

Regressões Lineares Simples (Seção 9.5)

1

Coefficiente de Correlação Linear (ρ_{xy})

Dadas duas variáveis quantitativas X e Y , medidas na mesma unidade amostral, avalia o grau de relação linear existente entre as duas variáveis. Ex: Peso e Altura, Salário e Anos de Escolaridade, Gasto com energia e Tamanho da residência

Dada uma amostra de n pares de observações $(x_1, y_1) (x_2, y_2) \dots (x_n, y_n)$

$$\rho_{xy} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sqrt{\left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \left(\sum_{j=1}^n y_j^2 - n \bar{y}^2 \right)}}$$

$$-1 \leq \rho_{xy} \leq 1$$

$\rho_{xy} \approx 0$ inexistência de relação linear


$\rho_{xy} = 1$ perfeita relação linear crescente

$\rho_{xy} = -1$ perfeita relação linear decrescente

Acredita-se que a utilização de uma certa substância no pasto produz um maior ganho de peso no gado. Para verificar o fato, foram escolhidos 15 bois de mesma raça e idade e cada animal recebeu uma determinada concentração da substância (variável X , em mg/l). O ganho de peso após 30 dias (variável Y , em Kg) foi anotado. Os resultados foram

X	0,2	0,5	0,6	0,7	1,0	1,5	2,0	2,5
Y	9,4	11,4	12,3	10,2	11,9	13,6	14,2	16,2
X	3,0	3,5	4,0	4,5	5,0	5,5	6,0	
Y	16,2	17,7	18,8	19,9	22,5	24,7	23,1	

Diagrama de Dispersão



$$\sum x_i y_i = 785,55 \quad \bar{x} = 2,7 \quad \bar{y} = 16,14$$

$$\sum x_i^2 = 163,39 \quad \sum y_i^2 = 4239,43$$

$$r_{xy} = \frac{785,55 - 15 \times 2,7 \times 16,14}{\sqrt{(163,39 - 15 \cdot 2,7^2)(4239,43 - 15 \cdot 16,14^2)}} = 0,99$$

Forte relação linear crescente.

Quanto maior a concentração da substância, maior o ganho de peso.

Os pontos tendem a se concentrar em torno de uma reta crescente.

Acredita-se que para cada valor x_i da variável X , tem-se

$$Y_i = \underbrace{\alpha + \beta x_i}_{\text{parte de } Y_i \text{ que é explicada por } X} + e_i$$


parte de Y_i que é explicada por X

↳ erro do modelo (parte de Y_i não explicada por X)



Variáveis externas não consideradas

Variaabilidade natural entre indivíduos



α e β parâmetros desconhecidos

$Y_i = \alpha + \beta x_i + e_i$ é um modelo de regressão linear simples. Suposições

i) $e_i, i=1, 2, \dots, n$ são v.a. independentes
 $e_i \sim N(0, \sigma^2)$

ii) Os valores de x_i são fixados e portanto não aleatórios. Como consequência

$Y_i, i=1, 2, \dots, n$ são v.a. independentes e

$$Y_i \sim N(\alpha + \beta x_i, \sigma^2)$$

Y - variável resposta ou variável dependente

X - variável independente, explicativa ou preditora.

$E(Y|X=x)$: média de Y quando $X=x$

Ex: $E(Y|X=4) \rightarrow$ ganho médio de peso para bois submetidos à concentração 4,0 mg/l.

Admite-se que $E(Y_i|X=x_i) = \alpha + \beta x_i$

Significado de β

$$E(Y|X=x+1) = \alpha + \beta(x+1) = \alpha + \beta x + \beta$$

$$E(Y|X=x) = \alpha + \beta x$$

$$\beta = E(Y|X=x+1) - E(Y|X=x)$$

$\hookrightarrow$ acréscimo na média de Y quando X aumenta em uma unidade (suposto constante $\forall$ o valor de X)


$$\alpha = E(Y|X=0)$$

$\hookrightarrow$ só tem significado prático se fizer sentido $X=0$.

Estimadores de Mínimos Quadrados de α e β ⁶

Dada a amostra de n pares de observações, os estimadores de mínimos quadrados de α e β , $\hat{\alpha}$ e $\hat{\beta}$, são os valores de α e β que minimizam

$$S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2.$$



A reta de mínimos quadrados $\hat{y} = \hat{\alpha} + \hat{\beta} x$ é aquela que dentre todas as possíveis retas minimiza a soma dos quadrados das distâncias verticais dos pontos (x_i, y_i) à reta.

$\hat{y} = \hat{\alpha} + \hat{\beta} x$ é denominada reta de regressão de Y em X .

$$\left. \begin{aligned} \frac{\partial SQ(\alpha, \beta)}{\partial \beta} &= 0 \\ \frac{\partial SQ(\alpha, \beta)}{\partial \alpha} &= 0 \end{aligned} \right\} \Rightarrow$$

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

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

No example

$$n = 15 \quad \sum x_i y_i = 785,55 \quad \sum x_i^2 = 163,39$$

$$\bar{x} = 2,7 \quad \bar{y} = 16,14$$

$$\hat{\beta} = \frac{785,55 - 15 \cdot 2,7 \cdot 16,14}{163,39 - 15 \cdot 2,7^2} = 2,44$$

$$\hat{\alpha} = 16,14 - 2,44 \cdot 2,7 = 9,55$$

$$\hat{y} = \hat{\alpha} + \hat{\beta} x = 9,55 + 2,44 x$$

Obtida a reta de regressão

$$\hat{y} = 9,55 + 2,44x$$

estima-se que, com o aumento em uma unidade da concentração da substância, o ganho médio de peso aumenta em 2,44 Kg.

Estima-se que o ganho médio de peso para bois que não recebem a substância é 9,55 kg.

A estimativa do ganho médio de peso de um boi sujeito a 6,2 mg/l da substância segundo o modelo ajustado é

$$\hat{y} = 9,55 + 2,44 \cdot 6,2 = 24,678$$


Não extrapolar muito.

Teste de hipóteses para o parâmetro β

$$H_0: \beta = 0$$

$$H_a: \beta \neq 0$$

$$\beta = 0$$



Não há influência da variável explicativa na média da variável resposta.

$$\beta \neq 0$$



Há influência da variável explicativa na média da variável resposta.

Verifica-se que $\text{Var}(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$

σ^2 desconhecido.

Estimador não viesado de σ^2 :

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-2}$$

$\sum_{i=1}^n (y_i - \hat{y}_i)^2 \rightarrow$ soma de quadrados dos resíduos

Estadística de teste

$$T = \frac{\hat{\beta}_0}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}}$$

Rejeita-se H_0 para $T \geq t_c$ ou $T \leq -t_c$

$t_c \mid P(T \geq t_c) = \alpha/2 \quad T \sim t_{n-2}$

No exemplo

i	$(y_i - \hat{y}_i)^2$	$(x_i - \bar{x})^2$
1	$0,41 = (9,4 - 9,55 - 2,44 \cdot 0,2)^2$	6,25
2	0,39	4,84
3	1,65	4,41
4	1,12	4,00
...		
15	1,20	10,89
Total	10,09 = <i>Soma de Quadrados do resíduo</i>	54,04 $\sum (x_i - \bar{x})^2$

$$\hat{\sigma}^2 = \frac{10,09}{13} = 0,776$$

$$T = \frac{2,44}{\sqrt{\frac{0,776}{54,04}}} = 20,375$$

13 gl

$$\alpha = 0,05$$

Teste bilateral

$$H_0: \beta = 0$$

$$H_a: \beta \neq 0$$

$$RC: T \leq -2,16 \text{ ou } T \geq 2,16$$

Rejeita-se H_0 .

Os dados sugerem que o ganho médio de peso é influenciado pela concentração da substância.

Adota-se o modelo $\hat{y} = 9,55 + 2,44x$

Se H_0 fosse aceita, a conclusão seria que os dados sugerem que o ganho médio de peso não é influenciado pela concentração da substância. Não se utilizaria o modelo

$$\hat{y} = 9,55 + 2,44x$$