

# Correlação e Regressão



Análise de dados. Tópico 1

Prof. Dr. Ricardo Primi & Prof. Dr. Fabian Javier Marin Rueda

Adaptado de

Gregory J. Meyer, University of Toledo, USA; Apresentação na  
Universidade e São Francisco, São Paulo, Brasil

31 Julho, 2007

# Correlação e Regressão

↗ Mensura a relação entre variáveis

Correlação = co-relação = co-variância =  $r$

↗ Geralmente examina variáveis bidimensionais

↗ Mas diferenças de média entre grupos também podem ser expressas por meio da co-relação

↗ e.g.,

VI = Diagnóstico: Transtorno Psicótico (codificado como 1) vs. outros transtornos (codificados como 0)

VD = X-% como um índice de Acurácia Perceptual

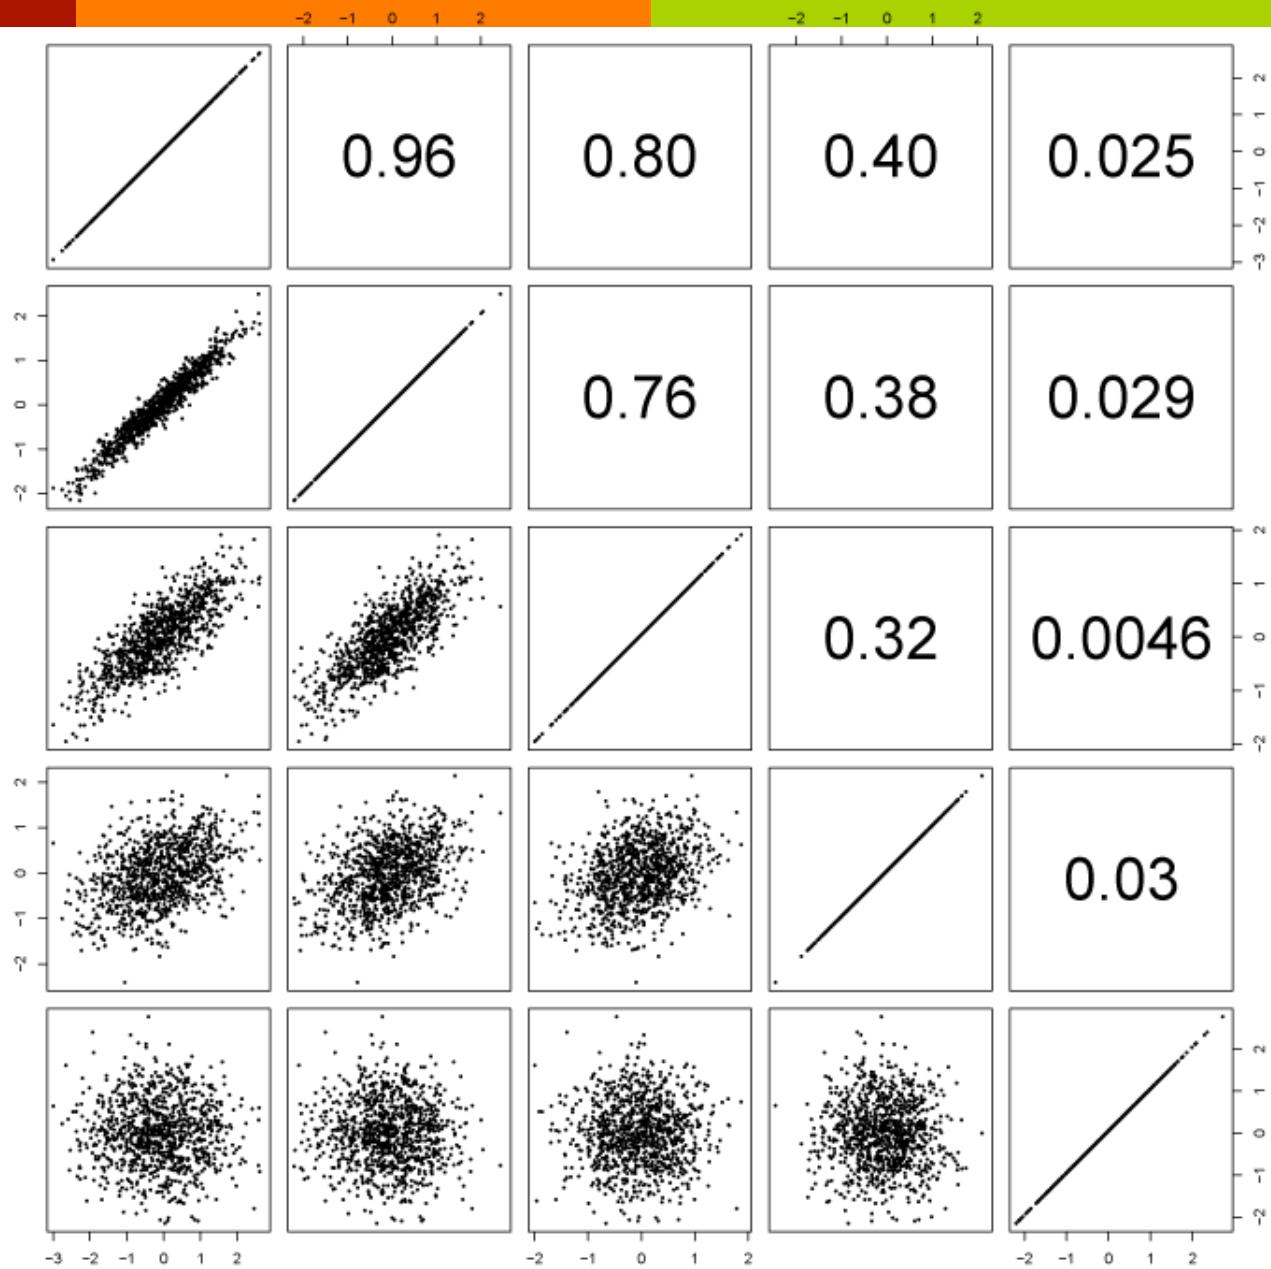
↗  $t$ -test comparando  $M_{\text{Psychotic}}$  vs.  $M_{\text{Other}}$  de X-% pode ser expressa como a  $r$  do Diagnóstico com X-%

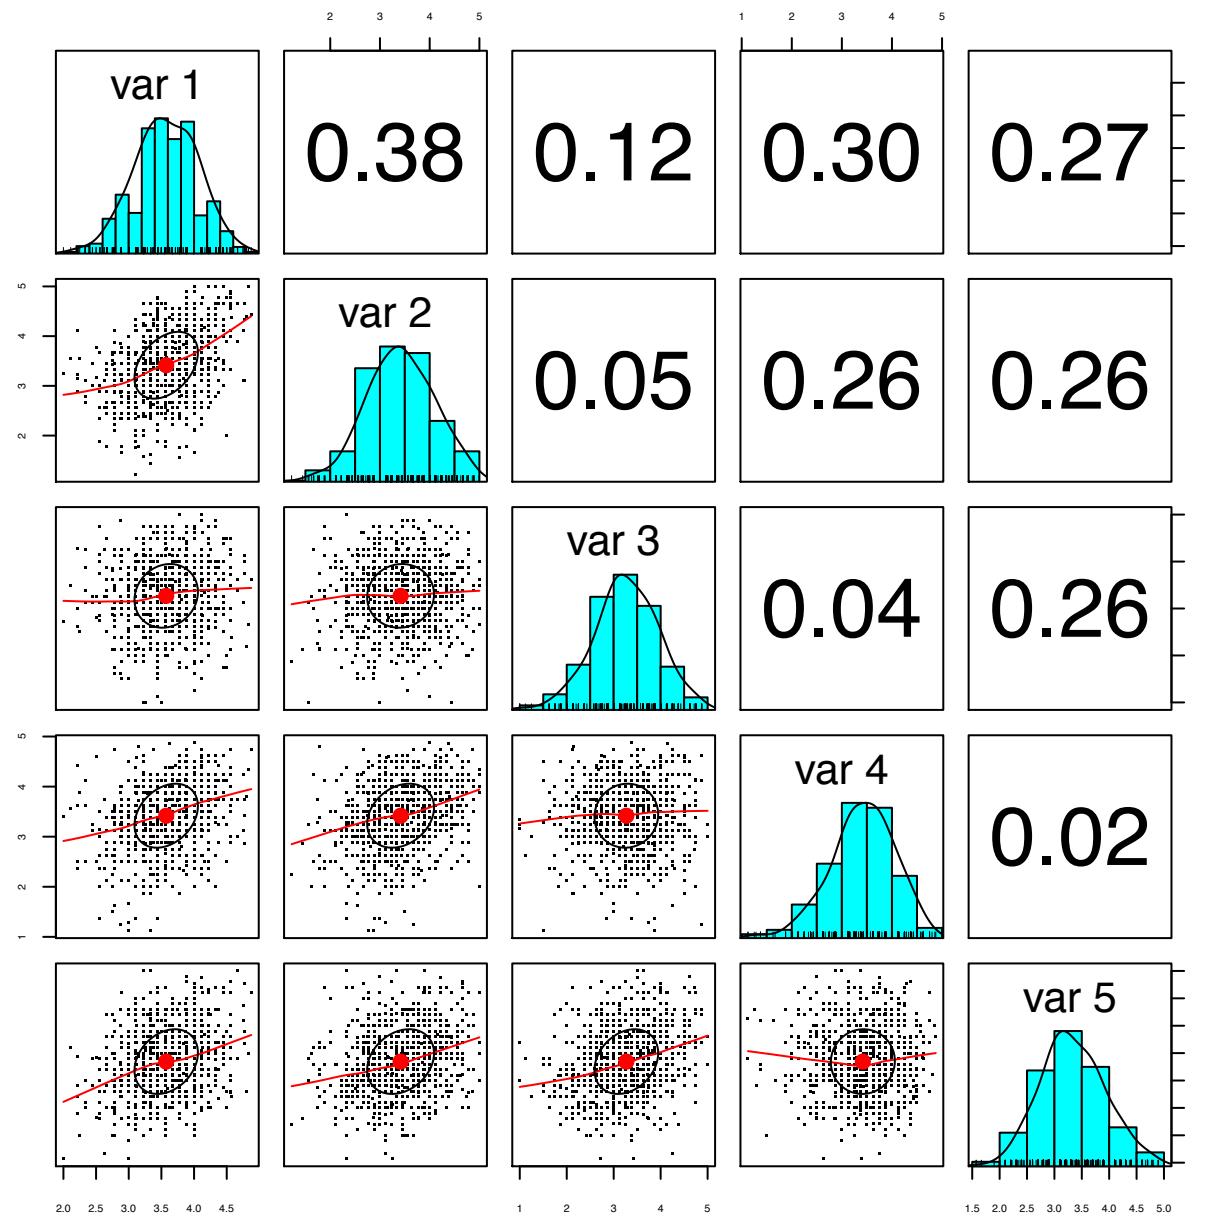
↗ i.e.,  $r_{\text{Diagnóstico-X-}%}$

↗  $r$  e  $t$  terão o mesmo valor de  $p$  ou de significância estatística

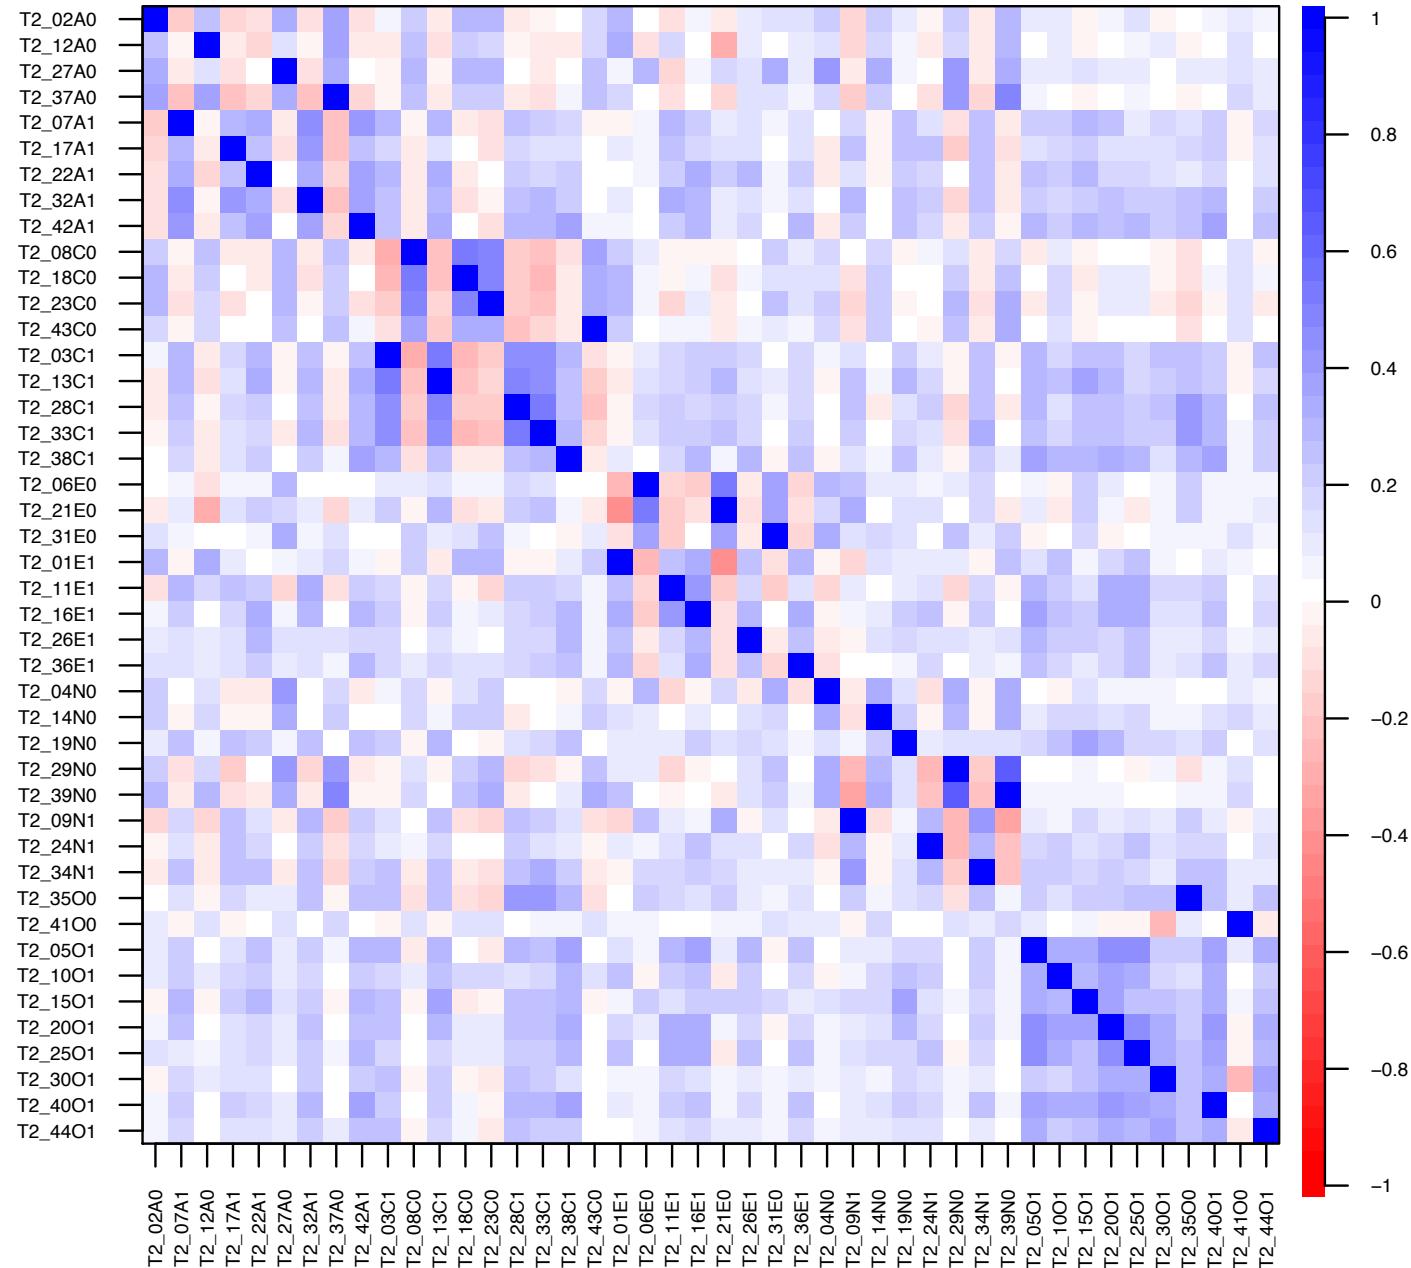
# Correlação e Regressão

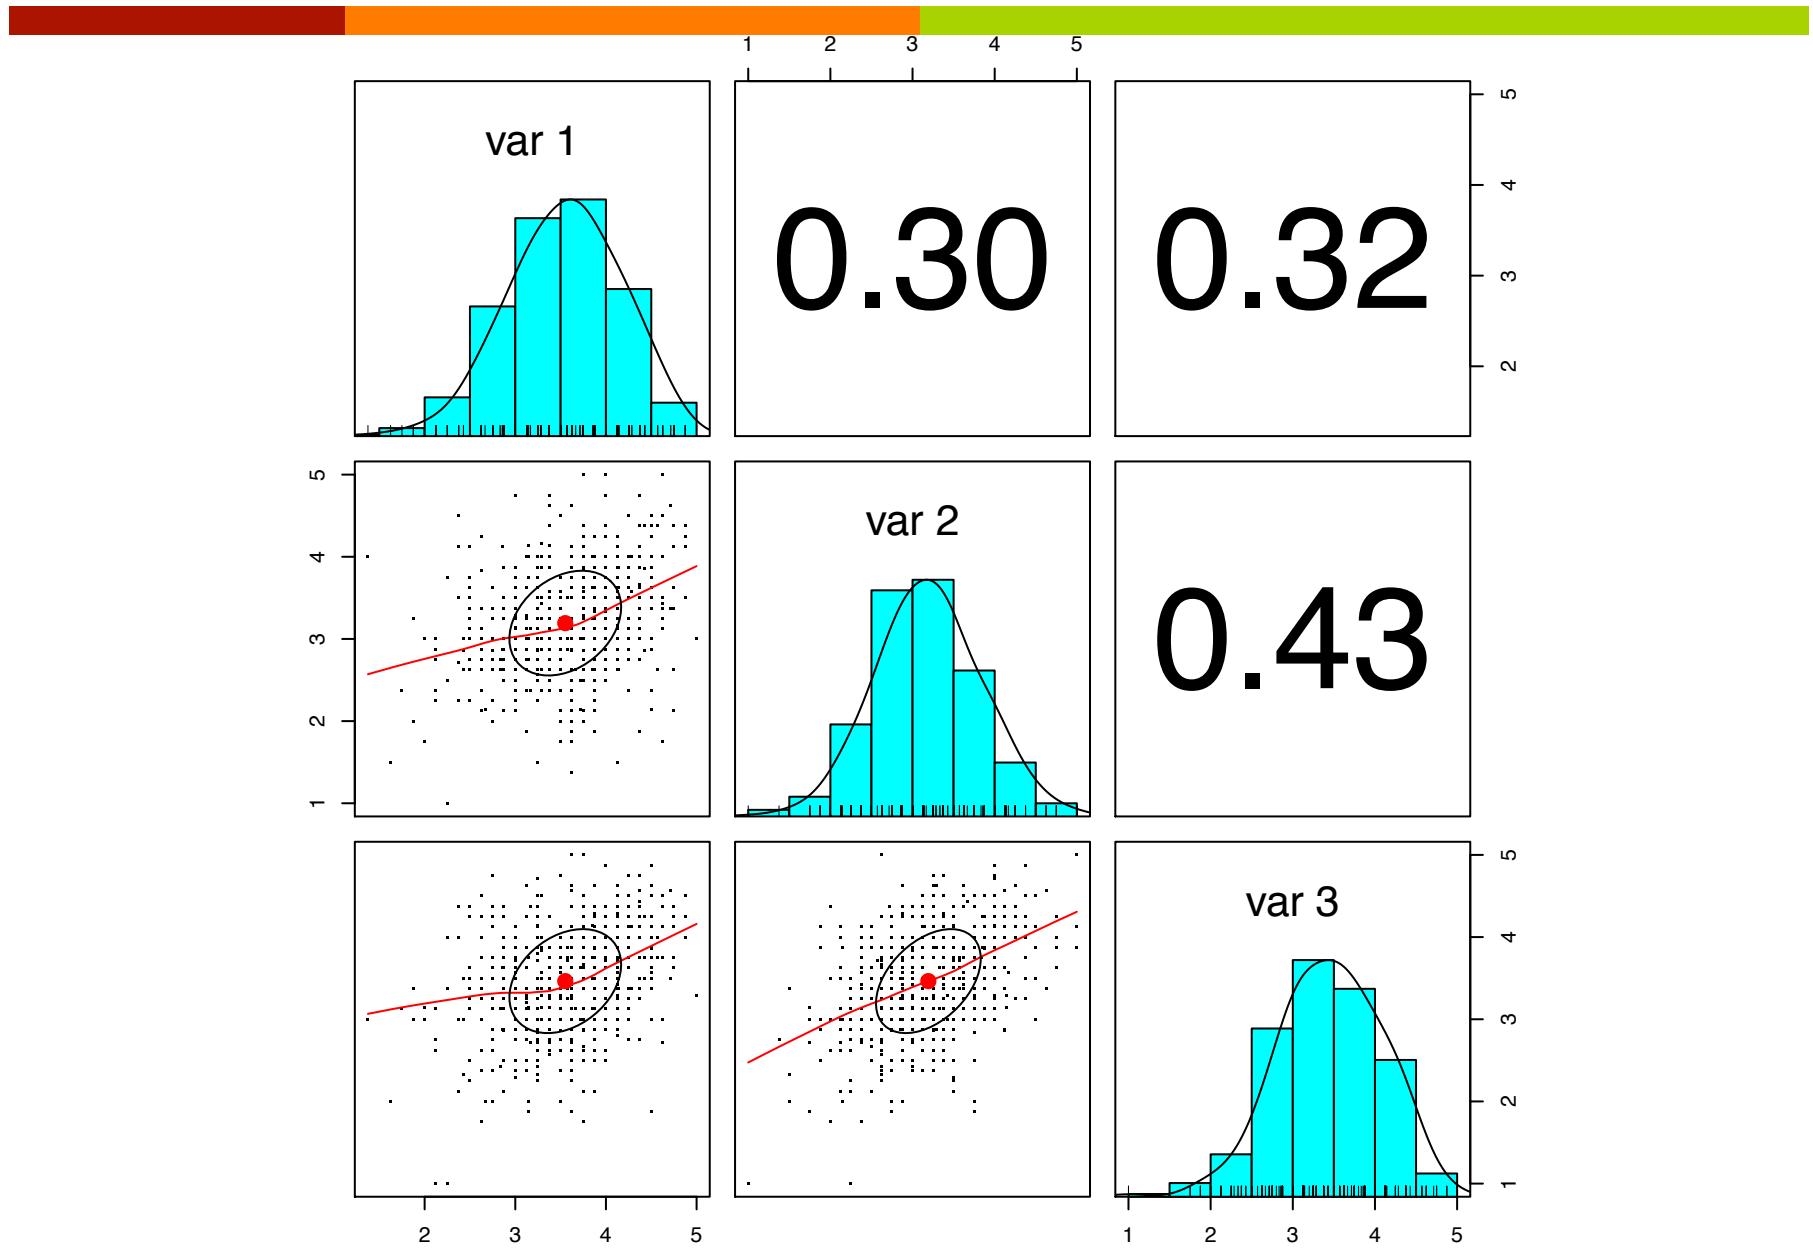
- ↗ Em geral as medidas estão associadas por relações lineares
  - ↗ Mas existem técnicas para correlações e regressões não lineares
- ↗ Correlação ≠ Causalidade
- ↗  $r's$  assumem valores entre -1.0 e +1.0
  - ↗ O sinal mostra a direção das relações
  - ↗ Os valores absolutos mostram a magnitude da relação
    - ↗ 0.0 = ausência de relação
    - ↗ -1.0 or +1.0 = relação perfeita
- ↗ Visualizando as magnitudes das correlações
  - ↗ "ForcedDegreeofCorrelation.sps"



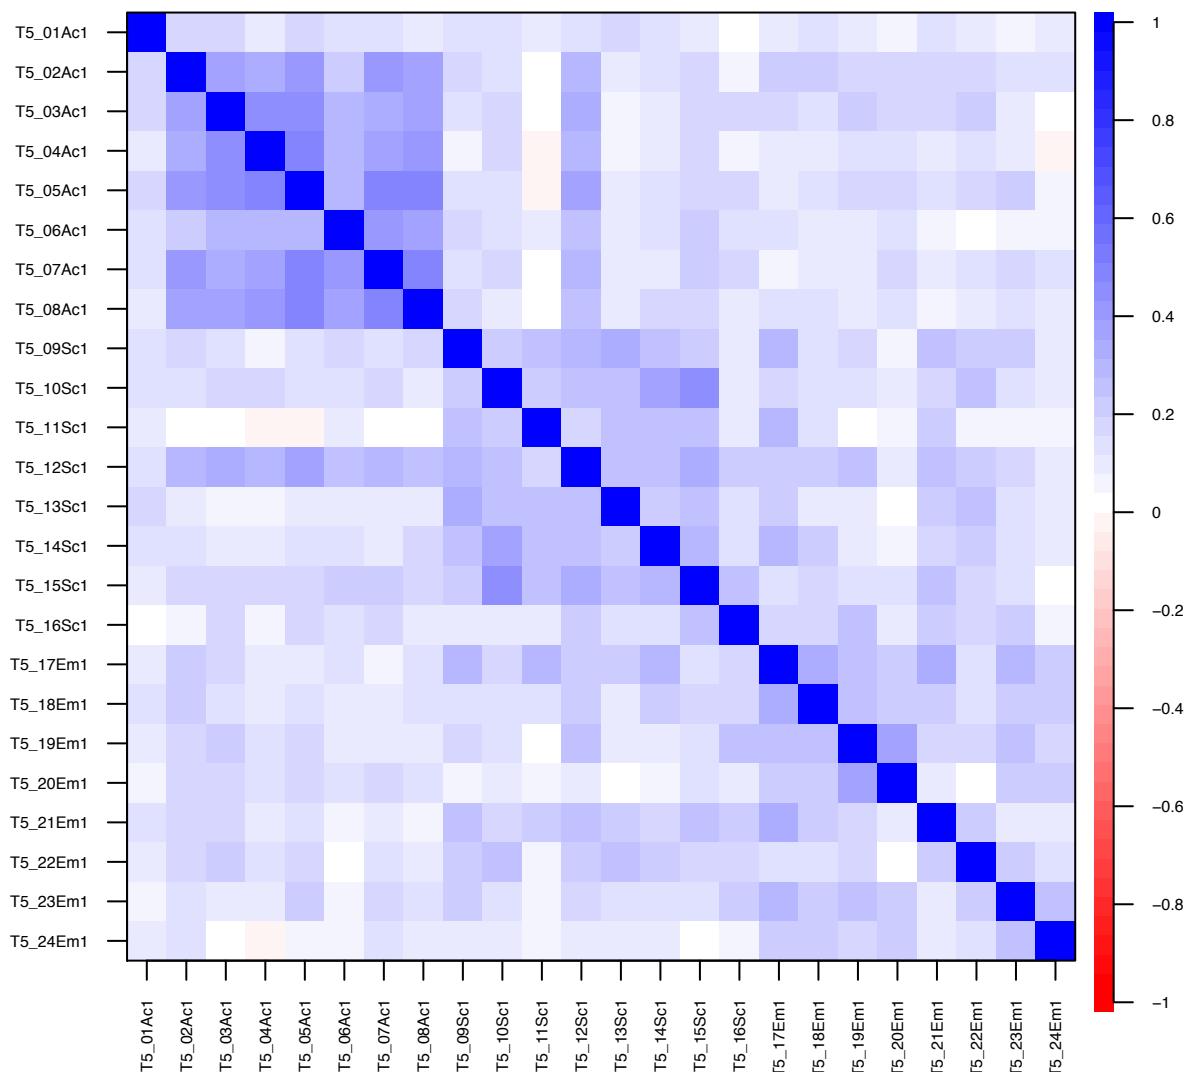


## Correlation plot

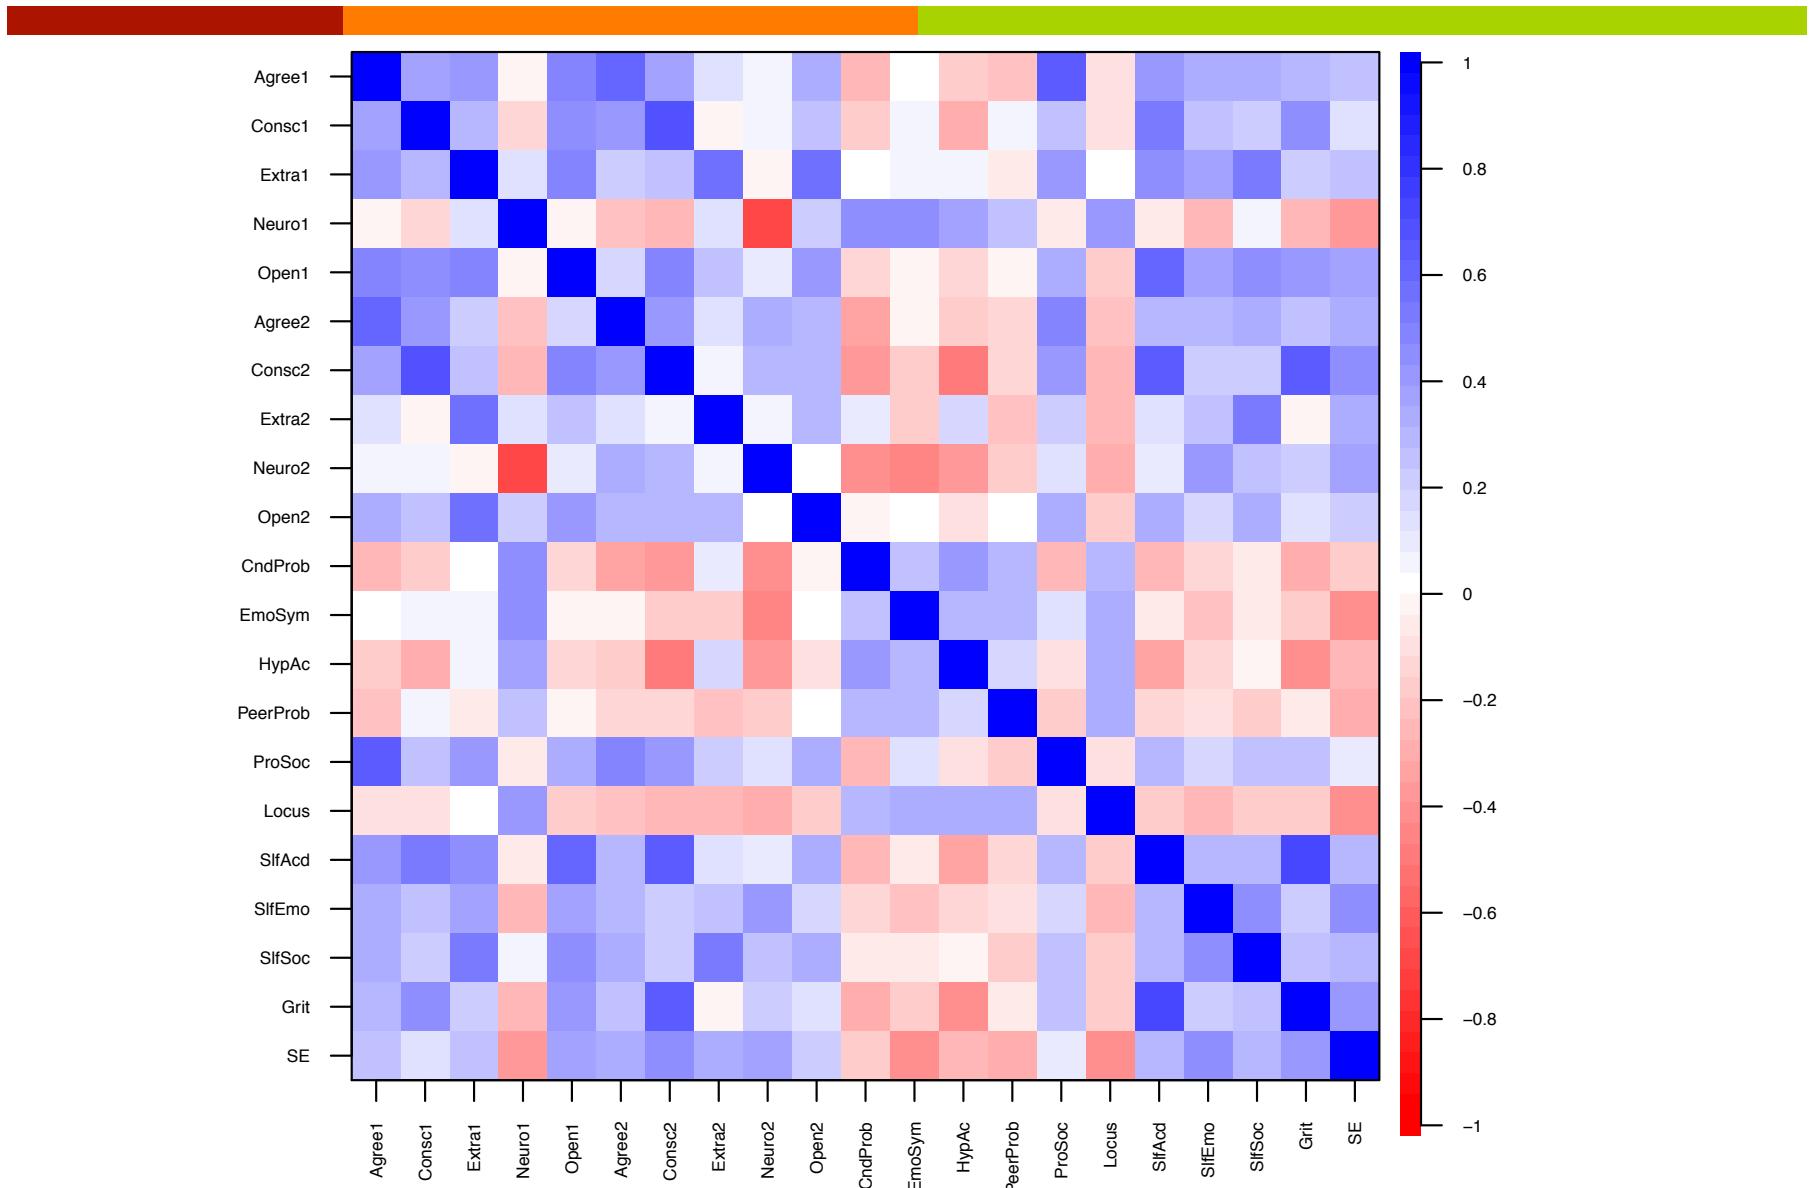


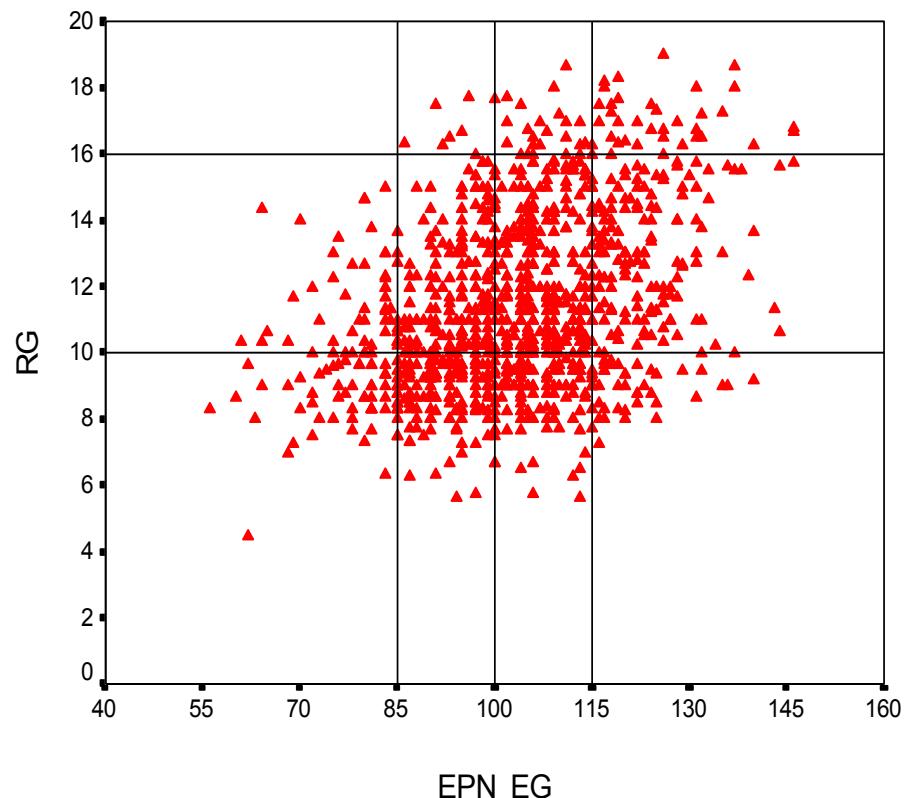
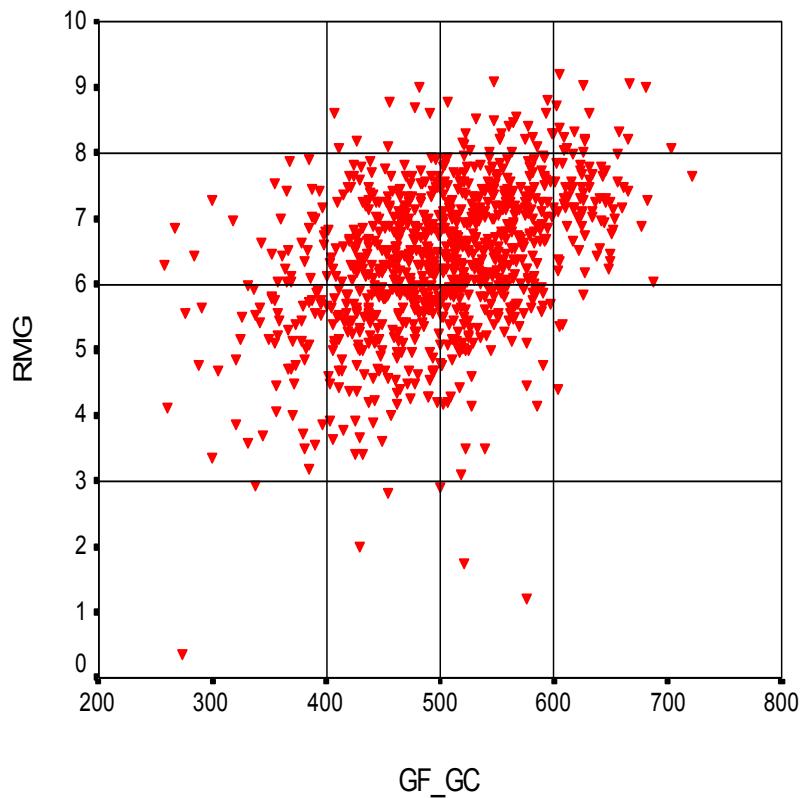


## Correlation plot



## Correlation plot





# Correlação e Regressão

- ↗ Distinção estatística
  - ↗ Correlação
    - ↗ 2 variáveis randômicas,  $X$  e  $Y$
    - ↗ Nenhuma delas está sob controle do experimentador
  - ↗ Regressão:
    - ↗ 1 variável fixa ( $X$ ), 1 variável randômica ( $Y$ )
    - ↗ se presume  $X$  que está sobre controle do experimentador e somente os valores que interessam são estudados
- ↗ Essa distinção é precisa tecnicamente mas não necessária no utilização prática das correlações e regressões

# Fórmula

$$r = \frac{\sum_{i=1}^N \left( \frac{(x_i - \bar{x})}{s_x} \right) \left( \frac{(y_i - \bar{y})}{s_y} \right)}{(N - 1)}$$

$$r = \frac{\sum_{i=1}^N z_{x_i} z_{y_i}}{N - 1}$$

# Produto-momento!

- ↗ A média do produto de dois momentos indicando co-relação
- ↗ Produto : multiplicação de duas variáveis (X, Y)
- ↗ Momento: função aplicada a média de desvios
- ↗ Momentos centrais: : 1º = Média, 2º = Variancia, 3º = Assimetria, 4º = Kurtose
- ↗ Os escores z são momentos
- ↗ Desvios da média em unidades de desvio padrão
- ↗ Co-relação: ocorrência simultânea together
- ↗ z para X pareado com z para Y
- ↗ Então a correlação Produto-Momento de Pearson ( $r$ ) é a magnitude média em que pares de escores (X, Y) se correlacionam por desviarem simultaneamente de suas respectivas médias

$$z = \frac{(X - \bar{X})}{\sigma}$$

$$r = \frac{\sum z_X z_Y}{N}$$

## Coeficiente de Correlação de Pearson - Produto Momento

| n  | Nota A | $x = X - \bar{X}$ | $ x $ | $x^2$ | $z = \frac{(X - \bar{X})}{S}$ | Nota B | $y = Y - \bar{Y}$ | $ y $ | $y^2$ | $z = \frac{(Y - \bar{Y})}{S}$ | $z^2$ |
|----|--------|-------------------|-------|-------|-------------------------------|--------|-------------------|-------|-------|-------------------------------|-------|
| 1  | 2      |                   |       |       |                               | 3      |                   |       |       |                               |       |
| 2  | 2      |                   |       |       |                               | 2      |                   |       |       |                               |       |
| 3  | 4      |                   |       |       |                               | 5      |                   |       |       |                               |       |
| :  | :      |                   |       |       |                               | :      |                   |       |       |                               |       |
| 9  | 9      |                   |       |       |                               | 7      |                   |       |       |                               |       |
| 10 | 10     |                   |       |       |                               | 7      |                   |       |       |                               |       |
| 11 | 9      |                   |       |       |                               | 6      |                   |       |       |                               |       |
| 12 | 9      |                   |       |       |                               | 8      |                   |       |       |                               |       |

$$r = \frac{\sum z_x z_y}{N-1}$$

$z = \frac{(X - \bar{X})}{S}$        $z = \frac{(Y - \bar{Y})}{S}$   
 $x = X - \bar{X}$        $y = Y - \bar{Y}$   
 $S = \sqrt{\frac{\sum (X - \bar{X})^2}{N-1}}$   
 $x^2 = (X - \bar{X})(X - \bar{X})$

# Correlação e Regressão

## ↗ Distinção Prática

### ↗ Correlação:

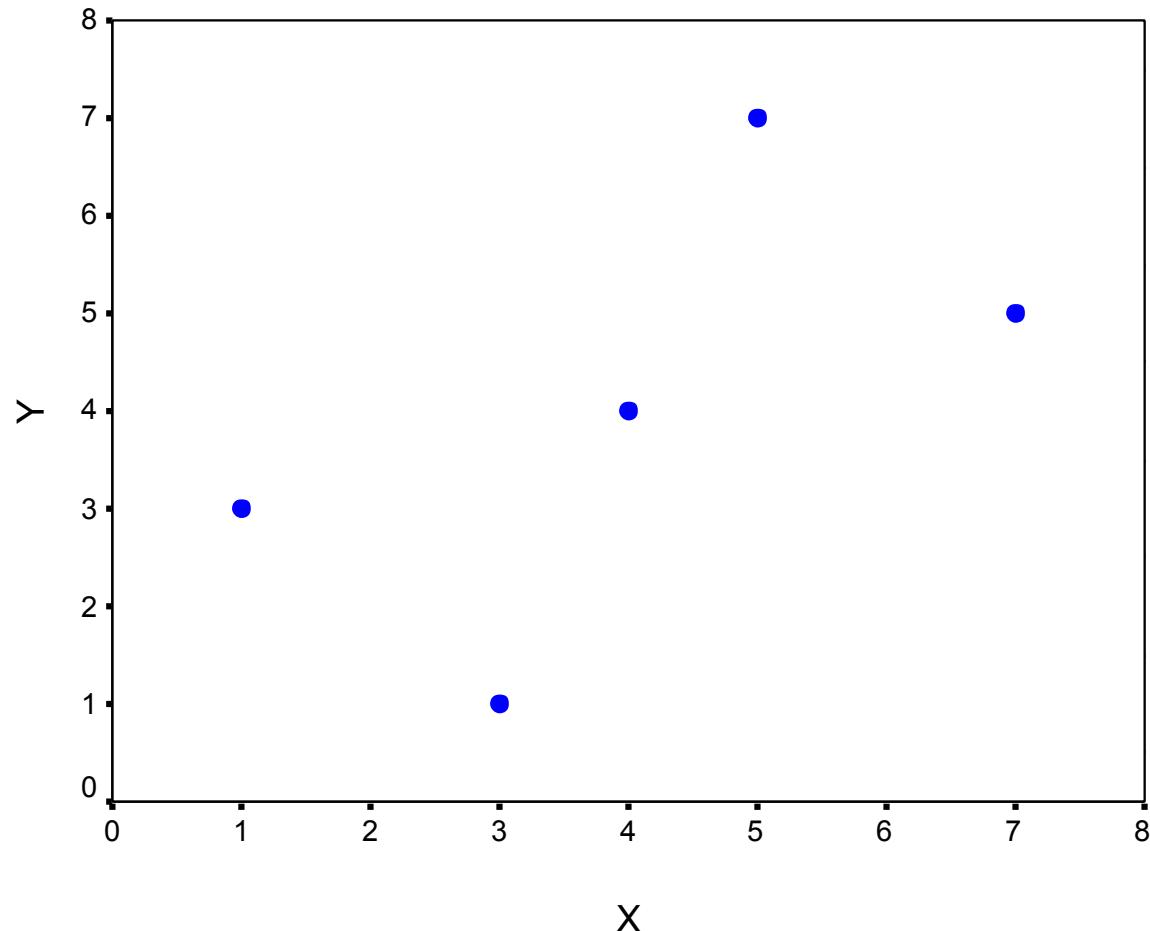
- ↗ Magnitude de associação entre  $X$  e  $Y$
- ↗ Ambas podem ser desenhadas no eixo horizontal (abscissa) porque ambas poderiam ser designadas como  $X$

### ↗ Regressão:

- ↗ Usa a associação para desenvolver uma equação que prevê  $Y$  a partir de  $X$  a partir da melhor forma possível.
- ↗ "Regride  $Y$  em  $X$ "
- ↗ Desenha  $X$  no eixo horizontal;  $Y$  no eixo vertical (ordenada)

# $r$ Produto Momento: Exemplo

| ID       | X    | Y    |
|----------|------|------|
| 1        | 5    | 7    |
| 2        | 1    | 3    |
| 3        | 4    | 4    |
| 4        | 3    | 1    |
| 5        | 7    | 5    |
| $M$      | 4.00 | 4.00 |
| $\sigma$ | 2.00 | 2.00 |
| Sum      |      |      |



↗ Insira  $X$  and  $Y$  no SPSS e calcule o  $r$

↗  $r_{XY} = .60$

# Reta de regressão

Equação preditora:

$$\hat{Y} = b_0 + b_1 X$$

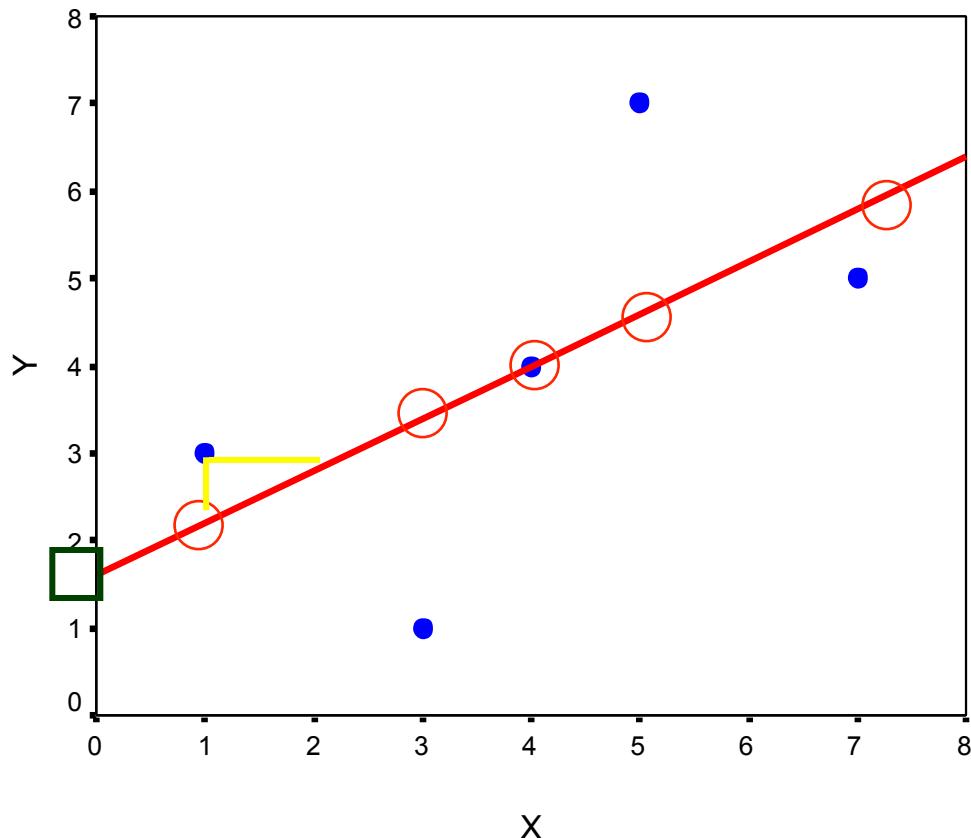
$X$  = valor do preditor

$Y$  = valor do critério

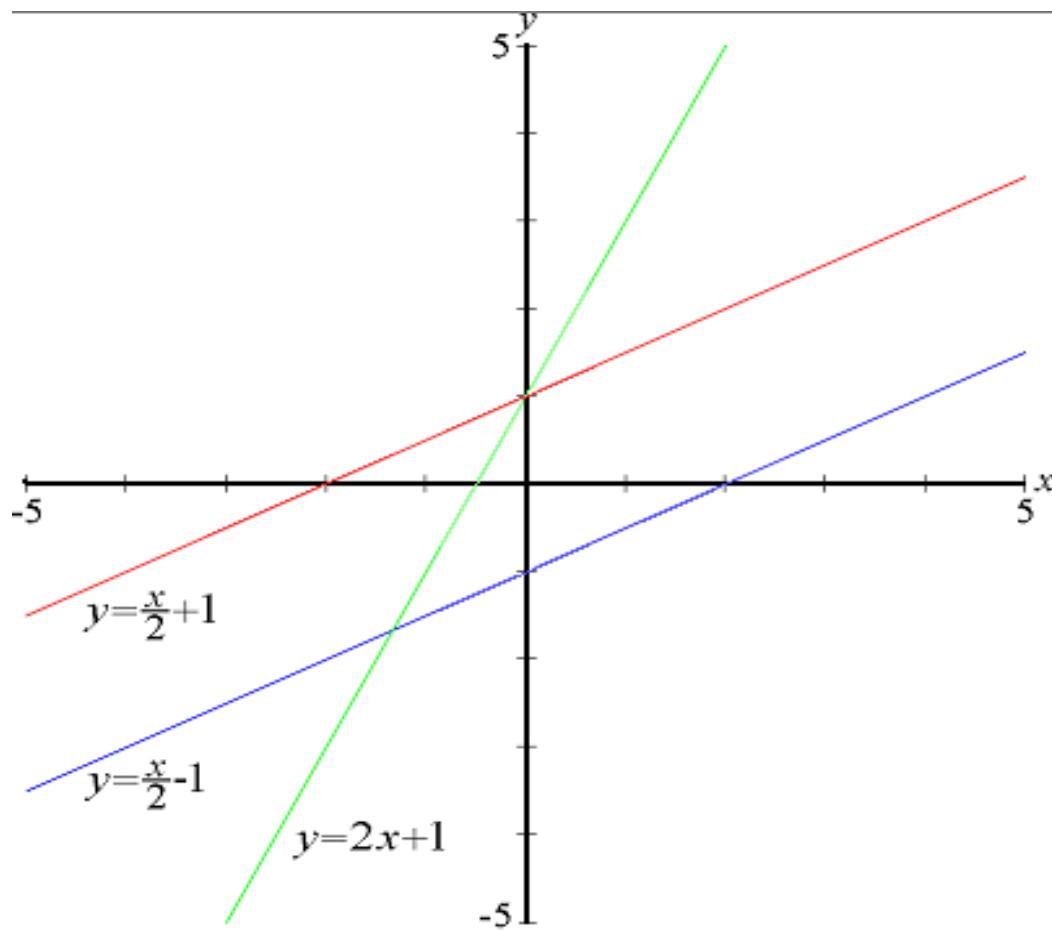
$\hat{Y}$  = valor predito

$b_1$  = inclinação da linha

$b_0$  = constante



# Equação da reta



# Reta de regressão

- ↗ Melhor previsão de  $Y$  em relação aos valores de  $X$
- ↗ Equação de previsão:

$$\hat{Y} = b_0 + b_1 X$$

Na qual:

$X$  = valor do preditor (variável preditora ou VI)

$\hat{Y}$  = valor previsto de  $Y$  (variável resposta ou VD ou critério)

i.e., valor de  $Y$  na linha, dado  $X$

$b_1$  = inclinação (*slope*) da linha, Mudança em  $\hat{Y}$  para uma mudança de 1-unidade de mudança em  $X$

$b_1 = r_{XY}(S_Y/S_X)$

$b_0$  = constante (*intercept*)

$\hat{Y}$  quando  $X = 0.0$

$$b_0 = M_Y - b_1 M_X$$

# Reta de regressão

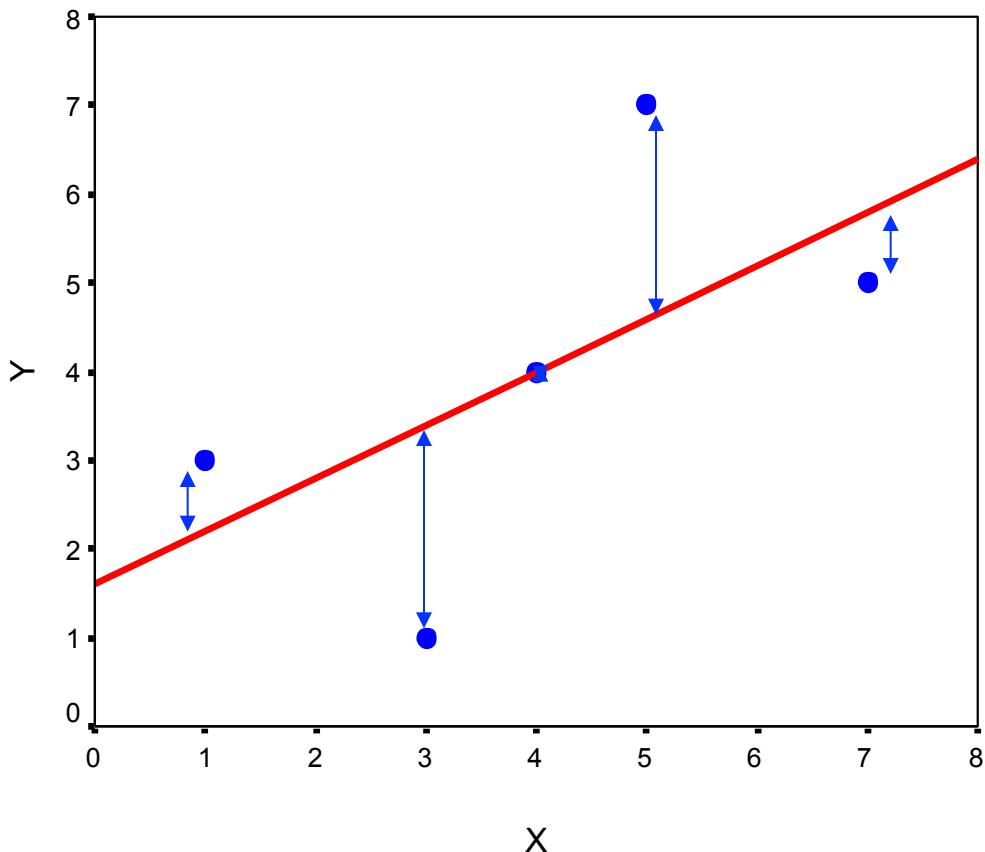
- ↗ Gere a equação de regressão do exemplo no SPSS
- ↗ A equação de previsão minimiza os erros, definidos como

$$SS_{\text{Residual}} = \sum(Y - \hat{Y})^2$$

- ↗ Em que :
  - ↗  $Y$  = valores observados (i.e., os valores do gráfico de dispersão)
  - ↗  $\hat{Y}$  = valores preditos na reta de regressão
- ↗ Portanto,  $SS_{\text{Residual}}$  indica a extensão em que a linha não consegue prever os dados observados
  - ↗  $SS_{\text{Resid}}$  na regressão é análogo ao  $SS_{WG}$  na ANOVA
    - ↗ i.e., variabilidade nas células que não pode ser explicada pelo modelo.

# Reta de regressão: Exemplo

- $SS_{\text{Resid}} = \sum(Y - \hat{Y})^2$
- Sum of squared distances of each person's Y score from the line of prediction



# Reta de regressão : Exemplo

Equação de previsão:  $\hat{Y} = b_0 + b_1 X$

$$b_1 = r_{XY}(S_Y/S_X)$$

$$= .60(2.236/2.236) = .60$$

(Porque  $S_Y = S_X$ ,  $r = b_1$ ; isso é raro acontecer)

$$b_0 = M_Y - b_1 M_X$$

$$= 4 - .60(4) = 4 - 2.4 = 1.6$$

$$\hat{Y} = 1.6 + (.60)(X)$$

| ID  | X     | Y     | $\hat{Y}$ |
|-----|-------|-------|-----------|
| 1   | 5     | 7     |           |
| 2   | 1     | 3     |           |
| 3   | 4     | 4     |           |
| 4   | 3     | 1     |           |
| 5   | 7     | 5     |           |
| $M$ | 4.0   | 4.0   |           |
| $S$ | 2.236 | 2.236 |           |
|     |       |       |           |

Calcule  $\hat{Y}$  para cada  $X$

e.g., for  $X = 5$

$$\hat{Y} = 1.6 + (.60)(5) = 4.6$$

# Reta de regressão : Exemplo

Equação de previsão:  $\hat{Y} = b_0 + b_1 X$

$$b_1 = r_{XY} (S_Y / S_X)$$

$$= .60(2.236 / 2.236) = .60$$

(Porque  $S_Y = S_X$ ,  $r = b_1$ ; isso é raro acontecer)

$$b_0 = M_Y - b_1 M_X$$

$$= 4 - .60(4) = 4 - 2.4 = 1.6$$

$$\hat{Y} = 1.6 + (.60)(X)$$

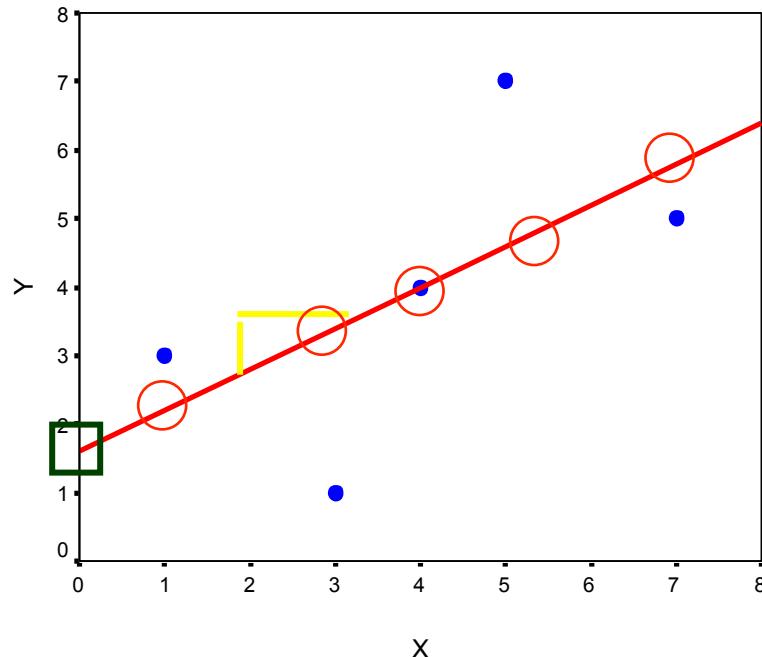
| ID  | X     | Y     | $\hat{Y}$ |
|-----|-------|-------|-----------|
| 1   | 5     | 7     | 4.60      |
| 2   | 1     | 3     | 2.20      |
| 3   | 4     | 4     | 4.00      |
| 4   | 3     | 1     | 3.40      |
| 5   | 7     | 5     | 5.80      |
| $M$ | 4.0   | 4.0   |           |
| $S$ | 2.236 | 2.236 |           |

Calcule  $\hat{Y}$  para cada X

e.g., for  $X = 5$

$$\hat{Y} = 1.6 + (.60)(5) = 4.6$$

# Reta de regressão exemplo



$$\hat{Y} = b_0 + b_1 X = 1.6 + (.60)(X)$$

$b_1 = .60$ ; mudança no escore bruto de  $\hat{Y}$  para 1a unidade de mudança em  $X$

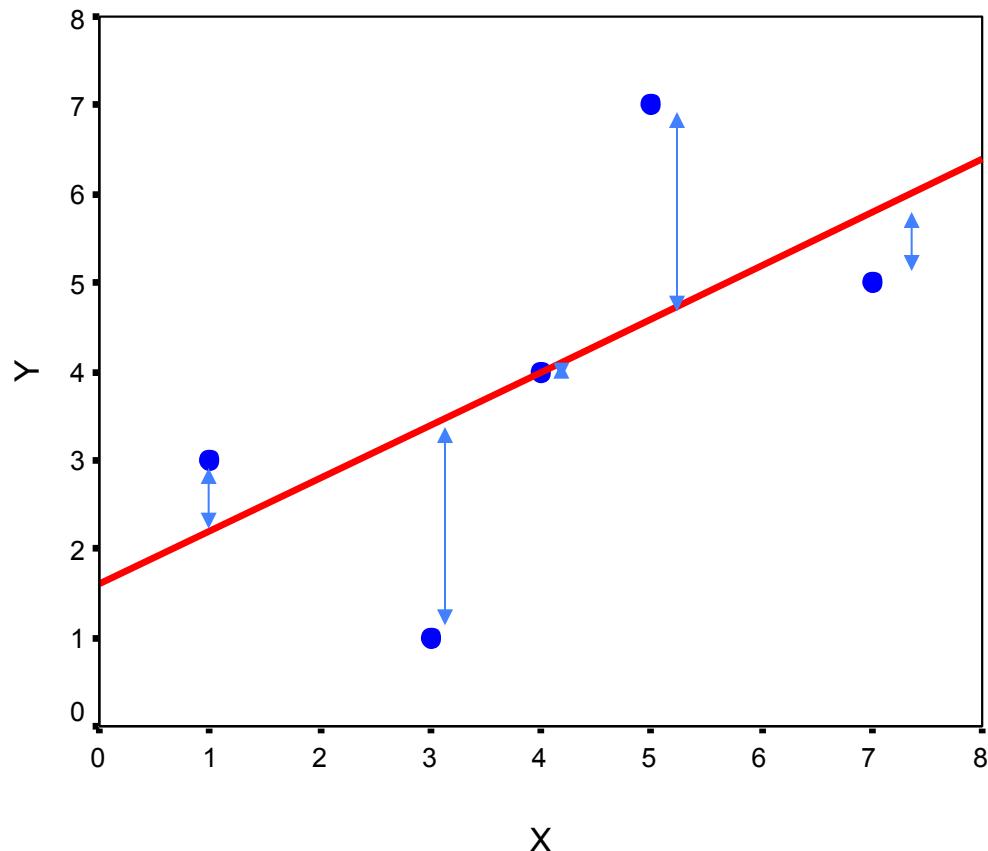
$b_0 = 1.6$ ; constante; valor de  $\hat{Y}$  quando  $X = 0$

- Como na ANOVA, a análise de regressão partitiona a variância da variável dependente em componentes mutuamente exclusivos e exaustivos:
  - 1. Aquilo que é explicado pelo modelo
    - i.e., pela VI ou VIs
  - 2. Aquilo que não pode ser explicado pelo modelo
    - i.e., variância residual
- $SS_{\text{Total}} = SS_{\text{Modelo}} + SS_{\text{Residual}}$ 
  - Como definido,  $SS_{\text{Residual}} = \sum(Y - \hat{Y})^2$ 
    - Soma das distâncias ao quadrado de cada escore Y das pessoas em relação a reta de regressão (linha de predição)

# Soma de Quadrados da Regressão

↗  $SS_{\text{Residual}} = \sum(Y - \hat{Y})^2$

↗ Soma das distâncias ao quadrado de cada escore Y das pessoas em relação a reta de previsão

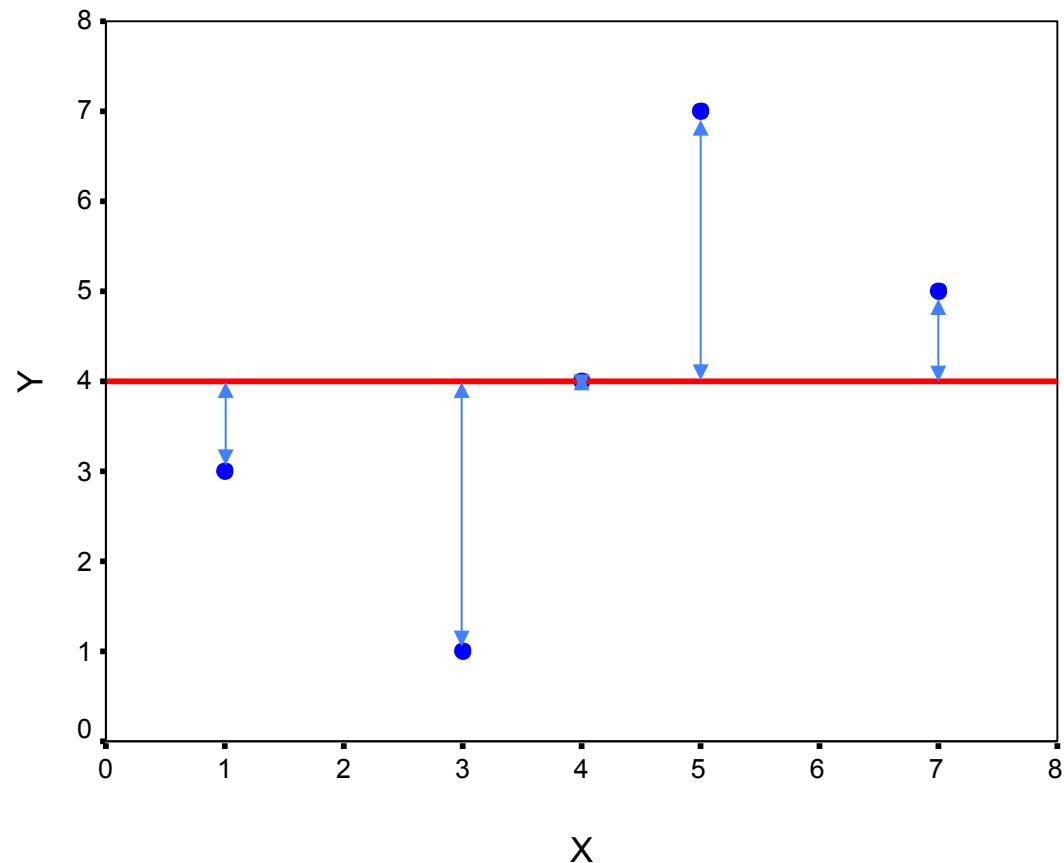


# Soma de Quadrados da Regressão

↗  $SS_{Total} = \sum(Y - M_Y)^2$

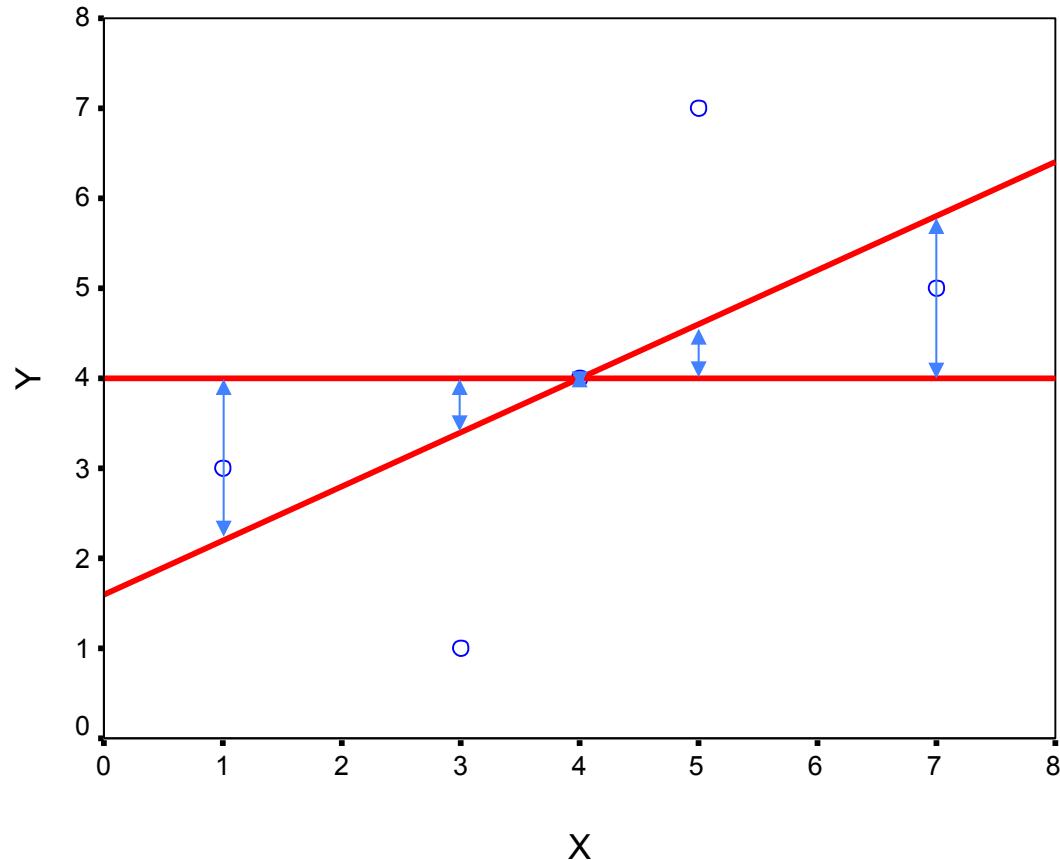
↗ Soma das distâncias ao quadrado de cada escore  $Y$  das pessoas em relação à média geral de  $Y$

↗ i.e., numerador da variância de  $Y$ ; total de variância na VD



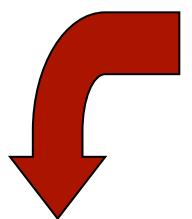
# Soma de Quadrados da Regressão

- $SS_{\text{Modelo}} = \sum(\hat{Y} - M_Y)^2$
- Soma das distâncias ao quadrado de cada escore predito  $\hat{Y}$  (i.e., a linha) da média de  $Y$
- Indica a variação na VD que pode ser explicada pelo modelo
- Os pontos observados de dados não são considerados; somente a comparação do modelo de  $\hat{Y}$  tem relação à média de  $Y$

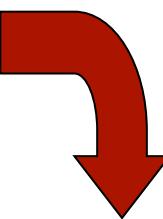
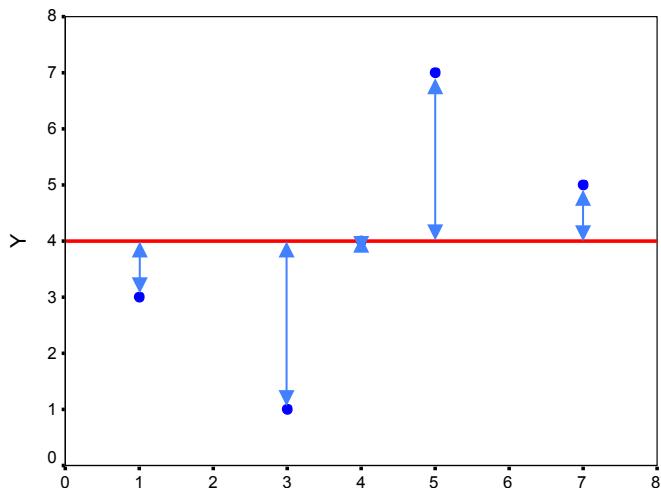


# Soma de Quadrados da Regressão

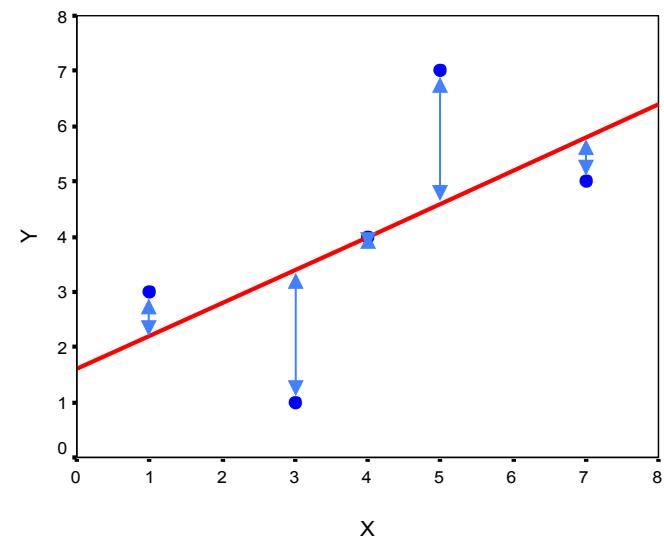
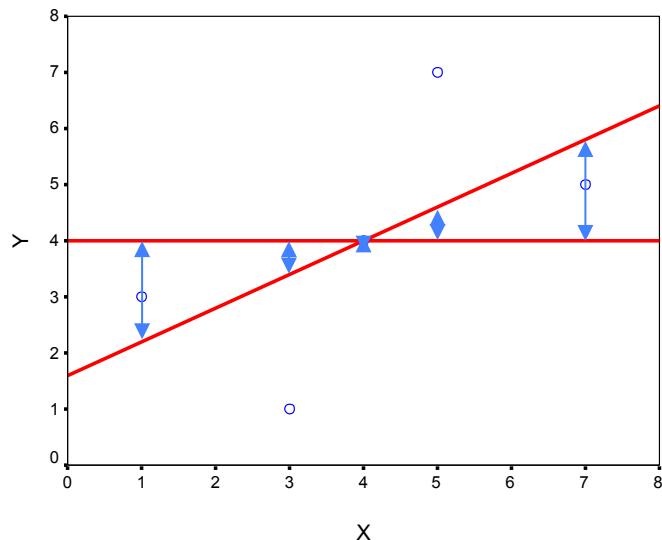
$$SS_{\text{Total}} = \sum(Y - MY)^2$$



$$SS_{\text{Model}} = \sum(\hat{Y} - MY)^2$$



$$SS_{\text{Residual}} = \sum(Y - \hat{Y})^2$$



# Saídas do SPSS (Output) Dados do Modelo: 2as Tabelas

## ➤ Tabelas da ANOVA

- $SS_{\text{Modelo}}$  é chamado  $SS_{\text{Regression}}$
- Variação (i.e.,  $SS$ ) é dividida pelo  $gl$  ( $df$ ) correspondente para calcular-se a a variância (i.e.,  $MS$ )
  - $MS = SS / df$
- $F$  é calculado por  $MS_{\text{Modelo}} / MS_{\text{Residual}}$ 
  - i.e., A variância explicada pelo modelo é maior do que a variância não explicada?
- Avaliar a significância usando  $df_{\text{Numerador}}$  e  $df_{\text{Denominador}}$

# Saídas do SPSS (Output) Dados do Modelo: 2as Tabelas

## ↗ Modelo Tabela Sumária (*Summary table*)

↗  $R^2$  = proporção da variância total explicada pelo modelo de regressão

$$\Rightarrow R^2 = SS_{\text{Model}} / SS_{\text{Total}}$$

$$\Rightarrow \text{No exemplo: } R^2 = 7.2 / 20.0 = .36$$

↗  $R = \sqrt{R^2} = r_{Y\hat{Y}}$

$$\Rightarrow \text{No exemplo: } R = \sqrt{.36} = .60$$

$$\Rightarrow R = r_{Y\hat{Y}} = .60$$

# Saídas do SPSS (Output) Dados do Modelo: 2as Tabelas

## ↗ Tabela sumária (cont.)

↗  $R^2$  ajustado = Estimativa do parâmetro populacional ,  $\rho$  (rho)

↗ Em que  $p$  = # de preditores

$$\begin{aligned} \rightarrow \text{No exemplo a: Adj. } R^2 &= 1 - [(1-.36)(5-1)/(5-1-1)] \\ &= 1 - [(.64 * 4)/3] = .14667 \end{aligned}$$

↗ Erro padrão da Estimativa (SEE)

↗ Indica o grau de incerteza na previsão

$$\rightarrow \text{SEE} = \sqrt{MS_{\text{Residual}}}$$

$$\rightarrow \text{No exemplo: SEE} = \sqrt{4.26667} = 2.06559$$

# Coeficientes de regressão: $b$ , $B$ , & $\beta$

- ↗ Indicam a mudança em  $\hat{Y}$  para cada 1a-unidade de mudança em  $X$
- ↗  $b$  = coeficiente de regressão não padronizado
  - ↗ Mudança expressa em unidades do escore bruto
  - ↗ Mudança no escore bruto  $\hat{Y}$  para uma unidade de mudança no escore bruto de  $X$
- ↗  $B$  = SPSS notação para  $b$
- ↗  $\beta$  (Beta) = coeficiente de regressão padronizado.
  - ↗ Mudança expressa em unidades de desvio padrão (SD)
  - ↗ Número de mudanças em SD em  $\hat{Y}$  para uma mudança de 1 SD em  $X$

# Coeficientes de regressão: $b$ , $B$ , & $\beta$

- ↗  $b$  pode ser muito maior que  $\beta$  (& vice versa)
  - ↗ Isso dependerá da unidade de medida
- ↗  $b = \beta$  quando:
  - ↗  $S_X = S_Y$
  - ↗ e.g., quando  $X$  e  $Y$  são escores z
- ↗ Interpretação
  - ↗  $b$  é empregado quando as unidades tenham um sentido inerente
  - ↗ e.g., renda, altura, peso
  - ↗  $\beta$  é empregado quando as métricas são arbitrárias
    - ↗ e.g., maioria das escalas psicológicas
- ↗ Note:  $b$  para (constante) é o termo constante (*intercept*,  $b_0$ )

# Pressupostos

- ↗ Correlação: como uma estatística descritiva não há assunções prévias
- ↗ Regressão: requer 2 assunções
  - ↗ Ambas relacionadas às distribuições condicionais

# Distribuições Marginais e Condicionais

## ↗ Distribuições marginais:

- ↗ Distribuição de  $Y$  desconsiderando  $X$
- ↗ i.e., Variância de  $Y$  transpassando todos os níveis de  $X$ :  $S^2_Y$

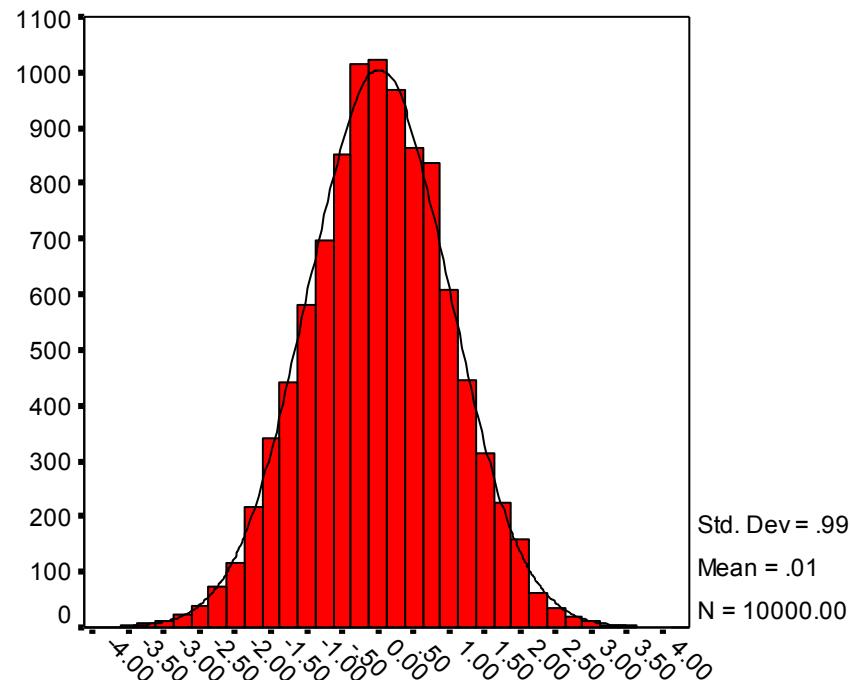
## ↗ Distribuição condicional:

- ↗ Distribuição de  $Y$  condicionada em  $X$
- ↗ i.e, Variância de  $Y$  em um dado valor de  $X$ :  $S^2_{Y|X}$

## ↗ Considere as diferenças usando a sintaxe do SPSS

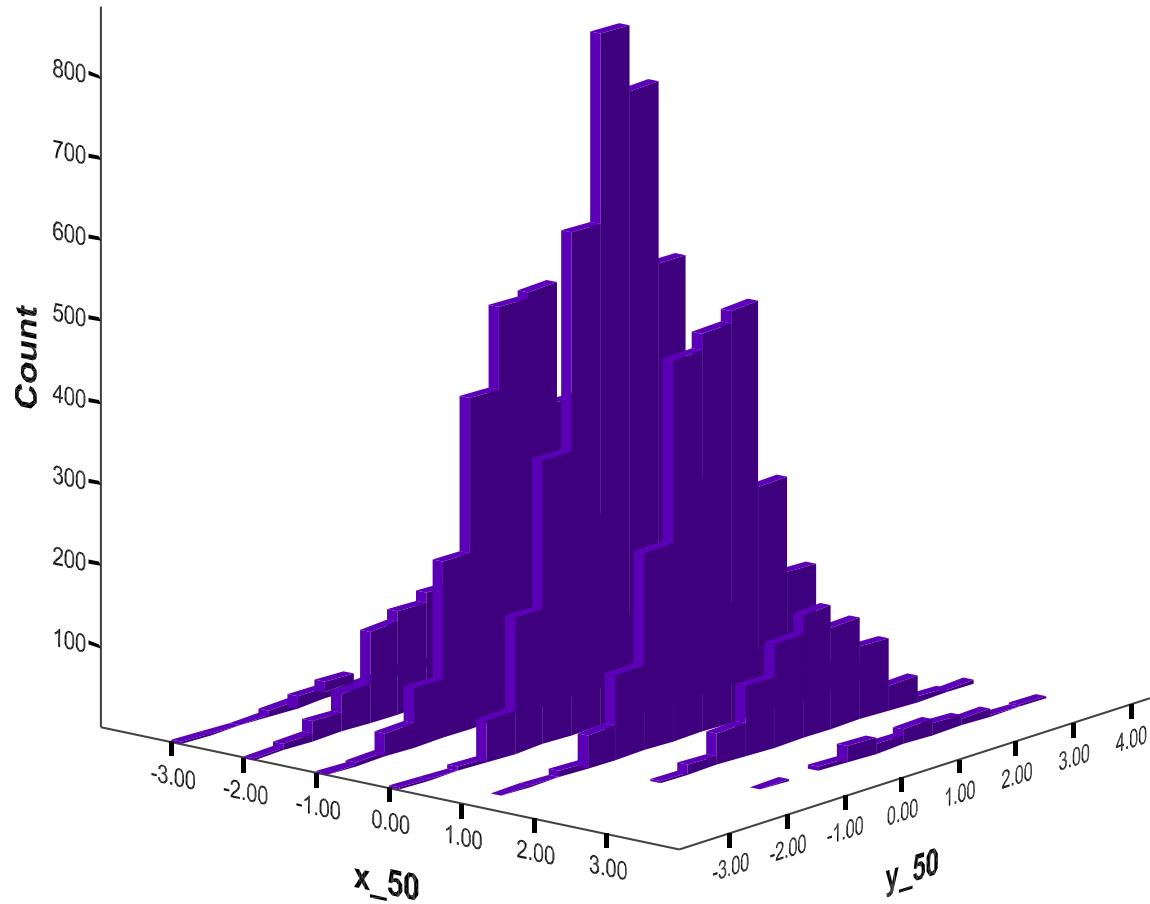
- ↗ "Marginal and Conditional Distributions.sps"

# Distribuição marginal de Y\_50



Marginal Distribution of  $Y_{50}$

# Distribuição condicional de Y\_50



# Duas assunções na regressão

## ↗ Normalidade:

- ↗  $Y$  é normalmente distribuído para cada valor de  $X$ 
  - ↗ Procure por assimetria < 2.0 e curtose < 7.0

## ↗ Homocedasticidade:

- ↗  $S^2$  de  $Y$  é constante quando calculado separadamente para cada valor específico de  $X$ ; i.e., cada distribuição condicional
  - ↗ Análogo à assunção de variâncias iguais dentro dos grupos no  $t$ -test ou ANOVA
- ↗ Justifica o uso de um único  $MS_{\text{Residual}}$  para:
  - ↗ Calcular a significância estatística
  - ↗ Determinar o erro padrão da estimativa (SEE)
    - ↗ SEE é simplesmente o SD das distribuições condicionais
    - ↗  $SEE = S_{Y \cdot X}$

$$S_{Y \cdot X} = \sqrt{\frac{\sum (Y - \hat{Y})^2}{N - 2}} = S_Y \sqrt{(1 - R^2)}$$

use  $N - 2$  because estimated  $a$  and  $b$  from data