

# Correlação

*Prof. Lorí Viali, Dr.*

*[vialli@mat.ufrgs.br](mailto:vialli@mat.ufrgs.br)*

*<http://www.mat.ufrgs.br/~vialli/>*

---

*É o grau de associação entre  
duas ou mais variáveis. Pode ser:*

*correlacional*

*ou*

*experimental.*



---

Numa relação *experimental* os valores de uma das variáveis são controlados.

No relacionamento *correlacional*, por outro lado, não se tem nenhum controle sobre as variáveis sendo estudadas.



---

# *Indicadores de Associação*



---

*Um engenheiro químico está investigando o efeito da temperatura de operação do processo no rendimento do produto. O estudo resultou nos dados da tabela seguinte:*



*Temperatura, C° (X)*

*Rendimento (Y)*

100

45

110

51

120

54

130

61

140

66

150

70

160

74

170

78

180

85

190

89




---

O primeiro passo para determinar se existe relacionamento entre as duas variáveis é obter o diagrama de dispersão (scatter diagram).



# Diagrama de Dispersão

---





---

*O diagrama de dispersão fornece uma idéia do tipo de relacionamento entre as duas variáveis. Neste caso, percebe-se que existe um relacionamento linear.*



---

*Quando o relacionamento  
entre duas variáveis  
quantitativas for do tipo linear,  
ele pode ser medido através do:*



---

# Coeficiente de Correlação



---

*Observado um relacionamento linear entre as duas variáveis é possível determinar a intensidade deste relacionamento. O coeficiente que mede este relacionamento é denominado de Coeficiente de Correlação (linear).*



---

*Quando se está trabalhando com amostras o coeficiente de correlação é indicado pela letra “r” e é uma estimativa do coeficiente de correlação populacional que é representado por “ $\rho$ ” (rho).*



---

*Determinação  
do  
Coeficiente  
de  
Correlação*



---

*Para determinar o coeficiente de correlação (grau de relacionamento linear entre duas variáveis) vamos determinar inicialmente a variação conjunta entre elas, isto é, a covariância.*



---

*A covariância entre duas variáveis  $X$  e  $Y$ , é representada por “ $Cov(X; Y)$ ” e calculada por:*

$$Cov(X, Y) = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{n - 1}$$





# Mas

---

$$\begin{aligned}\Sigma (X_i - \bar{X})(Y_i - \bar{Y}) &= \\ &= \Sigma [X_i Y_i - \bar{X} Y_i - X_i \bar{Y} + \bar{X} \bar{Y}] = \\ &= \Sigma X_i Y_i - \Sigma \bar{X} Y_i - \Sigma X_i \bar{Y} + \Sigma \bar{X} \bar{Y} = \\ &= \Sigma X_i Y_i - \bar{X} \Sigma Y_i - \bar{Y} \Sigma X_i + \Sigma \bar{X} \bar{Y} = \\ &= \Sigma X_i Y_i - n \bar{X} \bar{Y} - n \bar{X} \bar{Y} + n \bar{X} \bar{Y} = \\ &= \Sigma X_i Y_i - n \bar{X} \bar{Y}\end{aligned}$$



# Então:

---

$$\begin{aligned} \text{Cov}(X, Y) &= \frac{\sum (x_i - \bar{X})(y_i - \bar{Y})}{n - 1} = \\ &= \frac{\sum x_i y_i - n \bar{X} \bar{Y}}{n - 1} \end{aligned}$$



---

*A covariância poderia ser utilizada para medir o grau e o sinal do relacionamento entre as duas variáveis, mas ela é difícil de interpretar por variar de  $-\infty$  a  $+\infty$ . Assim vamos utilizar o coeficiente de correlação linear de Pearson.*



---

O coeficiente de correlação linear (de Pearson) é definido por:

$$r = \frac{\text{Cov}(X, Y)}{S_X S_Y}$$



# Onde:

---

$$\text{Cov}(X, Y) = \frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{n - 1}$$

$$S_X = \sqrt{\frac{\sum X_i^2 - n \bar{X}^2}{n - 1}}$$

$$S_Y = \sqrt{\frac{\sum Y_i^2 - n \bar{Y}^2}{n - 1}}$$



---

*Esta expressão não é muito prática para calcular manualmente o coeficiente de correlação. Pode-se obter uma expressão mais conveniente para o cálculo manual e o cálculo de outras medidas necessárias mais tarde.*



# Tem-se:

---

$$\begin{aligned} r &= \frac{\text{Cov}(X, Y)}{S_X S_Y} = \\ &= \frac{\frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{n-1}}{\sqrt{\frac{\sum X_i^2 - n \bar{X}^2}{n-1}} \sqrt{\frac{\sum Y_i^2 - n \bar{Y}^2}{n-1}}} = \\ &= \frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{\sqrt{(\sum X_i^2 - n \bar{X}^2)(\sum Y_i^2 - n \bar{Y}^2)}} \end{aligned}$$



*F*  
*a*

$$S_{XY} = \sum X_i Y_i - n \bar{X} \bar{Y}$$

*z*  
*e*

$$S_{XX} = \sum X_i^2 - n \bar{X}^2$$

*n*  
*d*  
*o*

$$S_{YY} = \sum Y_i^2 - n \bar{Y}^2$$

*Tem - se :*

$$r = \frac{S_{XY}}{\sqrt{S_{XX} \cdot S_{YY}}}$$



---

*A vantagem do coeficiente de correlação (de Pearson) é ser adimensional e variar de  $-1$  a  $+1$ , que o torna de fácil interpretação.*




---

*Assim se  $r = -1$ , temos uma  
relacionamento linear negativo  
perfeito, isto é, os pontos estão todos  
alinhados e quando  $X$  aumenta  $Y$   
decrece e vice-versa.*



# Correlação perfeita e negativa

---




---

*Se  $r = +1$ , temos uma  
relacionamento linear positivo  
perfeito, isto é, os pontos estão todos  
alinhados e quando  $X$  aumenta  $Y$   
também aumenta.*



# Correlação perfeita e positiva

---




---

*Assim se  $r = 0$ , temos uma ausência de relacionamento linear, isto é, os pontos não mostram “alinhamento”.*



# Correlação nula

---



---


*Assim se  $-1 < r < 0$ , temos uma  
relacionamento linear negativo, isto é,  
os pontos estão mais ou menos  
alinhados e quando  $X$  aumenta  $Y$   
decrece e vice-versa.*





# Correlação negativa

---



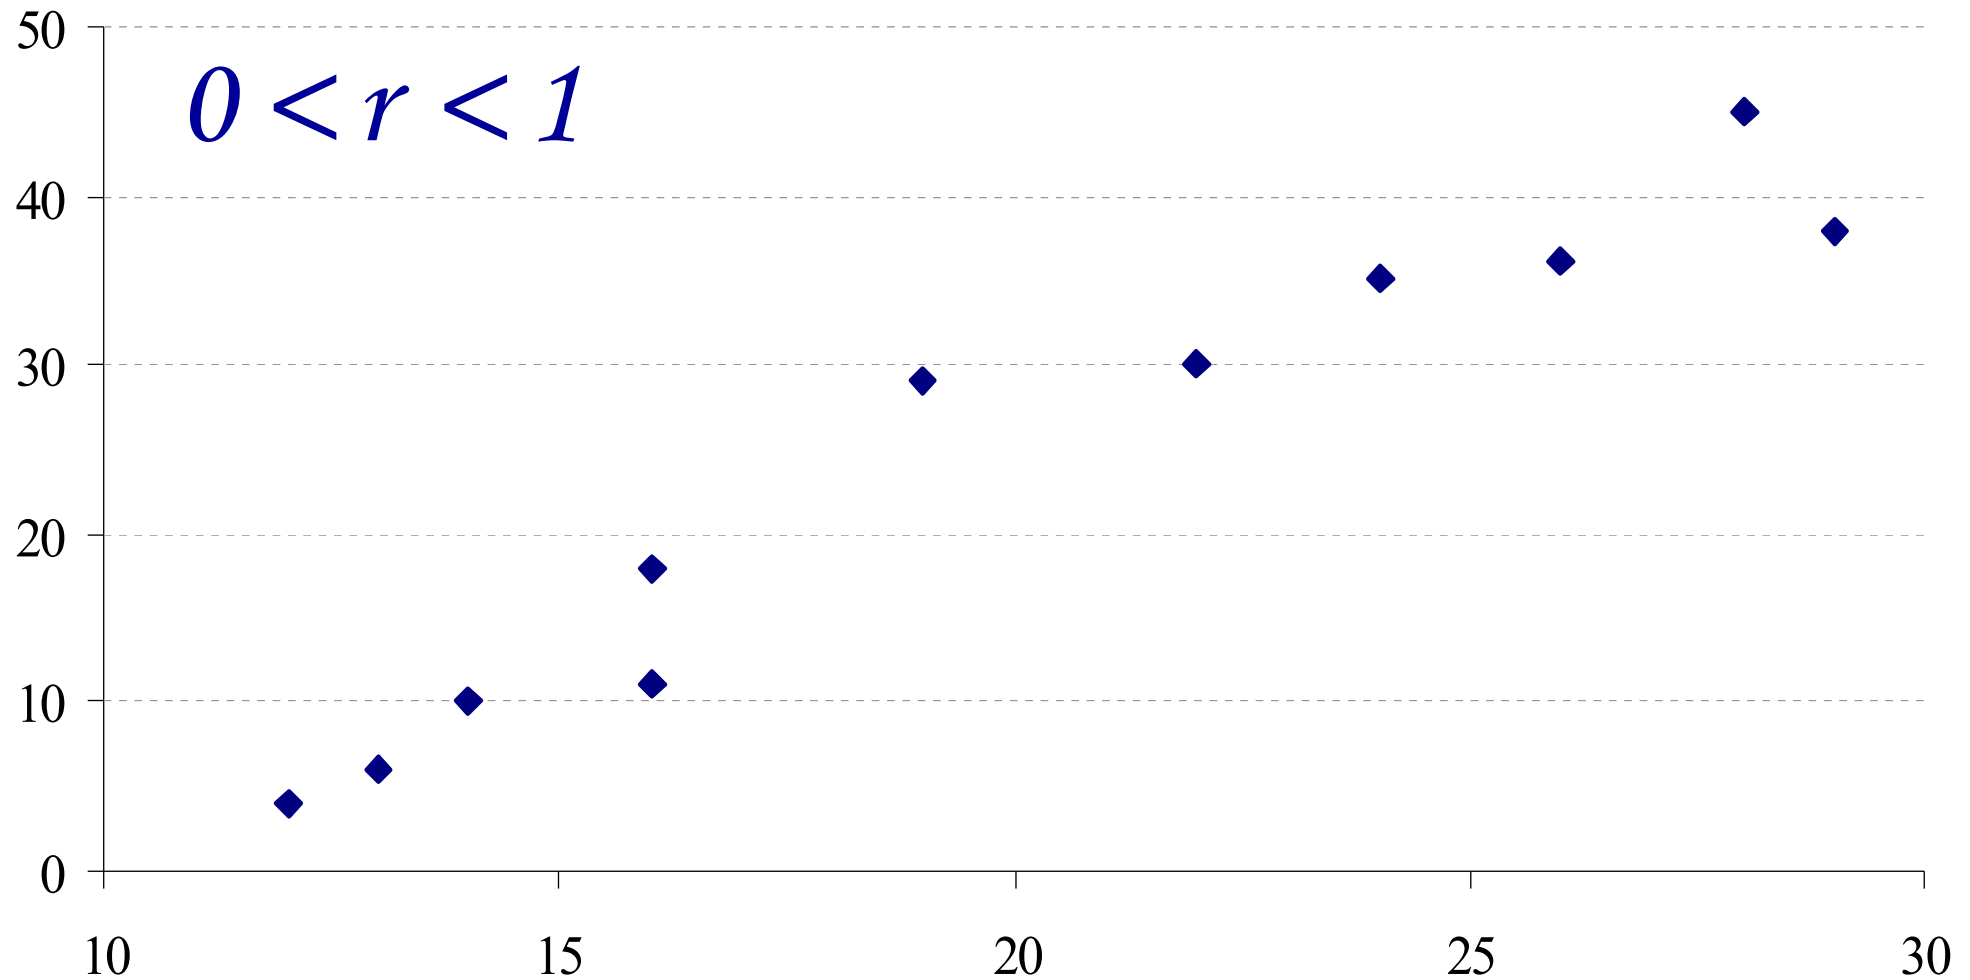
---

*Assim se  $0 < r < 1$ , temos uma relacionamento linear positivo, isto é, os pontos estão mais ou menos alinhados e quando  $X$  aumenta  $Y$  também aumenta.*



# Correlação positiva

---



# Observação:

---

*Uma correlação amostral não significa necessariamente uma correlação populacional e vice-versa. É necessário testar o coeficiente de correlação para verificar se a correlação amostral é também populacional.*




# *Ilustração*

---

*Observada uma amostra de seis pares, pode-se perceber que a correlação é quase um, isto é,  $r \cong 1$ . No entanto, observe o que ocorre quando mais pontos são acrescentados, isto é, quando se observa a população!*



# Correlação amostral $\chi$ populacional



---

# Exemplo



---

*Determinar o “grau de relacionamento linear” entre as variáveis  $X =$  temperatura de operação do processo versus  $Y =$  rendimento do produto, conforme tabela.*





$X$	$Y$	$XY$	$X^2$	$Y^2$
100	45	4500	10000	2025
110	51	5610	12100	2601
120	54	6480	14400	2916
130	61	7930	16900	3721
140	66	9240	19600	4356
150	70	10500	22500	4900
160	74	11840	25600	5476
170	78	13260	28900	6084
180	85	15300	32400	7225
190	89	16910	36100	7921
1450	673	101570	218500	47225

---

*Vamos calcular “r”  
utilizando a expressão em  
destaque vista anteriormente,  
isto é, através das quantidades,  
 $S_{xy}$ ,  $S_{xx}$  e  $S_{yy}$ .*



---

*Tem-se:*  $n = 10 \quad \sum X = 1450 \quad \sum Y = 673$

$$\bar{X} = 145 \quad \bar{Y} = 67,3 \quad \sum XY = 101570$$

$$\sum X^2 = 218500 \quad \sum Y^2 = 47225$$

*Então:* 
$$S_{XY} = \sum X_i Y_i - n \bar{X} \bar{Y} =$$
$$= 101570 - 10 \cdot 145 \cdot 67,3 =$$
$$= 3985$$



---

$$S_{XX} = \sum X_i^2 - n \bar{X}^2 =$$

$$= 218500 - 10.145^2 =$$

$$= 8250$$

$$S_{YY} = \sum Y_i^2 - n \bar{Y}^2 =$$

$$= 47225 - 10.67,3^2 =$$

$$= 1932,10$$



---

$$r = \frac{S_{xy}}{\sqrt{S_{xx} \cdot S_{yy}}} =$$
$$= \frac{3985}{\sqrt{8250 \cdot 1932,10}} =$$
$$= 0,9981$$



---

*Apesar de “ $r$ ” ser um valor adimensional, ele não é uma taxa. Assim o resultado não deve ser expresso em percentagem.*

