para o exemplo em análise a ANOVAR teria a seguinte estrutura:

Hipóteses:

$$H_0: |\beta_i| = 0 \quad \text{ou} \quad H_0: Y \neq \alpha_0 + \beta X$$

$$H_1: |\beta_i| > 0 \quad \text{ou} \quad H_1: Y = \alpha_0 + \beta X$$

- Significado de  $H_0$ : A equação de regressão não explica a variação da variável dependente  $Y$ , em decorrência da variação da variável independente  $X$ , ao nível de ...% de probabilidade.
- Significado de  $H_1$ : A equação de regressão explica a variação da variável dependente  $Y$ , em decorrência da variação da variável independente  $X$ , ao nível de ...% de probabilidade.

A análise de variância é esquematizada como:

F.V.	G.L.	S.Q.	Q.M.	F	<i>p-value</i>
Modelo	k	SQ(Mod.)	QM(Mod.)	QM(Mod.) / QM(Res.)	p
Resíduo	N-k-1	SQ(Res.)	QM(Res.)		
Total	N-1	SQ(Tot.)			

F.V. – Fontes de Variação, G.L. – Graus de Liberdade, S.Q. – Somas de Quadrados, Q.M. – Quadrados Médios, N – Número de observações, k – número de variáveis independentes.

A estatística F testa a hipótese:  $H_0: B_1=B_2= \dots =B_k=0$  vs  $H_1: B_i \neq B_{i'}$ , para algum  $i \neq i'$ .

O valor p (*p-value*) é obtido supondo que a estatística F tem uma distribuição F central com K e N-k-1 graus de liberdade. Essa pressuposição é válida se os erros forem iid - independentes e identicamente distribuídos, com distribuição normal  $N(0, \sigma^2)$ .

**Para exemplo:**

ANOVAR

Causa da variação	GL	SQD	QMD	$F_{cal}$	Pr
Regressão	1	25.270.000,00	25.270.000,00	239,69	< 0,0001
Erro	5	527.142,86	105.428,57		
Total	6	25.797.142,86			

Conclusão: rejeita-se  $H_0$  ao nível de 5% de probabilidade pelo teste F.

# ANÁLISE DE RESÍDUOS

- É importante, após a análise de regressão, testar se os pressupostos do modelo linear se aplicam aos dados estudados;
- Resíduos representam a diferença entre o valor observado de  $y$  e o que foi predito pelo modelo de regressão;
- A primeira forma de se avaliar resíduos é plotar um gráfico no qual os resíduos  $(y - \hat{Y})$  são colocados no eixo vertical ( $y$ ) e os valores esperados de  $y$  ( $\beta y$ ) no eixo horizontal ( $x$ ).

# Exemplo de Análise completa:

Os dados abaixo são provenientes de um ensaio experimental em que foram utilizadas sete doses de nitrogênio aplicado em cobertura sobre a produtividade de milho. O Experimento foi montado no delineamento inteiramente casualizado, DIC, com cinco repetições. Os dados são fornecidos abaixo:

Quadro 14.2 – Produção de milho, kg ha<sup>-1</sup>

N kg.ha <sup>-1</sup>	Repetições					Totais	Rep.	Médias
	1	2	3	4	5			
10	1.000	916	958	1.084	1.042	5.000	5	1.000
20	2.340	2.220	2.300	2.260	2.380	11.500	5	2.300
30	2.559	2.518	2.682	2.641	2.600	13.000	5	2.600
40	3.976	3.900	3.862	3.938	3.824	19.500	5	3.900
50	5.448	5.304	5.352	5.400	5.496	27.000	5	5.400
60	5.843	5.886	5.800	5.714	5.757	29.000	5	5.800
70	6.600	6.555	6.690	6.510	6.645	33.000	5	6.600
						138.000	35	3.942,86

$$C = (138.000)^2 / 35 = 544.114.285,71$$

$$SQD_{tot} = [(1.000)^2 + (916)^2 + \dots + (6.645)^2] - C = 129.112.384,29$$

$$SQD_{tra} = 1/5 [(5.000)^2 + (11.510)^2 + \dots + (33.000)^2] - C = 128.985.714,29$$

$$SQD_{res} = SQD_{tot} - SQD_{tra} = 129.112.384,29 - 128.985.714,29 = 126.670,00$$

Hipóteses:

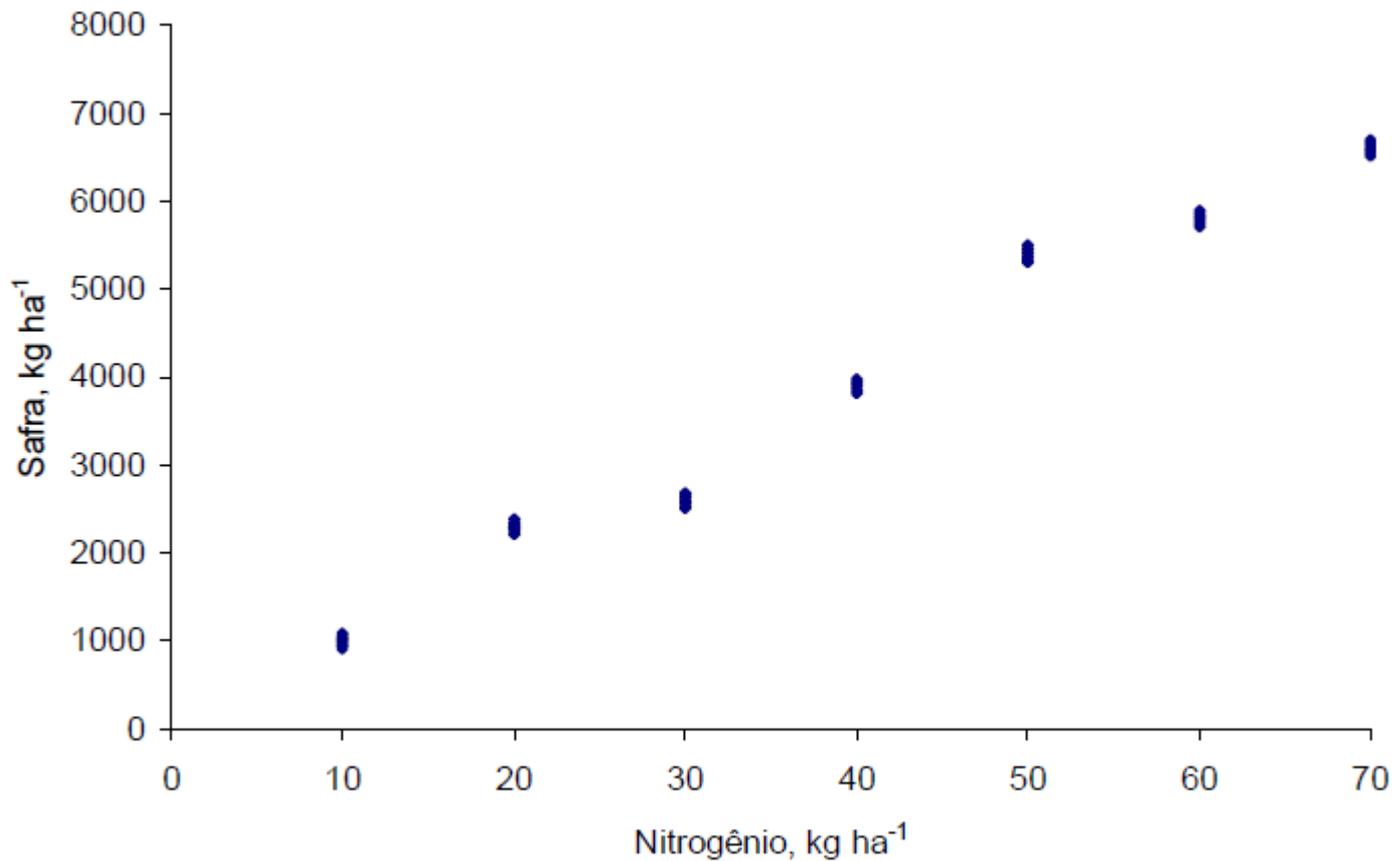
$$H_0: \mu_{10} = \dots = \mu_{70}$$

$H_1$ : Nem todas as médias são iguais

ANOVA

Causa da variação	GL	SQD	QMD	$F_{cal}$	Pr
Tratamentos	6	128.985.714,29	21.497.619,05	4.751,98	< 0,0001
Resíduo	28	126.670,00	4.523,93		
Total	34	129.112.384,29			

Conclusão: rejeita-se  $H_0$  ao nível de significância de 5% pelo teste F.



A visualização dos dados experimentais em um gráfico de dispersão auxilia na escolha do modelo a ser ajustado.

# Ajustando uma Reta

Ajustando um modelo linear:  $\hat{Y} = \alpha_0 + \beta_1 X$

Valores necessários para o ajustamento do modelo linear.

X	$x = X - \bar{X}$ $x = X - 40$	Y	xY	$x^2$
10	-30	1.000	-30.000	900
20	-20	2.300	-46.000	400
30	-10	2.600	-26.000	100
40	0	3.900	0	0
50	10	5.400	54.000	100
60	20	5.800	116.000	400
70	30	6.600	198.000	900

$$\begin{aligned} \sum X &= 280 & \sum Y &= 27.600 \\ \bar{X} &= \frac{1}{N} \sum X & \bar{Y} &= \frac{1}{N} \sum Y \\ \bar{X} &= \frac{280}{7} = 40 & \bar{Y} &= \frac{27.600}{7} \\ & & \sum xY &= 266.000 & \sum x^2 &= 2.800 \\ & & \bar{Y} &= 3.942,86 \end{aligned}$$

**Recomenda-se trabalhar com o máximo possíveis de casas decimais.**

$$\hat{\alpha} = \frac{\sum Y_i}{n} = \bar{Y} \quad \therefore \quad \hat{\alpha} = \frac{27.600}{7} = 3.942,86$$

$$\hat{\beta} = \frac{\sum x_i Y_i}{\sum x_i^2} \quad \therefore \quad \hat{\beta} = \frac{266.000}{2.800} = 95,00$$

$$\hat{Y} = 3.942,86 + 95x$$

$$\hat{Y} = 3.942,86 + 95x \quad \therefore \quad x = (X - \bar{X})$$

$$\hat{Y} = 3.942,86 + 95(X - \bar{X})$$

$$\hat{Y} = 3.942,86 + 95(X - 40)$$

$$\hat{Y} = 3.942,86 + 95X - 3.800$$

Equação da reta ajustada:

$$\hat{Y} = 142,86 + 95X$$

# Análise de Variância da Regressão: ANOVAR

## ANOVAR

Causa da variação	GL
Regressão	1
Erro	5
Total	6

Para se decidir quão bem o modelo ajustado é adequado à natureza dos dados experimentais, pode-se lançar mão da análise de variância da regressão (ANOVAR).

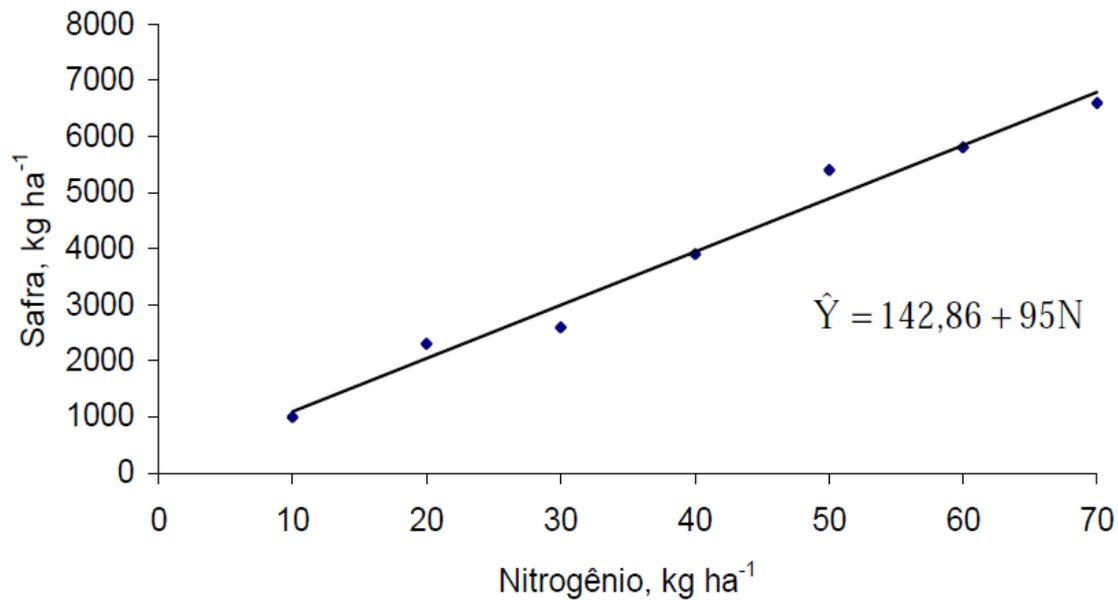
Para o caso em estudo, a ANOVAR irá particionar a variação total (SQD<sub>tot</sub>) da variável dependente - ou fator resposta - em função das variações nos níveis da variável independente - ou regressor, em duas partes:

- Uma parte associada ao modelo ajustado (SQDD<sub>reg</sub>)
- Uma outra parte associada à falta de ajuste (SQDD<sub>err</sub>)

$$\text{Quadrado médio dos desvios} = s^2 = \frac{SQD}{n-1} \therefore SQD = \sum (Y_i - m)^2$$

Vejamos<sup>1</sup>:

N , kg ha <sup>-1</sup>	Safra_Obs	Safra_Est
10	1.000	1092,86
20	2.300	2042,86
30	2.600	2992,86
40	3.900	3942,86
50	5.400	4892,86
60	5.800	5842,86
70	6.600	6792,86



**SQDtot**

Obs	$m_{(Obs)}$	$Obs - m_{(Obs)}$	$[Obs - m_{(Obs)}]^2$
1.000	3.942,86	-2.942,86	8.660.408,16
2.300	3.942,86	-1.642,86	2.698.979,59
2.600	3.942,86	-1.342,86	1.803.265,31
3.900	3.942,86	-42,86	1.836,73
5.400	3.942,86	1.457,14	2.123.265,31
5.800	3.942,86	1.857,14	3.448.979,59
6.600	3.942,86	2.657,14	7.060.408,16
			<hr/> 25.797.142,86

**SQDreg**

Est	$m_{(Est)}$	$Est - m_{(Est)}$	$[Est - m_{(Est)}]^2$
1.093	3.942,86	-2.850,00	8.122.500,00
2.043	3.942,86	-1.900,00	3.610.000,00
2.993	3.942,86	-950,00	902.500,00
3.943	3.942,86	0,00	0,00
4.893	3.942,86	950,00	902.500,00
5.843	3.942,86	1.900,00	3.610.000,00
6.793	3.942,86	2.850,00	8.122.500,00
			<hr/> 25.270.000,00

### SQDerr

Obs	Est	Erro(Obs-Est)	$m_{(Erro)}$	Erro- $m_{(Erro)}$	$[Erro-m_{(Erro)}]^2$
1.000	1.092,86	-92,86	0,00	-92,86	8.622,45
2.300	2.042,86	257,14	0,00	257,14	66.122,45
2.600	2.992,86	-392,86	0,00	-392,86	154.336,73
3.900	3.942,86	-42,86	0,00	-42,86	1.836,73
5.400	4.892,86	507,14	0,00	507,14	257.193,88
5.800	5.842,86	-42,86	0,00	-42,86	1.836,73
6.600	6.792,86	-192,86	0,00	-192,86	37.193,88
					<b>527.142,86</b>

### ANOVAR

Causa da variação	GL	SQD	QMD	$F_{cal}$	Pr
Regressão	1	25.270.000,00	25.270.000,00	239,69	< 0,0001
Erro	5	527.142,86	105.428,57		
Total	6	25.797.142,86			

# Cálculos alternativos da soma de quadrados dos desvios

$$SQD_{tot} = \sum Y_i^2 - \frac{(\sum Y_i)^2}{n}$$

$$SQD_{reg} = \hat{\alpha}_0 \sum Y_i + \hat{\beta} \sum X_i Y_i - \frac{(\sum Y_i)^2}{n}$$

$$SQD_{err} = SQD_{tot} - SQD_{reg}$$

X	Y	Y <sup>2</sup>	XY
10	1.000	1.000.000	10.000
20	2.300	5.290.000	46.000
30	2.600	6.760.000	78.000
40	3.900	15.210.000	156.000
50	5.400	29.160.000	270.000
60	5.800	33.640.000	348.000
70	6.600	43.560.000	462.000
	27.600	134.620.000	1.370.000

$$SQD_{tot} = \sum Y_i^2 - \frac{(\sum Y_i)^2}{n} = 134.620.000 - \frac{(27.600)^2}{7} = 25.797.142,86$$

$$SQD_{reg} = \hat{\alpha}_0 \sum Y_i + \hat{\beta} \sum X_i Y_i - \frac{(\sum Y_i)^2}{n}$$

$$SQD_{reg} = 142,85714286 \times 27.600 + 95 \times 1.370.000 - \frac{(27.600)^2}{7}$$

$$SQD_{reg} = 25.270.000$$

$$SQD_{err} = SQD_{tot} - SQD_{reg}$$

$$SQD_{err} = 25.797.142,86 - 25.270.000$$

$$SQD_{err} = 527.142,86$$

Ilustração da ANOVAR apenas para efeito de comparação com a ANOVA:

ANOVAR

Causa da variação	GL	SQD	QMD	F <sub>cal</sub>	Pr
Regressão	1	25.270.000,00	25.270.000,00	239,69	< 0,0001
Erro	5	527.142,86	105.428,57		
Total	6	25.797.142,86			

# Coeficiente de determinação da Regressão:

$$r^2 = \frac{SQD_{reg}}{SQD_{tot}} \quad \therefore \quad 0 \leq r^2 \leq 1$$

$$r^2 = \frac{25.270.000,00}{25.797.142,86} = 0,9796 = 97,96\%$$

Observa-se que a soma de quadrados, e os respectivos graus de liberdade, associados a tratamentos foram desdobrados em duas partes:

Uma parte associada ao modelo de regressão utilizado ( $\hat{Y} = 142,86 + 95N$ ).

Uma parte associada à falta de ajuste ou erro de ajustamento:

Para a obtenção da soma de quadrados do devido à regressão e ao independente da regressão tem-se duas opções:

- Realizar todos os cálculos das somas de quadrados dos desvios considerando agora todas as repetições, o que embora possa ser feito, é um processo mais trabalhoso.
- Utilizar o teorema do limite central (que facilita bastante os cálculos):

# Teorema do limite central:

$$Var(m) = \frac{\sigma^2}{n} \quad \therefore \quad \sigma^2 = Var(m) \times n$$

$$SQD(m) = \frac{SQD}{n} \quad \therefore \quad SQD = SQD(m) \times n \quad \therefore \quad \text{Como } n = r$$

$$SQDDreg = 25.270.000,00 \times 5 = 126.350.000,00$$

$$SQDDireg = 527.142,86 \times 5 = 2.635.714,29$$

## ANOVA

Causa da variação	GL	SQD	QMD	F <sub>cal</sub>	Pr
Tratamentos	(6)	(128.985.714,29)			
Dev. regressão	1	126.350.000,00	126.350.000,00	27.929,26	< 0,0001
Ind. regressão	5	2.635.714,29	527.142,86	116,52	< 0,0001
Resíduo	28	126.670,00	4.523,93		
Total	34	129.112.384,29			

**Conclusão: rejeita-se H0 ao nível de significância de 5% pelo teste F.**

# Critérios para decisão de um modelo ajustado e considerações finais

## ANOVA

Causa da variação	GL	SQD	QMD	F <sub>cal</sub>	Pr
Tratamentos	(6)	(128.985.714,29)			
Dev. regressão	1	126.350.000,00	126.350.000,00	27.929,26	< 0,0001
Ind. regressão	5	2.635.714,29	527.142,86	116,52	< 0,0001
Resíduo	28	126.670,00	4.523,93		
Total	34	129.112.384,29			

**Conclusão: rejeita-se H<sub>0</sub> ao nível de significância de 5% pelo teste F.**

- O modelo é adequado à natureza do fenômeno em estudo, ou adequado ao que se sabe sobre o fenômeno?
- O coeficiente de determinação ( $r^2$ ) é elevado?
- No quadro final da análise de variância o efeito do devido a regressão é significativo?
- No quadro final da análise de variância o efeito do devido ao independente da regressão é não significativo?

# REGRESSÃO LINEAR MÚLTIPLA

- A análise de uma regressão múltipla segue, basicamente, os mesmos critérios da análise de uma regressão simples.
- A regressão múltipla envolve três ou mais variáveis, portanto, estimadores. Ou seja, ainda uma única variável dependente, porém duas ou mais variáveis independentes .
- A finalidade das variáveis independentes adicionais é melhorar a capacidade de predição em confronto com a regressão linear simples.

# USOS DA REGRESSÃO MÚLTIPLA

- Ajustar dados estudando o efeito de uma variável  $X$ , levando em conta outras variáveis independentes.
- Obter uma equação para prever valores de  $Y$  a partir dos valores de várias variáveis  $X_1, X_2, \dots, X_k$ .
- Explorar as relações entre múltiplas variáveis ( $X_1, X_2, \dots, X_k$ ) para determinar que variáveis influenciam  $Y$ .

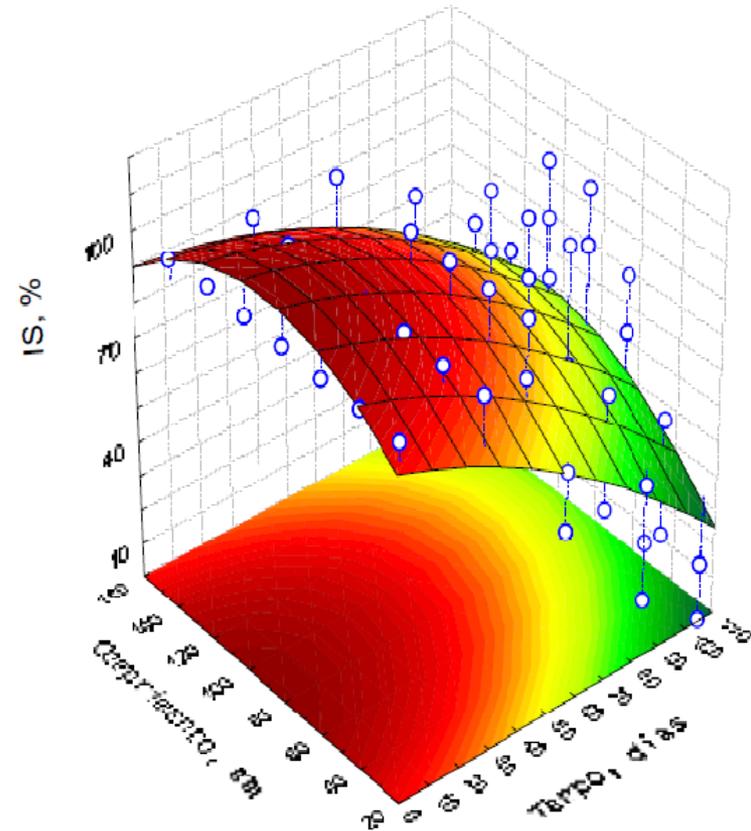
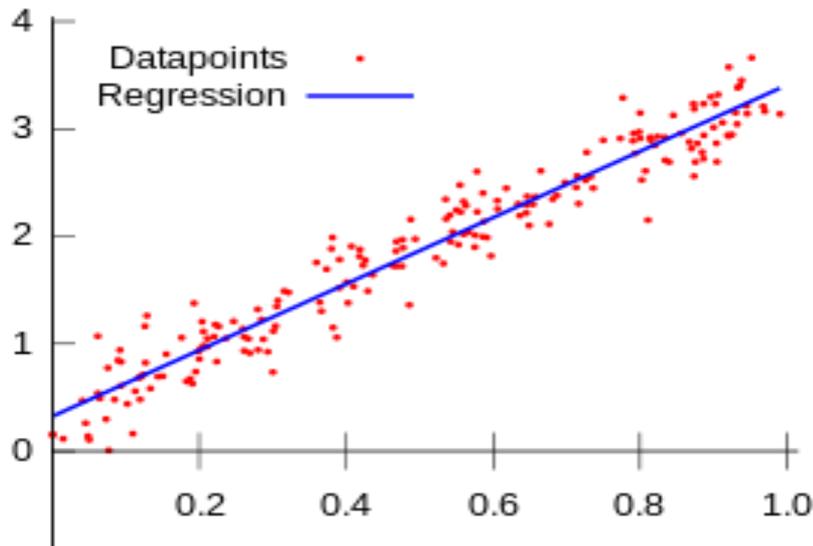
# MODELO MATEMÁTICO

$$Y_c = a + b_1x_1 + b_2x_2 + \dots + b_kx_k$$

Onde:

- $Y_c$  = variável dependente;
- $a$  = intercepto do eixo  $y$ ;
- $b$  = coeficiente angular da  $i$ -ésima variável;
- $k$  = número de variáveis independentes.

- Enquanto uma regressão simples de duas variáveis resulta na equação de uma reta, um problema de três variáveis implica num plano, e um problema de  $k$  variáveis implica em um hiperplano;



- Também na regressão múltipla, as estimativas dos mínimos quadrados são obtidas pela escolha dos estimadores que minimizam a soma dos quadrados dos desvios entre os valores observados  $Y_i$  e os valores ajustados  $Y_c$ .

# SOLUÇÃO DOS MÍNIMOS QUADRADOS

- A solução dos mínimos quadrados é a que minimiza a soma dos quadrados dos desvios entre os valores observados e a superfície de regressão ajustada.

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_k X_{ki}))^2$$

# COEFICIENTE DE DETERMINAÇÃO

- O **coeficiente de determinação múltipla** é uma medida de quão bem a equação e regressão múltipla se ajusta aos dados amostrais:
  - Ajuste perfeito:  $r^2 = 1$ .
  - Ajuste bom:  $r^2 =$  prox. de 1.
  - Ajuste pobre:  $r^2 =$  prox. 0.
- Defeito: Na medida em que mais variáveis são incluídas,  $r^2$  cresce (pela simples inclusão de todas as variáveis disponíveis);
- Por causa dessa falha, a comparação de diferentes equações é feita mais adequadamente com o ajuste do coeficiente de determinação para o número de variáveis e o tamanho amostral.

# REGRESSÃO NÃO LINEAR

- Os dados são modelados por uma função que é uma combinação não-linear de parâmetros do modelo e depende de uma ou mais variáveis independentes.
- Pode a partir de suposições importantes sobre o problema trabalhar no sentido de obter uma relação teórica entre as variáveis observáveis de interesse.
- Diferentemente do caso linear, é que os parâmetros entram na equação de forma não linear, assim, nós não podemos simplesmente aplicar fórmulas para estimar os parâmetros do modelo.

# Exemplo:

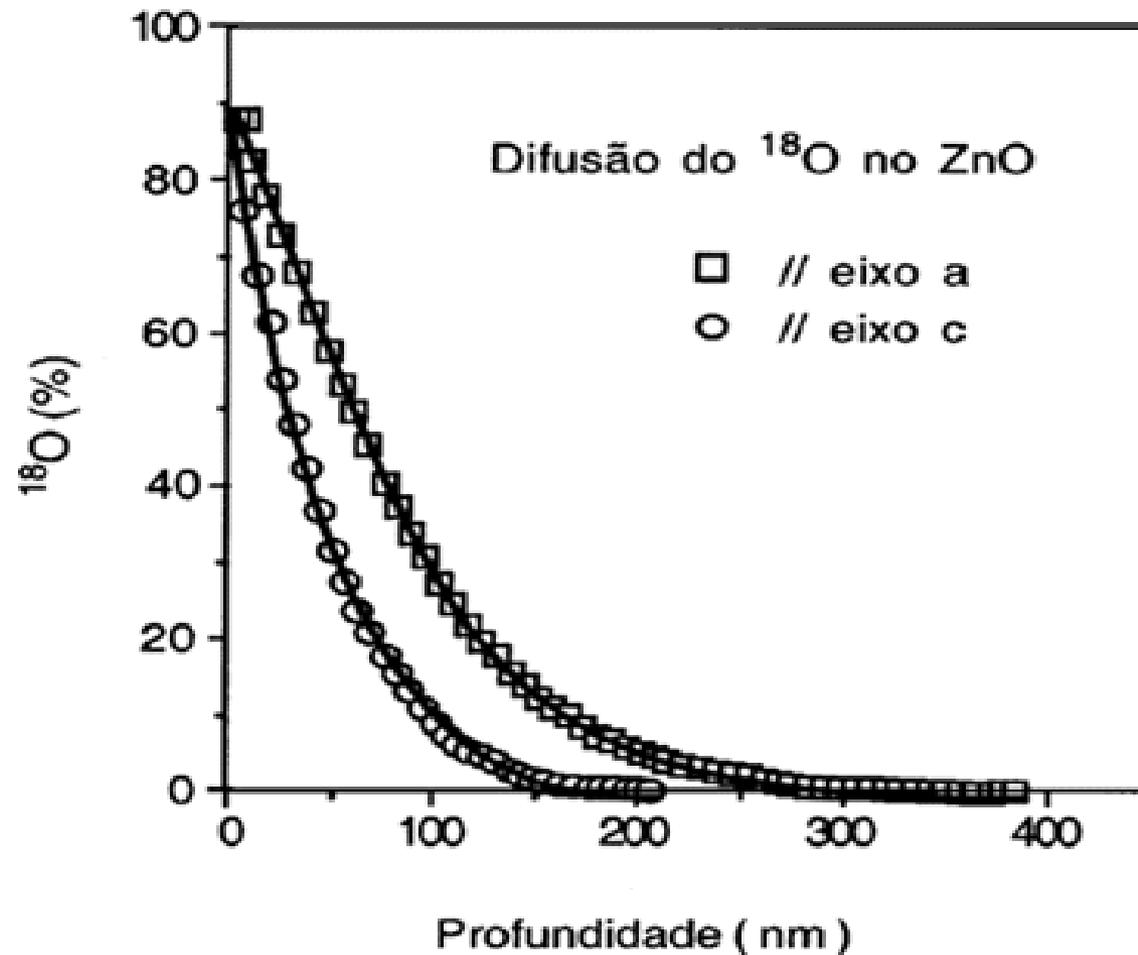


Figura 5: Anisotropia da difusão do oxigênio no ZnO monocristalino [14].

# REFERÊNCIAS BIBLIOGRÁFICAS

- FARIA, J.C. **Notas de aulas expandidas.** Ilhéus, UESC, 2006.
- Wonnacott, Thomas H. **Estatística aplicada a economia e a administração** / Thomas H Wonnacott e Ronald J. Wonnacott, 1981



**Obrigado !**