

# Correlação

*Prof. Lorí Viali, Dr.*

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

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

---

*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.



---

*I n d í c a d o r e s*  
*de*  
*A s s o c i a ç ã o*



---

*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 ideia 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:*



---

# Coefficiente 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).*



---

*D e t e r m i n a ç ã o*  
*do*  
*C o e f i c i e n t e*  
*de*  
*C o r r e l a ç ã o*



---

*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*  $\sum (X_i - \bar{X})(Y_i - \bar{Y}) =$

$$= \sum [X_i Y_i - \bar{X} Y_i - X_i \bar{Y} + \bar{X} \bar{Y}] =$$

$$= \sum X_i Y_i - \sum \bar{X} Y_i - \sum X_i \bar{Y} + \sum \bar{X} \bar{Y} =$$

$$= \sum X_i Y_i - \bar{X} \sum Y_i - \bar{Y} \sum X_i + \sum \bar{X} \bar{Y} =$$

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

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



---

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

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



*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.*



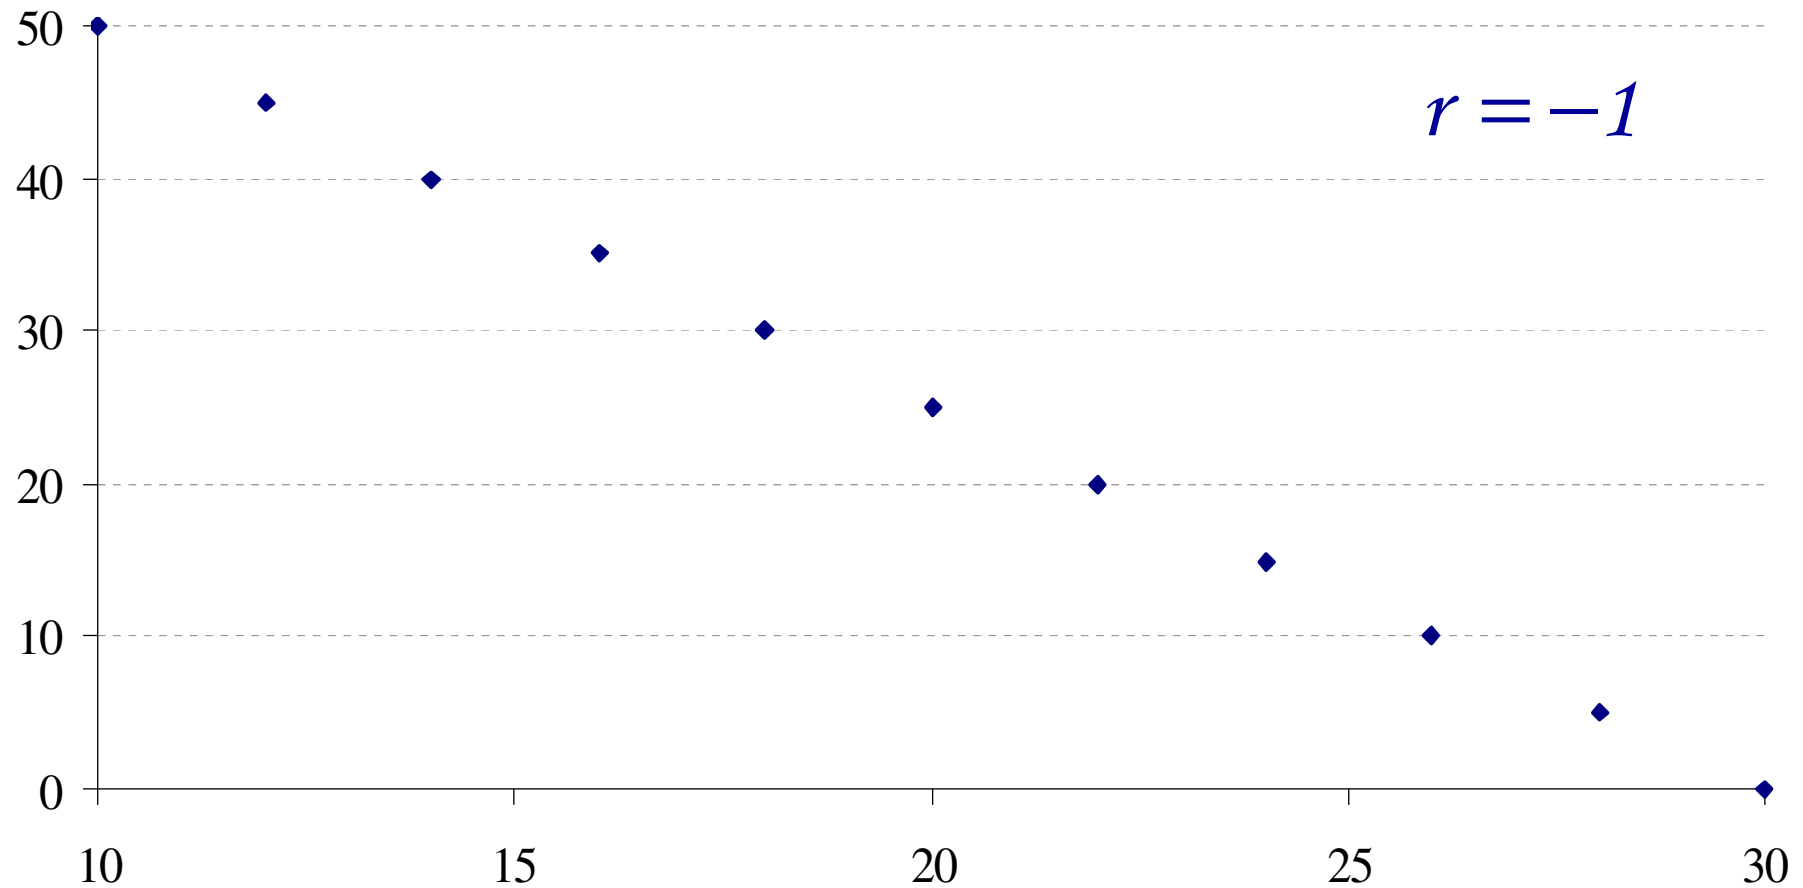
---

*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  $Y$  decresce 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 $X$ populacional



---

# *E x e m p l o*



---

*Determinar o “grau de relacionamento linear” entre as variáveis  $X =$  nota em Português  $Y =$  nota em Matemática, de 20 candidatos em um concurso vestibular com 30 questões, conforme tabela, na próxima lâmina.*





	<i>Português (X)</i>	<i>Matemática (Y)</i>	$X^2$	$Y^2$	$XY$
1	23	26	529	676	598
2	13	13	169	169	169
3	15	21	225	441	315
4	4	6	16	36	24
5	12	17	144	289	204
6	17	31	289	961	527
7	11	11	121	121	121
8	16	27	256	729	432
9	12	22	144	484	264
10	16	29	256	841	464
11	11	14	121	196	154
12	20	29	400	841	580
13	14	4	196	16	56
14	19	29	361	841	551
15	6	8	36	64	48
16	19	25	361	625	475
17	9	11	81	121	99
18	15	13	225	169	195
19	16	22	256	484	352
20	16	13	256	169	208
<i>Total</i>	284	371	4442	8273	5836

---

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



---

*Tem-se:*  $n = 20 \quad \sum X = 284 \quad \sum Y = 371$

$$\bar{X} = 14,20 \quad \bar{Y} = 18,55 \quad \sum XY = 5836$$

$$\sum X^2 = 4442 \quad \sum Y^2 = 8273$$

*Então:*  $S_{XY} = \sum X_i Y_i - n\bar{X}\bar{Y} =$   
 $= 5836 - 20 \cdot 14,20 \cdot 18,55 =$   
 $= 567,80.$



---

$$\begin{aligned} S_{XX} &= \sum X_i^2 - n \bar{X}^2 = \\ &= 4442 - 20 \cdot 14,20^2 = \\ &= 409,20 \end{aligned}$$

$$\begin{aligned} S_{YY} &= \sum Y_i^2 - n \bar{Y}^2 = \\ &= 8273 - 20 \cdot 18,55^2 = \\ &= 1390,95. \end{aligned}$$



---

$$\begin{aligned} r &= \frac{S_{XY}}{\sqrt{S_{XX} \cdot S_{YY}}} = \\ &= \frac{567,80}{\sqrt{409,20 \cdot 1390,95}} = \\ &= 0,7526. \end{aligned}$$



---

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

