



Lisbon School
of Economics
& Management
Universidade de Lisboa

Estatística II

Licenciatura em Gestão
2.º Ano/1.º Semestre
2023/2024

Aulas Teóricas N.ºs 18 e 19 (Semana 10)

Docente: Elisabete Fernandes

E-mail: efernandes@iseg.ulisboa.pt



<https://doity.com.br/estatistica-aplicada-a-nutricao>



<https://basiccode.com.br/produto/informatica-basica/>

Conteúdos Programáticos

Aulas Teóricas
(Semanas 1 a 5)

- **Capítulo 1:** Estimação

Aulas Teóricas
(Semanas 5 a 7)

- **Capítulo 2:** Testes de Hipóteses

Aulas Teóricas
(Semanas 7 a 9)

- **Capítulo 3:** Modelo de Regressão Linear

Aulas Teóricas
(Semanas 10 a 13)

- **Capítulo 4:** Complementos ao Modelo de Regressão Linear

Material didático: Exercícios do Livro Murteira et al (2015), Formulário e Tabelas Estatísticas

Bibliografia: B. Murteira, C. Silva Ribeiro, J. Andrade e Silva, C. Pimenta e F. Pimenta; *Introdução à Estatística*, 2ª ed., Escolar Editora, 2015.

<https://cas.iseg.ulisboa.pt>

7ª semana (31/10 a 02/11)

T12 - Teste de hipóteses

Testes em universos normais com amostras emparelhadas. Exemplo. Teste de hipóteses para grandes amostras. Aplicação ao universo de Bernoulli (média e diferença de médias). Exemplos.

T13 - Modelo de regressão linear

Introdução; modelo linear e linearizável; exemplos; Hipóteses básicas; estimação dos coeficientes da regressão pelos Mínimos Quadrados. Exemplo.

8ª semana (07/11 e 09/11)

T14 - Modelo de Regressão Linea (MRL)r

Interpretação dos parâmetros da regressão; exemplos; Resíduos MQ e regressão ajustada; Propriedades dos estimadores MQ dos coeficientes da regressão; Estimador não enviesado da variância da variável residual; Exemplo.

T15 - Modelo de regressão Linear

Coefficiente de determinação e sua interpretação. Hipótese adicional (H6) e inferência estatística sobre o modelo; Inferência sobre um parâmetro beta. Exemplos

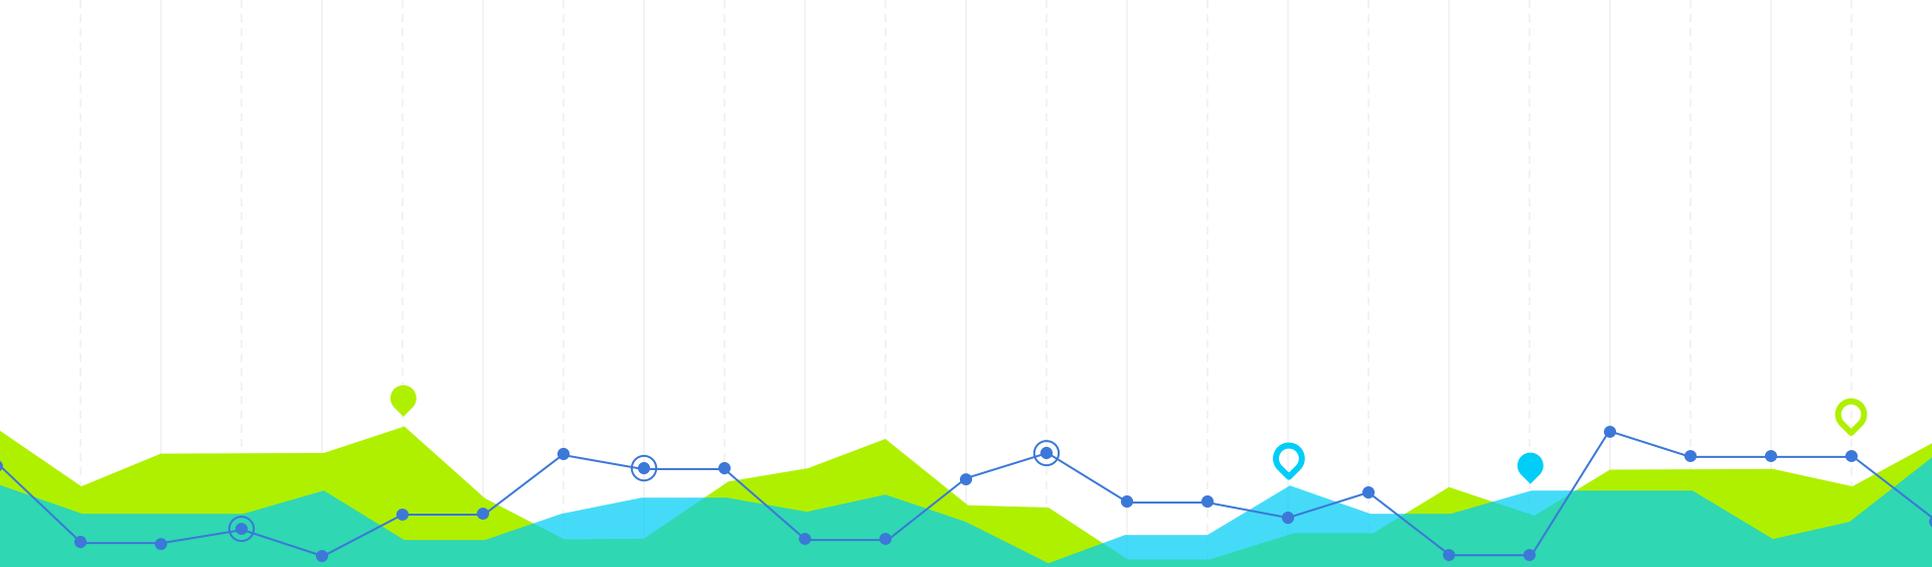
9ª semana (14/11 e 16/11)

T16 - Modelo de Regressão Linear

Mais exemplos de inferência sobre um parâmetro beta; Inferência sobre uma combinação linear de betas; exemplos.

T17 - Modelo de Regressão Linear

Teste de nulidade conjunta de vários coeficientes; exemplo; Teste F à significância global da regressão; Teste de um conjunto de restrições lineares; exemplo.



Modelo de Regressão Linear Simples

Coeficientes da reta de regressão

Revisão

1

Modelo de Regressão Linear

Modelos de Regressão

São modelos utilizados para compreender a relação entre

- uma variável resposta Y
- e
- uma ou mais variáveis explicativas (X ou X_1, X_2, \dots).

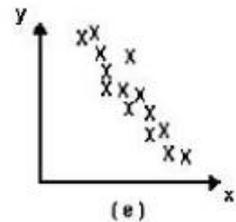
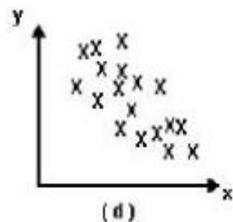
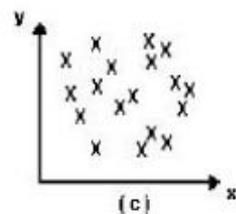
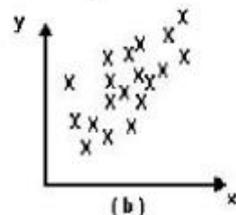
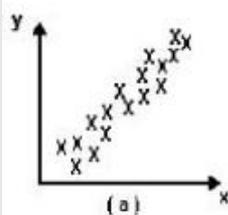
Um problema de análise da associação entre **duas variáveis** quantitativas começa pela recolha de uma amostra de pares de pontos:

$$\{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_n, y_n)\},$$

após o qual se deve proceder à representação gráfica desses pontos, usando os **diagramas de dispersão**.

Diagramas de Dispersão

Possíveis Padrões para Diagramas de Dispersão.

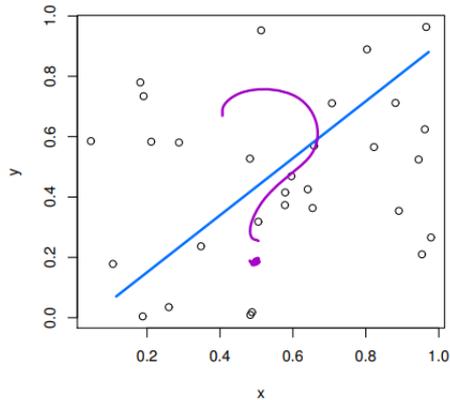


Legenda

- (a) - Elevada correlação positiva
- (b) - Moderada correlação positiva
- (c) - Ausência de correlação
- (d) - Moderada correlação negativa
- (e) - Elevada correlação negativa

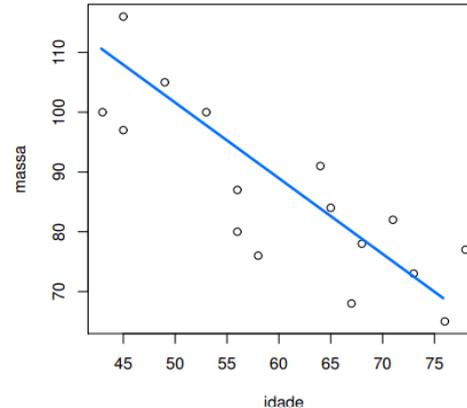
Diagramas de Dispersão

Quando duas variáveis **não estão relacionadas**, este gráfico representará uma **mancha de pontos aleatória**:



será que um modelo linear é adequado?

Quando **existe uma relação entre duas variáveis**, o diagrama de dispersão mostrará uma **mancha de pontos não aleatória** e poder-se-á verificar se a relação entre x e y poderá ser modelada por uma reta ou sugerir alguma outra relação.



Modelo de Regressão Linear Simples

Modelo de Regressão Linear Simples (RLS)

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, 2, \dots, n.$$

onde

Y_i : variável aleatória (variável dependente ou resposta)
 x_i : valor fixo (medição sem erro ou com erro desprezável) (variável independente ou de controlo)

β_0 : parâmetro (ordenada na origem) \rightarrow a estimar

β_1 : parâmetro regressor (declive, coeficiente angular) \rightarrow a estimar

ε_i : erro aleatório associado à i -ésima prova, verificando:

- $E[\varepsilon_i] = 0$ (valor esperado nulo);
- $Var[\varepsilon_i] = \sigma^2$ (variância constante); \rightarrow a estimar
- $Cov[\varepsilon_i, \varepsilon_j] = 0, \forall i, j \ (i \neq j)$ (não correlacionados);

Y é a v.a. dependente, resposta, explicada

X é a v.a. independente, de controlo, explicativa, regressora

Modelo de Regressão Linear Simples

Equação da Regressão Linear

Para se estimar o valor esperado, usa-se de uma equação, que determina a relação entre ambas as variáveis.

$$y_i = \alpha + \beta X_i + \varepsilon_i$$

, onde:

y_i : Variável explicada (dependente); representa o que o modelo tentará prever

α : É uma constante, que representa a interceptação da **reta** com o eixo vertical;

β : Representa a inclinação (coeficiente angular) em relação à variável explicativa;

X_i : Variável explicativa (independente);

ε_i : Representa todos os factores residuais mais os possíveis erros de medição. O seu comportamento é aleatório, devido à natureza dos factores que encerra. Para que essa fórmula possa ser aplicada, os erros devem satisfazer determinadas hipóteses, que são: terem distribuição normal, com a mesma variância σ^2 , independentes e independentes da variável explicativa X , ou seja, i.i.d. (**independentes e identicamente distribuídas**).

A v.a. X , denominada variável regressora, explicativa ou independente, é considerada uma variável controlada pelo investigador e medida com erro desprezível

Modelos de Regressão Linear Simples

Modelo determinístico

$$y = \beta_0 + \beta_1 x$$

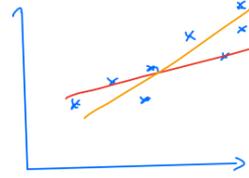
(i.e., todos os pontos estão em cima da recta)



Modelo estocástico (modelo de regressão linear simples)



Pessoa 1: recolhe as observações e sua representação gráfica.



Pessoa 2: procura a recta que melhor ajuste os valores observados

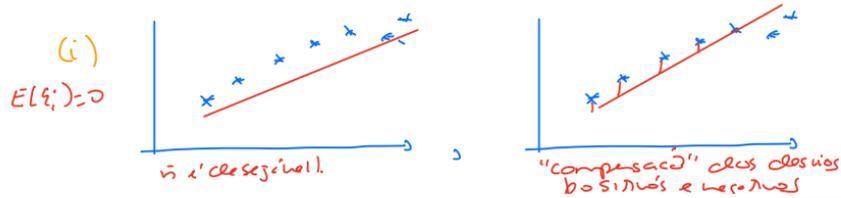
$$y = \beta_0 + \beta_1 x + \varepsilon$$

Componente estocástico,
designado por "erro"

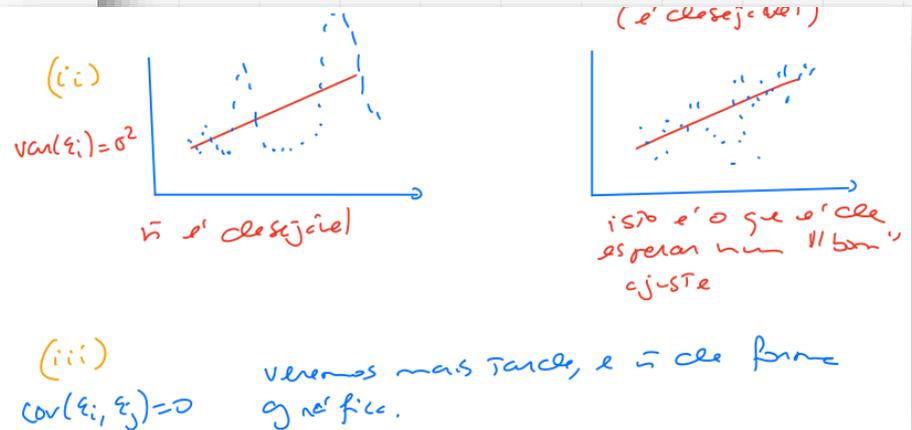
Modelo de Regressão Linear Simples

ε_i : erro aleatório associado à i -ésima prova, verificando:

- $E[\varepsilon_i] = 0$ (valor esperado nulo); (i)
- $\text{Var}[\varepsilon_i] = \sigma^2$ (variância constante); \rightarrow a estimar (ii)
- $\text{Cov}[\varepsilon_i, \varepsilon_j] = 0, \forall i, j (i \neq j)$ (não correlacionados); (iii)



Slides Professora Conceição Amado



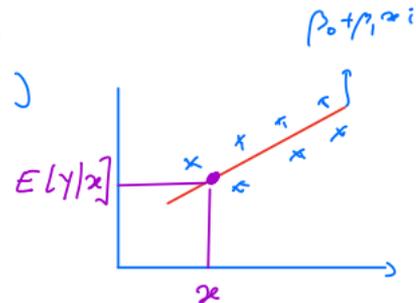
Modelo de Regressão Linear Simples

Em consequência do modelo:

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, 2, \dots, n.$$

e das hipóteses sobre os ε_i 's, decorre-se:

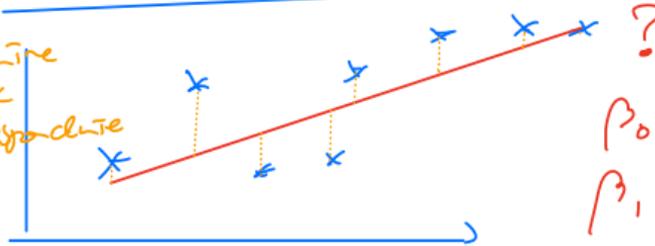
$$\begin{aligned} E(Y_i) &= E(\beta_0 + \beta_1 x_i + \varepsilon_i) \\ &= \beta_0 + \beta_1 x_i + E(\varepsilon_i) \\ &= \beta_0 + \beta_1 x_i \end{aligned}$$



Modelos de Regressão Linear Simples

Objectivo : Dado um conjunto de observações,
 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$
estimar a melhor recta de regressão

..... distância entre
o ponto e a recta
no valor correspondente
a x



$\beta_0 = ?$
 $\beta_1 = ?$

Modelos de Regressão Linear Simples

Observações:

- 1 Como $E[\varepsilon_i] = 0$ então

$$E[Y|x_i] = \beta_0 + \beta_1 x_i \quad (\text{recta de regressão})$$

Ou seja, para cada valor x_i o ponto sobre a recta tem ordenada $E[Y|x_i] = \beta_0 + \beta_1 x_i$.

- 2 Interpretação dos parâmetros β_0 e β_1 :
 - $\beta_0 = E(Y|x = 0) \rightarrow$ ordenada na origem;
 - $\beta_1 = E(Y|x = x^* + 1) - E(Y|x = x^*), \forall x^* \rightarrow$ declive;

Modelos de Regressão Linear Simples (MRLS)

O modelo RLS diz-se:

- 1 **simples**, pelo facto de apenas existir **uma variável explicativa**, (x), na relação.

(O modelo $Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \varepsilon_i$ é um exemplo de um modelo de regressão linear múltiplo, já que envolve duas variáveis explicativas x_1 e x_2 .)

- 2 **linear**, referindo à **linearidade nos parâmetros** ($\beta_0, \beta_1 \dots$).
ou seja, modelos que em vez de x e Y apareçam funções destas variáveis também são considerados modelos de regressão linear, por exemplo, os modelos

$$Y = \beta_0 + \beta_1 x^2 + \varepsilon$$

ou

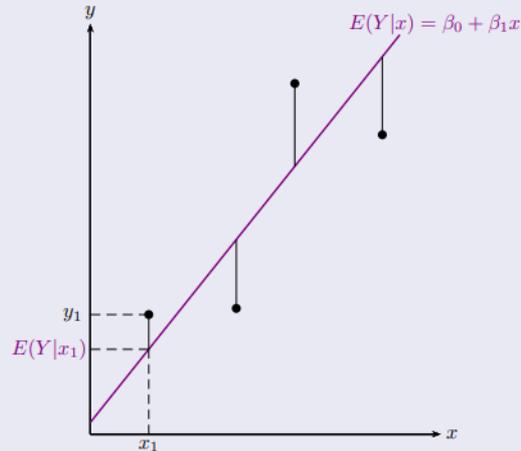
$$\log Y = \beta_0 + \beta_1 \log x + \varepsilon$$

são modelos de regressão linear.

Método dos Mínimos Quadrados: MRLS

Estimação de β_0 e β_1

Como as observações estão afetadas de erros não é possível saber qual o valor exato dos coeficientes β_0 e β_1 , mas é possível estimá-los...usando, por exemplo, o **método dos mínimos quadrados**.



Para cada valor de x_i o ponto sobre a recta tem ordenada $E(Y|x_i) = \beta_0 + \beta_1 x_i$.

Seja

$$Q(\beta_0, \beta_1) = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

Pretende-se então determinar β_0 e β_1 que minimizam $Q(\beta_0, \beta_1)$.

Método dos Mínimos Quadrados: MRLS

Estimação de β_0 e β_1

Amostra, $\{(x_i, y_i), i = 1, \dots, n\}$, pretende-se $(\hat{\beta}_0, \hat{\beta}_1) = \arg \min Q(\beta_0, \beta_1)$

$$\begin{cases} \frac{\partial Q}{\partial \beta_0} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) = 0 \\ \frac{\partial Q}{\partial \beta_1} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i = 0 \end{cases} \Leftrightarrow \begin{cases} n\beta_0 + \beta_1 \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \\ \beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i y_i \end{cases}$$

trata-se de um sistema de duas equações lineares a duas incógnitas que tem como solução as

estimativas dos mínimos quadrados:

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}; \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$$

$$\text{com } \bar{x} = \frac{\sum_{i=1}^n x_i}{n}, \bar{y} = \frac{\sum_{i=1}^n y_i}{n}$$

Método dos Mínimos Quadrados: MRLS

<p><i>modelo:</i></p> $Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$	<p><i>estimador MQL do intercepto</i></p> $\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x}$	<p><i>estimador MQL do coeficiente</i></p> $\hat{\beta}_1 = \frac{\sum_{i=1}^n x_i Y_i - n \bar{x} \bar{Y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$
$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2, \hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$		$\hat{\sigma}^2 = \frac{1}{n-2} \left[\left(\sum_{i=1}^n Y_i^2 - n \bar{Y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right]$
$\frac{\hat{\beta}_0 - \beta_0}{\sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right) \hat{\sigma}^2}} \sim t_{(n-2)}$	$\frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \sim t_{(n-2)}$	$\frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right) \hat{\sigma}^2}} \sim t_{(n-2)}$
$R^2 = \frac{\left(\sum_{i=1}^n x_i Y_i - n \bar{x} \bar{Y} \right)^2}{\left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \times \left(\sum_{i=1}^n Y_i^2 - n \bar{Y}^2 \right)}$		

Exemplo

Uma nutricionista está a investigar a relação entre o índice de colesterol total (x , em miligramas por decilitro) e o índice de massa corporal (Y , em quilogramas por altura ao quadrado). Numa amostra de 10 utentes de um centro de saúde, obtiveram-se os seguintes resultados:

$$\sum_{i=1}^{10} x_i = 2459, \quad \sum_{i=1}^{10} x_i^2 = 620155, \quad \sum_{i=1}^{10} y_i = 263.63, \quad \sum_{i=1}^{10} y_i^2 = 7091.388, \quad \sum_{i=1}^{10} x_i y_i = 65530.71,$$

onde $[\min_{i=1, \dots, 10}(x_i), \max_{i=1, \dots, 10}(x_i)] = [200, 310]$. Admita que x e Y estão relacionadas de acordo com o modelo de regressão linear simples, $Y = \beta_0 + \beta_1 x + \epsilon$. Obtenha a reta de mínimos quadrados com base nos dados fornecidos; além disso, calcule o coeficiente de determinação e interprete o seu valor.



Exemplo: Estimação dos Coeficientes da Reta de Regressão

Estimativas de MQ dos parâmetros desconhecidos β_0 e β_1

$$\begin{aligned}\hat{\beta}_1 &= \frac{\sum_{i=1}^{10} x_i y_i - 10 \cdot \bar{x} \bar{y}}{\sum_{i=1}^{10} x_i^2 - 10 \cdot \bar{x}^2} \\ &= \frac{65530.71 - 10 \cdot 245.9 \cdot 26.36}{620155 - 10 \cdot 245.9^2} \\ &= \frac{704.093}{15486.9} \\ &= 0.0454.\end{aligned}$$

$$\begin{aligned}\hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \cdot \bar{x} \\ &= 26.36 - 0.0454 \cdot 245.9 \\ &= 15.196.\end{aligned}$$

obtem $\hat{\beta}_1$ e $\hat{\beta}_0$,
ver fórmula

ie:

$$Y_i = 15.196 + 0.0454 x_i + \varepsilon_i \quad \text{erro (mult!)}$$

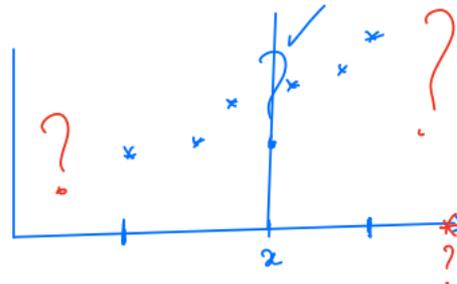
$$E(Y_i) = 15.196 + 0.0454 x_i \quad \text{erro}$$

$$x_i \in [200, 310]$$

$$E[\hat{Y}_i] = 15.196 + 0.0454 x_i \quad \text{centro}$$

Exemplo: Estimação dos Coeficientes da Reta de Regressão

nota: game de valores observados



O modelo linear e suas estimativas só são válidos para os valores da variável independente se dentro de game de valores observados.

Método dos Mínimos Quadrados: MRLS

Observações:

- 1 Pode mostrar-se, pelo determinante da matriz Hessiana, que se existir solução ela corresponde sempre a um mínimo.
- 2 Existe solução se e só se $\sum_{i=1}^n x_i^2 - n\bar{x}^2 = \sum_{i=1}^n (x_i - \bar{x})^2 \neq 0$, ou seja, se na amostra existirem pelo menos dois valores distintos de x .

3

$$\hat{y} = \widehat{E}[Y|x] = \hat{\beta}_0 + \hat{\beta}_1 x$$

é a estimativa de mínimos quadrados da reta de regressão. A estimação pontual de $E(Y|x)$ deve restringir-se ao domínio dos valores observados na amostra da variável explicativa x .

- 4 Às diferenças

$$e_i = y_i - \hat{y}_i, \quad i = 1, \dots, n$$

chamam-se **resíduos**. A análise dos resíduos permite avaliar se o modelo assumido é adequado.

Método dos Mínimos Quadrados: MRLS

Os correspondentes estimadores dos mínimos quadrados de β_0 e β_1 são, respetivamente:

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x};$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n x_i Y_i - n\bar{x}\bar{Y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2};$$

onde

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad \text{e} \quad \bar{Y} = \frac{\sum_{i=1}^n Y_i}{n}.$$

$$\hat{Y}_i = E[\widehat{Y|x_i}] = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

é o estimador de mínimos quadrados da reta de regressão.

Estimador da Variância

Recordar que no modelo apresentado aparece mais um parâmetro:
 $Var[\varepsilon_i] = \sigma^2$. Essa estimação faz-se usando os resíduos ($e_i = y_i - \hat{y}_i$).

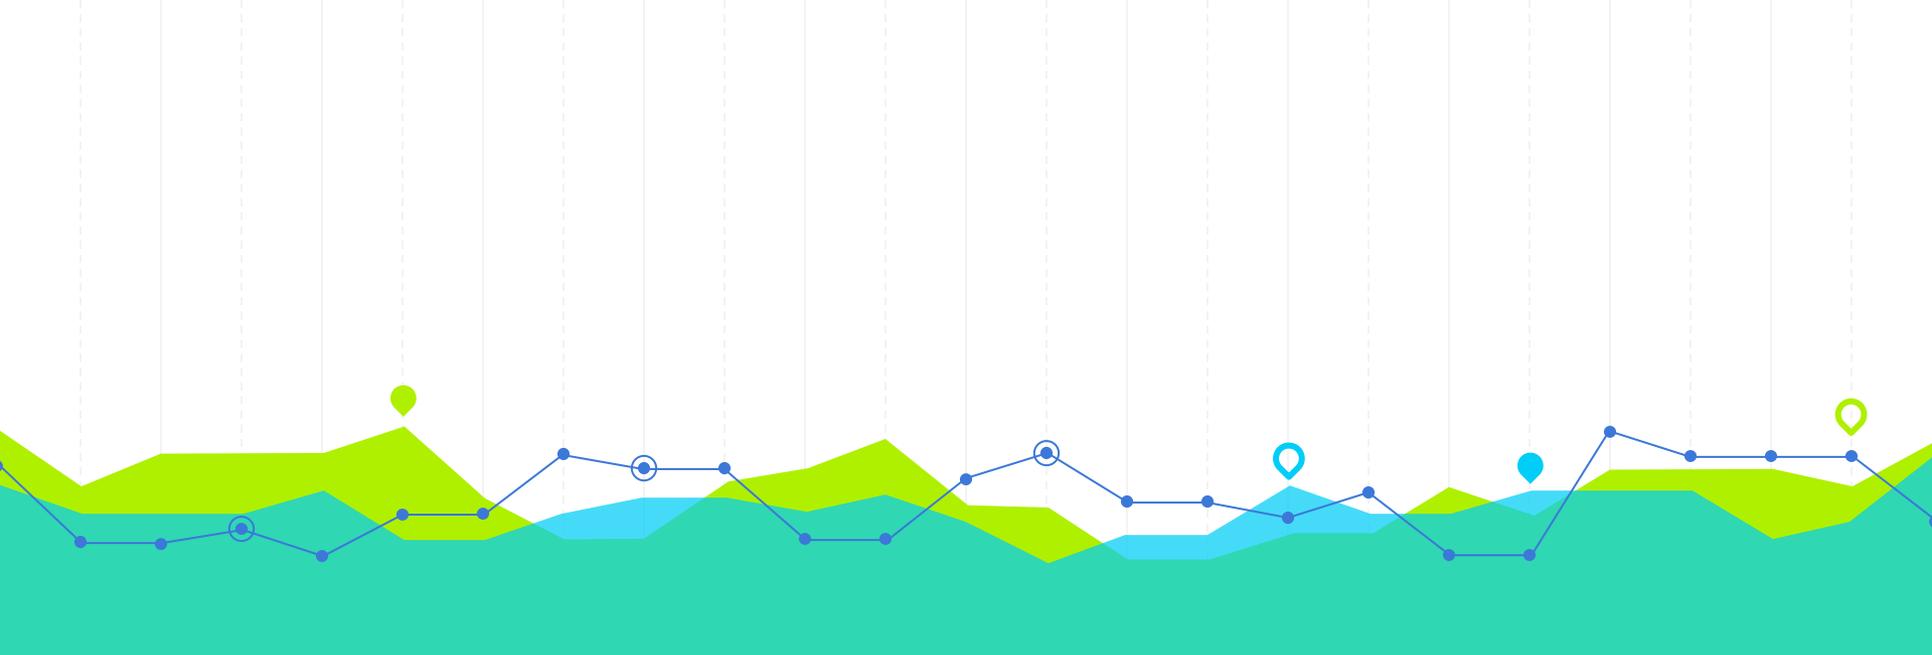
Estimação de $\sigma^2 = Var[\varepsilon_i]$

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

$$= \frac{1}{n-2} \left[\left(\sum_{i=1}^n Y_i^2 - n\bar{Y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \right] \quad (3)$$

onde $\hat{Y}_i = E[\widehat{Y|x_i}] = \hat{\beta}_0 + \hat{\beta}_1 x_i$.

- Nota:**
- A $\hat{\sigma}$ chama-se erro padrão dos resíduos;
 - $\hat{\sigma}^2$ é também um estimador da variância de Y_i .



Inferência na Regressão Linear Simples

Intervalos de Confiança e Testes de Hipóteses

Revisão

2

Inferência na Análise de Regressão



Intervalos de confiança



Testes de hipóteses:

Assumimos o modelo: $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad i = 1, \dots, n$

β_0 e β_1 são os parâmetros;

X_i são constantes conhecidas, fixas.

$\Rightarrow \varepsilon_i$ são independentes com distribuição $N(0, \sigma^2)$.



Inferência sobre os Coeficientes da Reta RLS

Para se fazerem inferências em RLS (i.e, realizar testes de hipóteses e calcular intervalos de confiança) é necessário admitir que:

os erros tenham distribuição normal

As suposições do modelo de RLS são então:

- $E[\varepsilon_i] = 0$,
- $Var[\varepsilon_i] = \sigma^2$ e
- e $Cov[\varepsilon_i, \varepsilon_j] = 0, \forall i, j \ (i \neq j)$

e com a nova hipótese de trabalho tem-se agora que

$$\varepsilon_i \underset{i.i.d.}{\sim} N(0, \sigma^2)$$

(i), (ii), (iii)
+ normalidade

Inferência sobre os Coeficientes da Reta RLS

Resultados importantes

Mostra-se que:

$$\frac{\hat{\beta}_0 - \beta_0}{\sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(n-2)},$$

e

$$\frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \sim t_{(n-2)}.$$

Estes resultados permitem realizar testes de hipóteses e calcular intervalos de confiança relativos a β_0 e β_1 , respectivamente.

Inferência sobre os Coeficientes da Reta RLS

Exemplos: Intervalos de confiança e Testes de hipóteses para:
 $\beta_0, \beta_1, E(Y|x_0)$

v. graus: $n-2$
 ordenada na origem declive

$\frac{\hat{\beta}_0 - \beta_0}{\sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(n-2)}$	$\frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum x_i^2 - n\bar{x}^2}}} \sim t_{(n-2)}$	$\frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(n-2)}$
---	--	---

valor esperado de y dado um valor particular x_0

I.C. p/ β_0
 T.H. p/ β_0

I.C. p/ β_1
 T.H. p/ β_1
 (significância estatística)

I.C. p/ $E(Y|x_0)$
 T.H. p/ $E(Y|x_0)$

Pergunta 10

2 valores

O interesse crescente na utilização da Internet para fins comerciais tem levado muitas companhias a vender os seus produtos através deste meio. Um estatístico levou a cabo um estudo para determinar até que ponto o grau de escolaridade e o uso da Internet estão ligados entre si. Para o efeito considerou uma amostra seleccionada aleatoriamente de 20 adultos, para os quais registou o número de anos de escolaridade (x , com valores observados entre 8 e 14 anos) e o número de horas despendidas na Internet, Y , na semana anterior ao decorrer do questionário. Obtiveram-se os seguintes resultados:

$$\sum_{i=1}^{20} x_i = 228, \quad \sum_{i=1}^{20} x_i^2 = 2696, \quad \sum_{i=1}^{20} y_i = 157, \quad \sum_{i=1}^{20} y_i^2 = 1671, \quad \sum_{i=1}^{20} x_i y_i = 1852.$$

Admita a validade do modelo de regressão linear simples, $Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, i = 1, \dots, 20$. Para indivíduos com 14 anos de escolaridade, obtenha um intervalo de confiança a 90% para o número esperado de horas semanais despendidas na Internet.

Pede-se: I.C. ($E(y|x=14)$)
0.90

em geral, I.C.: (exp-7)

- ① escolher a v. funcional ✓
- ② determinar os quantis ✓
- ③ inventar as desigualdades
- ④ concretizar, pl os valores amostrais

$$\frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(x-x_0)^2}{\sum x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(n-2)}$$



Exemplo: Intervalos de Confiança dos Coeficientes da Reta de Regressão

- **Hipóteses de trabalho**

No modelo de RLS, $Y_i = \beta_0 + \beta_1 x_i + \epsilon_i$, consideraremos $\epsilon_i \stackrel{i.i.d.}{\sim} \text{normal}(0, \sigma^2)$, $i = 1, \dots, n$.

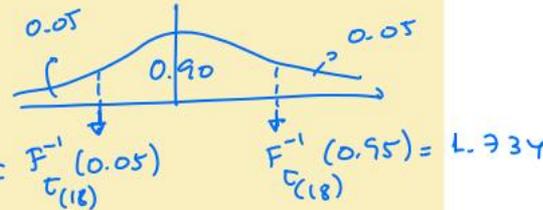
Pretende-se um intervalo de confiança a 90% para $E[Y|x = 14]$.

Observar que $x = 14 \in [\min(x_i), \max(x_i)] = [8, 14]$

- **Variável aleatória fulcral**

$$T = \frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(18)},$$

com $x_0 = 14$.



- **Intervalo aleatório** Como $1 - \alpha = 0.9$ então $\alpha = 0.10$ e $a = F_{t(18)}^{-1}\left(1 - \frac{\alpha}{2}\right) = F_{t(18)}^{-1}(1 - 0.05) = F_{t(18)}^{-1}(0.95) = 1.734$

Como a distribuição da t-Student é simétrica vem:

Exemplo: Intervalos de Confiança dos Coeficientes da Reta de Regressão

$$\textcircled{3} \quad -1.734 < \frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} < 1.734$$

$$\text{I.C.A.}_{0.90}(\beta_0 + \beta_1 x_0) = \left[\hat{\beta}_0 + \hat{\beta}_1 x_0 - 1.734 \sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}, \right. \\ \left. \hat{\beta}_0 + \hat{\beta}_1 x_0 + 1.734 \sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2} \right]$$

$$x_0 = 14; n = 20; \hat{\beta}_0 = \dots; \hat{\beta}_1 = \dots \\ \bar{x} = \dots \quad \hat{\sigma}^2 =$$

Exemplo: Intervalos de Confiança dos Coeficientes da Reta de Regressão

- **Concretização:** Precisamos de calcular as estimativas de β_0 e β_1 , que serão dadas por:

$$\begin{aligned}\hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \\ &= \frac{1852 - 20 \times 228/20 \times 157/20}{2696 - 20 \times (228/20)^2} \\ &\approx 0.6426;\end{aligned}$$

$$\begin{aligned}\hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \times \bar{x} \\ &\approx 157/20 - 0.6425 \times 228/20 \\ &= 0.5244,\end{aligned}$$

e também a estimativa de σ^2

$$\begin{aligned}\hat{\sigma}^2 &= \frac{1}{n-2} \left[\left(\sum_{i=1}^n y_i^2 - n \bar{y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right] \\ &= \frac{1}{20-2} [438.55 - 0.6425^2 \times 96.8] \\ &= 22.1432.\end{aligned}$$

O intervalo de confiança, a 90% de confiança é dado por:

$$\begin{aligned}IC_{90\%}(\beta_0 + \beta_1 \times 14) &= \left((0.5244 + 0.6426 \times 14) \pm 1.73 \sqrt{\left(\frac{1}{20} + \frac{(228/20 - 14)^2}{96.8} \right) 22.1432} \right) \\ &= (6.6961, 12.3454).\end{aligned}$$

Pergunta 10

2 valores

O interesse crescente na utilização da Internet para fins comerciais tem levado muitas companhias a vender os seus produtos através deste meio. Um estatístico levou a cabo um estudo para determinar até que ponto o grau de escolaridade e o uso da Internet estão ligados entre si. Para o efeito considerou uma amostra selecionada aleatoriamente de 20 adultos, para os quais registou o número de anos de escolaridade (x , com valores observados entre 8 e 14 anos) e o número de horas despendidas na Internet, Y , na semana anterior ao decorrer do questionário. Obtiveram-se os seguintes resultados:

$$\sum_{i=1}^{20} x_i = 228, \quad \sum_{i=1}^{20} x_i^2 = 2696, \quad \sum_{i=1}^{20} y_i = 157, \quad \sum_{i=1}^{20} y_i^2 = 1671, \quad \sum_{i=1}^{20} x_i y_i = 1852.$$

$x = 4 =$ de anos de escolaridade (8-14)

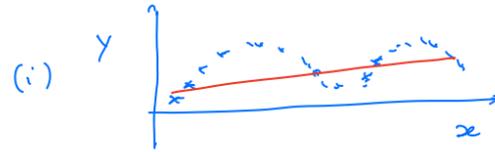
Admita a validade do modelo de regressão linear simples, $Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, i = 1, \dots, 20$. Para indivíduos com 14 anos de escolaridade, obtenha um intervalo de confiança a 90% para o número esperado de horas semanais despendidas na Internet.

• I.C. 0.90 ($\gamma | x_0 = 14$) ✓

Testar a significância do modelo de regressão (ou se há relação linear entre y e x , estatisticamente significativa)



Exemplo: Testes de Hipóteses dos Coeficientes da Reta de Regressão



É esperado se
há uma relação linear
entre y e x



É esperado se
há uma relação
linear entre y e x

$$H_0: \beta_1 = 0$$

$$H_1: \beta_1 \neq 0$$

Reconstruir

- indicar a v. funcional
- estatística de teste e o valor observado de est. teste

~~α for α de α~~

~~α in α de α~~

- construir a região de rejeição
- valor observado é R. rejeição

- calcular o valor-p
- decidir

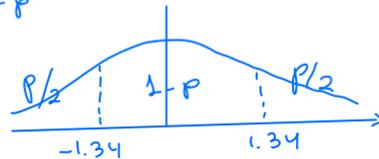
Exemplo: Testes de Hipóteses dos Coeficientes da Reta de Regressão

• variável
fict.: $T = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum x_i^2 - n\bar{x}^2}}} \sim t_{(n-2)}$

• EST. TESTE $T_0 = \frac{\hat{\beta}_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum x_i^2 - n\bar{x}^2}}} \stackrel{H_0}{\sim} t_{(n-2)}$

• valor obs: $t_0 = \frac{0.6426}{\sqrt{\frac{22.1432}{2696 - 20 \times (\frac{228}{20})^2}}} = 1.34$

• valor-p



$1 - P = F_{T(18)}(1.34) \stackrel{0.921541}{=} \Leftrightarrow P = 0.197$

• decisão: rejeitar H_0 p/ $\forall \alpha \geq 19.7\%$, ie, H_0 não deve ser rejeitada p/ os valores usuais de significância.

Exemplo: Estimativas da Reta de Regressão

- ESTIMAR o n° médio de horas despendidas no NET para 2 pessoas cuja escolaridade difere de 3 anos?

Se x e $x+3 \in [8, 14]$: OK, podemos resolver!

$$E(Y|x) = \beta_0 + \beta_1 x$$

$$\begin{aligned} E(Y|x+3) &= \beta_0 + \beta_1(x+3) = \\ &= \beta_0 + \beta_1 x + \boxed{3\beta_1} \end{aligned}$$

Resposta: diferença estimada é $3\hat{\beta}_1$

Teste de Hipóteses para a Ordenada na Origem

Teste de hipóteses relativo a β_0

- 1 Definir H_0 e H_1 : $H_0 : \beta_0 = \beta_{0,0}$ vs $H_1 : \beta_0 >, <, \neq \beta_{0,0}$
- 2 Estatística de teste:

$$T_{H_0} = \frac{\hat{\beta}_0 - \beta_{0,0}}{\sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \underset{\text{Sob } H_0}{\sim} t_{(n-2)}$$

- 3 Região Crítica (ao nível de significância α):
 - 1 $H_1 : \beta_0 \neq \beta_{0,0}$, $RC_\alpha : |T_{H_0}| > c$, com $c = F_{t_{(n-2)}}^{-1}(1 - \alpha/2)$
 - 2 $H_1 : \beta_0 > \beta_{0,0}$, $RC_\alpha : T_{H_0} > c$, com $c = F_{t_{(n-2)}}^{-1}(1 - \alpha)$
 - 3 $H_1 : \beta_0 < \beta_{0,0}$, $RC_\alpha : T_{H_0} < c$, com $c = F_{t_{(n-2)}}^{-1}(\alpha)$

Ou cálculo do valor-p.

Decisão usual.

Intervalo de Confiança para a Ordenada na Origem

Intervalo de confiança a $(1 - \alpha) \times 100\%$ para β_0

Usando a seguinte variável aleatória fulcral:

$$T = \frac{\hat{\beta}_0 - \beta_0}{\sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(n-2)}$$

obtém-se, após dedução, o seguinte intervalo para β_0 a $(1 - \alpha) \times 100\%$ de confiança

$$I.C._{(1-\alpha) \times 100\%}(\beta_0) = \hat{\beta}_0 \pm F_{t_{n-2}}^{-1}(1 - \alpha/2) \sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}$$

Teste de Hipóteses para o Declive

Teste de hipóteses relativo a β_1

- 1 Definir H_0 e H_1 : $H_0 : \beta_1 = \beta_{1,0}$ vs $H_1 : \beta_1 >, <, \neq \beta_{1,0}$
- 2 Estatística de teste:

$$T_{H_0} = \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \underset{\text{Sob } H_0}{\sim} t_{(n-2)}.$$

- 3 Região crítica (ao nível de significância α):
 - 1 $H_1 : \beta_1 \neq \beta_{1,0}$, $RC_\alpha : |T_{H_0}| > c$, com $c = F_{t_{(n-2)}}^{-1}(1 - \alpha/2)$
 - 2 $H_1 : \beta_1 > \beta_{1,0}$, $RC_\alpha : T_{H_0} > c$, com $c = F_{t_{(n-2)}}^{-1}(1 - \alpha)$
 - 3 $H_1 : \beta_1 < \beta_{1,0}$, $RC_\alpha : T_{H_0} < c$, com $c = F_{t_{(n-2)}}^{-1}(\alpha)$.

Ou cálculo do valor-p.

Decisão usual.

Teste de Hipóteses para o Declive

Observações:

- 1 Um teste importante em RLS é

$$H_0 : \beta_1 = 0 \text{ vs } H_1 : \beta_1 \neq 0$$

pois não rejeitar H_0 significa que há evidência para a não existência de uma associação linear entre x e y , ou seja não há associação ou a associação não é linear. A este teste costuma designar-se por:

teste à significância da regressão

- 2 Como já foi referido no Capítulo 8 também se pode realizar um teste de hipóteses usando a relação com intervalos de confiança (desde que a v.a. fulcral e a estatística de teste sejam da mesma forma!).

Intervalo de Confiança para o Declive

Intervalo de confiança a $(1 - \alpha) \times 100\%$ para β_1

Usando a seguinte variável aleatória fulcral:

$$T = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \sim t_{(n-2)}$$

obtém-se, após dedução, o seguinte intervalo para β_1 a $(1 - \alpha) \times 100\%$ de confiança:

$$I.C._{(1-\alpha) \times 100\%}(\beta_1) = \hat{\beta}_1 \pm F_{t_{n-2}}^{-1}(1 - \alpha/2) \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}$$

Teste de Hipóteses para o Valor Médio de Y dado um dado x

Em algumas situações é necessário efetuar inferências sobre o valor médio de Y para um dado valor fixo de x, digamos, x_0 .

Inferência para $E[Y|x_0] = \beta_0 + \beta_1 x_0$

Um estimador pontual de $E[Y|x_0] = \beta_0 + \beta_1 x_0$ é:

$$\widehat{E[Y|x_0]} = \hat{\beta}_0 + \hat{\beta}_1 x_0.$$

E pode mostrar-se que:

$$\frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(n-2)}.$$

Testes de hipóteses e intervalos de confiança para $E[Y|x_0]$ são então baseados nesta variável, e o procedimento é o habitual.



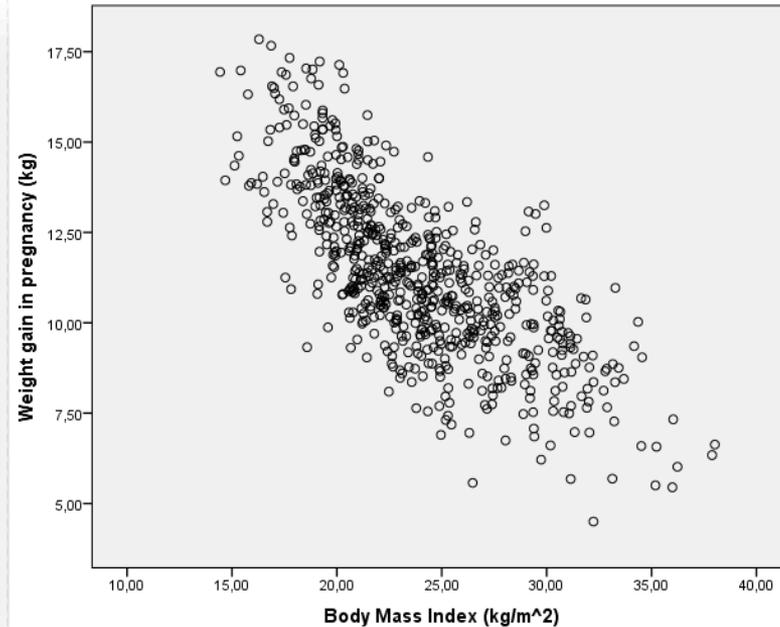
Qualidade do Modelo de Regressão Linear Simples

Coeficiente de determinação

Revisão

Diagrama de Dispersão

BMI vs. WGain



Coeficiente de Correlação de Pearson e Coeficiente de Determinação

BMI vs. WGain

SPSS: Analyze > Correlate > Bivariate [✓ Pearson ...]

Correlações Bivariadas

Variáveis:

- Maternal age [Age]
- Weight before pre...
- Weight after preg...
- Height (m) [Height]
- Maternal asthma [...]
- Maternal smoking...
- Older siblings in t...
- Maternal educatio...
- Household incom...

Body Mass Index (kg/m²)

Weight gain in pregn...

Opções...
Estilo...
Bootstrap...

Coefficientes de correlação

Pearson Tau-b de Kendall Spearman

Teste de significância

Com duas extremidades Com uma extremidade

Criar flag para correlações significantes

		Body Mass Index (kg/m ²)	Weight gain in pregnancy (kg)
Body Mass Index (kg/m ²)	Correlação de Pearson	1	-,738**
	Sig. (bilateral)		,000
	N	699	699
Weight gain in pregnancy (kg)	Correlação de Pearson	-,738**	1
	Sig. (bilateral)	,000	
	N	699	699

** . A correlação é significativa no nível 0,01 (bilateral).

Coeficiente de Correlação de Pearson:
 $r = -0,738 \Rightarrow$ Correlação linear negativa moderada, pois $-0,8 < r \leq -0,5$.

54,4% da variabilidade no WGain (variável dependente) pode ser explicada pelo BMI (variável independente) no modelo.

Coeficiente de Determinação: $r^2 = 0,544$

Regressão Linear

BMI vs. WGain

SPSS: Analyze Regression Linear

Coefficiente de Determinação: $r^2 = 0,544$

Regressão linear

Dependente: Weight gain in pregnancy (kg) [...]

Bloco 1 de 1

Anterior Próximo

Independente(s): Body Mass Index (kg/m²) [BMI]

Método: Enter

Variável de seleção:

ANOVA^a

Modelo	Soma dos Quadrados	gl	Quadrado Médio	F	Sig.	
1	Regressão	2028,201	1	2028,201	831,467	,000 ^b
	Resíduo	1700,196	697	2,439		
	Total	3728,397	698			

a. Variável Dependente: Weight gain in pregnancy (kg)
b. Preditores: (Constante), Body Mass Index (kg/m²)

Coefficients^a

Model		Unstandardized Coefficients	Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	20,900	,337	62,024	,000	20,239	21,562
	Body Mass Index (kg/m ²)	-,400	,014	-,738	,000	-,427	-,373

a. Dependent Variable: Weight gain in pregnancy (kg)

Reta de Regressão: $y = 20,900 - 0,400x$

Nota: Neste output, o valor do coeficiente de correlação surge sempre positivo independentemente se de fato é positivo ou negativo. Provavelmente é um lapso do package. Por exemplo, neste caso, sabe-se que $r = -0,738$, mas neste output surge $r = 0,738$.

Regressão Linear

BMI vs. WGain

X - BMI

- v.a. independente, explicativa
- Quantitativa contínua (escala métrica)

Y - WGain

- v.a. dependente
- Quantitativa contínua (escala métrica)

Considere-se a reta de regressão: $y = \alpha + \beta x$, onde α = ordenada na origem e β = declive

Hipóteses

- $H_0: \alpha = 0$ versus $H_1: \alpha \neq 0$
- $H_0: \beta = 0$ versus $H_1: \beta \neq 0$

Testes de Hipóteses para os Coeficientes da Reta de Regressão

BMI vs. WGain

Valores observados das estatísticas de teste (VOE)

- a) $t_0 = 62,024$ e valor- $p < 0,0005 < 0,05 \Rightarrow$ Rejeita-se H_0 para $\alpha = 0,05$
- b) $t_0 = -28,835$ e valor- $p < 0,0005 < 0,05 \Rightarrow$ Rejeita-se H_0 para $\alpha = 0,05$

Conclusão

- Faz sentido ajustar um modelo de **regressão linear simples**.
- O valor de beta ou coeficiente estandardizado/padronizado corresponde ao **coeficiente de correlação linear de Pearson**: $r = -0,738 \sim -0,74$.
- Existe evidência estatística para afirmar que existe uma **associação (correlação) linear negativa moderada** entre X e Y (ou seja, parece existir uma relação de dependência), pois $-0,8 < r \leq -0,5$.
- O **coeficiente de determinação** é igual a $r^2 = 0,544$. Logo a qualidade do ajustamento do modelo aos dados é moderada.

Nota: O sinal de beta (declive da reta) indica se a relação linear é positiva ou negativa (direta ou inversa).

Modelo		Coeficientes não padronizados		Coeficientes padronizados		
		B	Erro Padrão	Beta	Sig.	
1	(Constante)	20,900	,337		62,024	,000
	Body Mass Index (kg/m ²)	-4,000	,014	-,738	-28,835	,000

a. Variável Dependente: Weight gain in pregnancy (kg)

Equação da Reta de Regressão e Previsões

BMI vs. WGain

Estimativas dos parâmetros α e β

- a) $a = 20,900$
- b) $b = -0,400$ (declive negativo)

Reta de regressão ajustada

$$y = 20,900 - 0,400x$$

Previsões

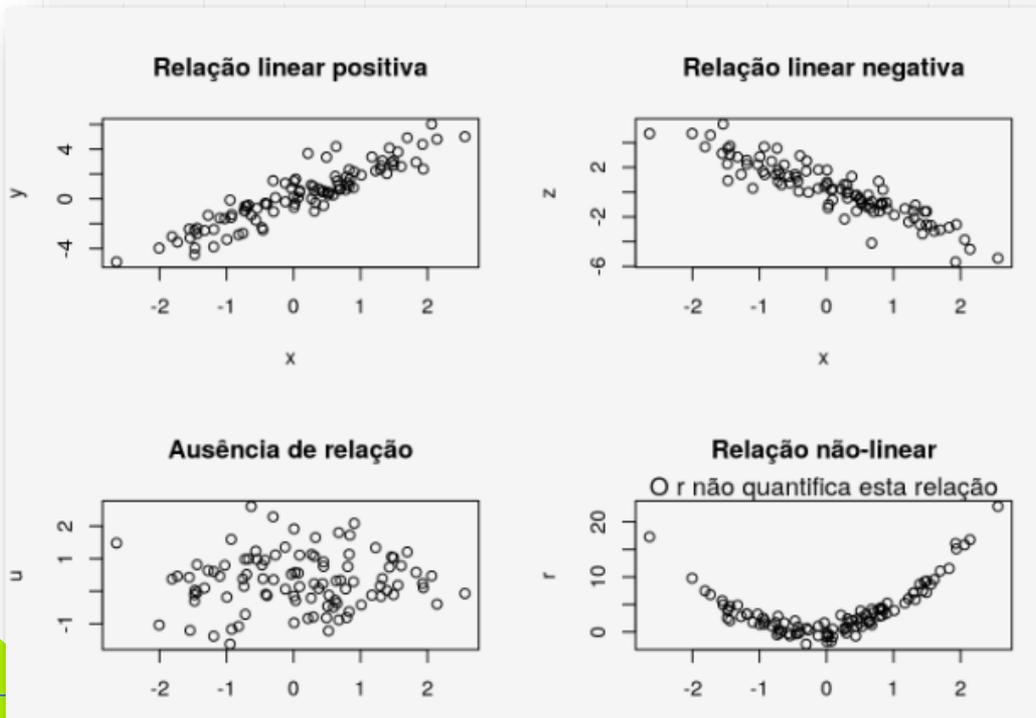
Se $x = 30$ então $y^* = 8,9\text{kg}$

	N	Mínimo	Máximo	Média	Desvio Padrão
Body Mass Index (kg/m ²)	699	14,43	38,02	23,9178	4,26199
N válido (listwise)	699				

Nota: Não é possível obter-se uma previsão do ganho de peso durante a gravidez para as mulheres que tenham um BMI inferior a 14,43 e superior a 38,02, pois esses valores não pertence ao intervalo de valores de x (14,43; 38,02) utilizados na estimação dos coeficientes da reta de regressão.

Associação/Correlação Linear?

<https://lec.pro.br//2-nao-categorizado/150-cor-pearson>



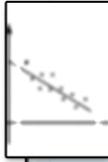
Coeficiente de Correlação de Pearson

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right] \left[\sum_{i=1}^n (y_i - \bar{y})^2 \right]}}$$



$r = -1$

- Correlação linear negativa perfeita



$-1 < r \leq -0,8$

- Correlação linear negativa forte



$-0,8 < r \leq -0,5$

- Correlação linear negativa moderada



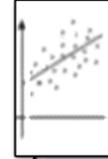
$-0,5 < r < 0$

- Correlação linear negativa fraca



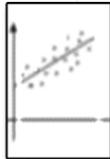
$r = 0$

- Não existe correlação linear



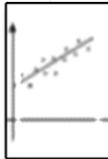
$0 < r < 0,5$

- Correlação linear positiva fraca



$0,5 \leq r < 0,8$

- Correlação linear positiva moderada



$0,8 \leq r < 1$

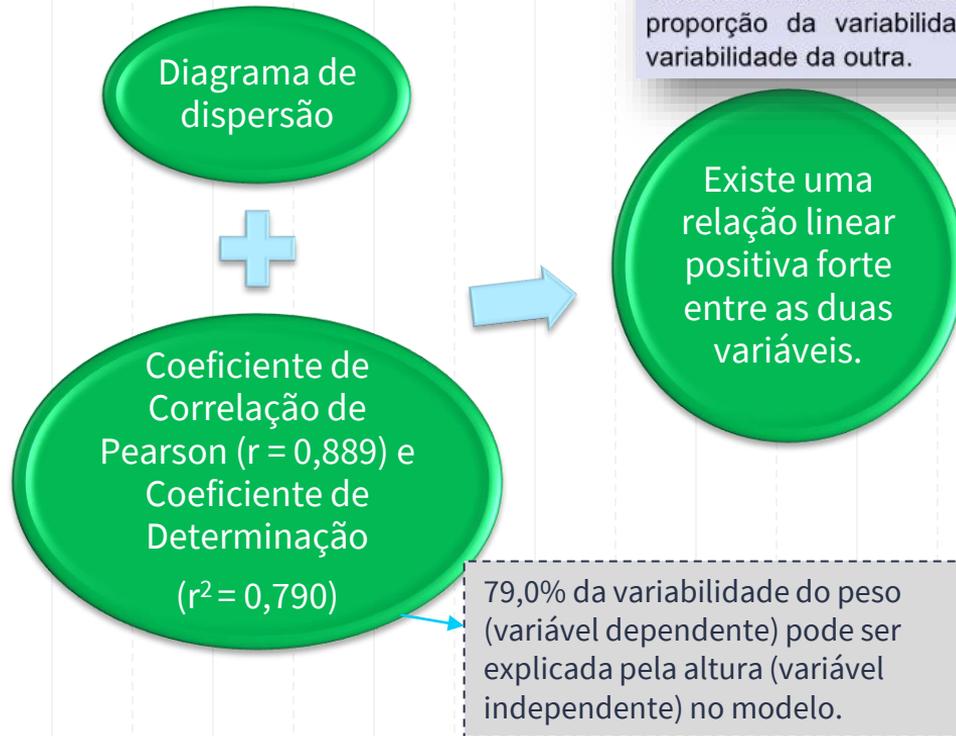
- Correlação linear positiva forte



$r = 1$

- Correlação linear positiva perfeita

Coeficiente de Determinação



O **coeficiente de determinação** ou simplesmente R^2 . É uma medida da proporção da variabilidade em uma variável que é explicada pela variabilidade da outra.

<https://pt.slideshare.net/rodrigomuribec>

Faixa de variação de r : $0 \leq r^2 \leq 1$

Interpretação:

- a) **Próximo de 1**: Forte poder de explicação do modelo (reta de regressão);
- b) **Próximo de 0**: Fraco poder de explicação do modelo (reta de regressão);
- c) **Exemplo**: $r^2 = 0,92$. Então, 92% da variação de y pode ser explicada pela relação entre x e y .

<https://slideplayer.com.br/slide/48204>

Coefficiente de Determinação

Decomposição das somas dos quadrados

O coeficiente de determinação é uma medida descritiva indicadora da qualidade do ajustamento da recta estimada. Mostra-se que:

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

SST *SSE* *SSR*

onde

- *SST* corresponde à soma de quadrados total
- *SSE* corresponde à soma dos quadrados dos resíduos
- *SSR* é a soma dos quadrados da regressão

Coefficiente de Determinação

Coefficiente de determinação: R^2

O coeficiente de determinação é, então, dado pela expressão:

$$\begin{aligned}R^2 &= \frac{SSR}{SST} = \frac{\text{variação explicada pelo modelo}}{\text{variação total}} = \\&= 1 - \frac{SSE}{SST} = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = \\&= \frac{\left(\sum_{i=1}^n x_i Y_i - n\bar{x}\bar{Y} \right)^2}{\left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \left(\sum_{i=1}^n Y_i^2 - n\bar{Y}^2 \right)}.\end{aligned}$$

$$R^2 = \frac{\left(\sum_{i=1}^n x_i Y_i - n\bar{x}\bar{Y} \right)^2}{\left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \times \left(\sum_{i=1}^n Y_i^2 - n\bar{Y}^2 \right)} \in [0,1]$$

Coeficiente de Determinação

Interpretação: $R^2 \times 100\%$ representa a % de variabilidade do y explicada pelo modelo de regressão linear simples.

R^2 "pequeno" \rightarrow modelo é pouco adequado
[provavelmente ao testar se $\beta_1 = 0$, vamos aceitar]

R^2 "grande" \rightarrow modelo é adequado
[provavelmente ao testar se $\beta_1 = 0$, vamos rejeitar]

Coeficiente de Determinação

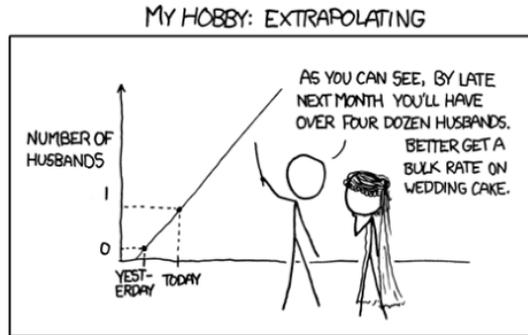
O coeficiente de determinação e o ajuste do modelo

- $R^2 \times 100\%$ representa a percentagem de variabilidade total de Y que é explicada pelo modelo de regressão.
- $\hat{y}_i = y_i, \forall i, \Leftrightarrow R^2 = 1$. Todos os pontos estão sobre a recta, o modelo de regressão explica toda a variabilidade observada em y . **Modelo óptimo!**
- $\hat{\beta}_1 = 0 \Leftrightarrow \hat{\beta}_0 = \bar{y} \Leftrightarrow \hat{y}_i = \bar{y}, \forall i, \Leftrightarrow R^2 = 0$. A recta é horizontal, o modelo de regressão não explica nada da variabilidade observada em y . **Modelo péssimo!**
- Em geral, $0 < R^2 < 1$.
- Observar que a expressão do coeficiente de **determinação** em RLS corresponde ao **quadrado** do coeficiente de **correlação** linear (r_{xy}) que vimos no Cap.1.

Coeficiente de Determinação

Extrapolação: pode ser uma má ideia!

Extrapolação – uso do modelo de regressão para valores fora do domínio da variável explicativa.



Para explorar a relação entre a massa muscular e a idade (no género feminino) um nutricionista seleccionou aleatoriamente 16 mulheres com idades compreendidas entre os 40 e os 79 anos. Os resultados observados encontram-se na tabela seguinte (x representa a idade e y é um índice de massa muscular):

i	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
x_i	71	64	43	67	56	73	68	56	76	65	45	58	45	53	49	78
y_i	82	91	100	68	87	73	78	80	65	84	116	76	97	100	105	77

$$\sum_{i=1}^{16} x_i = 967, \quad \sum_{i=1}^{16} y_i = 1379, \quad \sum_{i=1}^{16} x_i^2 = 60409, \quad \sum_{i=1}^{16} y_i^2 = 121887,$$

$$\sum_{i=1}^{16} x_i y_i = 81331.$$



Admita que o modelo de regressão linear simples ($Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$) é adequado.

- a) Calcule:
 - i) uma estimativa pontual da diferença entre as massas musculares médias de mulheres cujas idades diferem de um ano;
 - ii) uma estimativa pontual da massa muscular média para as mulheres de 60 anos;
 - iii) o valor do resíduo para a 8ª observação;
 - iv) uma estimativa pontual de $Var(\varepsilon_i) = \sigma^2$;
 - v) o coeficiente de determinação e interprete o valor obtido.
- b) O nutricionista pensa que (na gama de idades considerada) a massa muscular é significativamente influenciada pela idade. Acha que as observações confirmam esta hipótese? Use um nível de significância de 5% e indique as hipóteses de trabalho de que necessita para efectuar o teste.
- c) Calcule o intervalo de confiança a 99% para o valor esperado da massa muscular para uma mulher de 45 anos. Acha legítimo usar o mesmo procedimento tratando-se de uma mulher com 20 anos em vez de 45?



Modelo de RLS

Resolução:

Modelo de RLS:

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i,$$

onde

Y_i : variável aleatória que representa o índice da massa muscular associada à i -ésima mulher;

x_i : variável explicativa que representa a idade da i -ésima mulher;

β_0, β_1 : parâmetros;

ε_i : erro aleatório associado à i -ésima mulher, verificando:

(i) $E[\varepsilon_i] = 0$;

(ii) $Var[\varepsilon_i] = \sigma^2$;

(iii) $Cov[\varepsilon_i, \varepsilon_j] = 0, \forall i, j \ (i \neq j)$;

$i = 1, 2, \dots, 16$.

Exercício a) i)

Cálculos auxiliares:

$$\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} = 81331 - 16 \times \frac{967}{16} \times \frac{1379}{16} = -2012.3125$$

$$\sum_{i=1}^n x_i^2 - n \bar{x}^2 = 60409 - (967^2)/16 = 1965.9375$$

$$\sum_{i=1}^n y_i^2 - n \bar{y}^2 = 121887 - (1379^2)/16 = 3034.4375$$

a) Calcule:

- i) uma estimativa pontual da diferença entre as massas musculares médias de mulheres cujas idades diferem de um ano;

Como

$E[Y|(x_j + 1)] - E[Y|(x_j)] = \beta_0 + \beta_1(x_j + 1) - \beta_0 - \beta_1 x_j = \beta_1$,
então uma estimativa dessa diferença será

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} = \frac{-2012.3125}{1965.9375} \approx -1.0236$$

Exercícios a) ii) e iii)

- ii) uma estimativa pontual da massa muscular média para as mulheres de 60 anos;

A estimativa pretendida é

$$\hat{E}[Y|x = 60] = \hat{\beta}_0 + \hat{\beta}_1 \times 60 = 148.05 - 1.0236 \times 60 \approx 86.63, \text{ pois}$$
$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} = 1379/16 + 1.0236 \times (967/16) \approx 148.05.$$

- iii) o valor do resíduo para a 8ª observação;

Representando $\hat{y}_i = \hat{E}[Y|x_i]$ sabe-se que o oitavo resíduo é dado por $e_8 = y_8 - \hat{y}_8 = 80 - 90.728 \approx -10.7284$, já que $\hat{y}_8 = 148.05 - 1.0236 \times 56 = 90.728$.

Exercícios a) iv) e v)

iv) uma estimativa pontual de $\text{Var}(\varepsilon_i) = \sigma^2$;

Uma estimativa pontual de $\text{Var}(\varepsilon_i) = \sigma^2, \forall i, i = 1, 2, \dots, 16$ é

$$\begin{aligned}\hat{\sigma}^2 &= \frac{1}{n-2} \left[\left(\sum_{i=1}^n y_i^2 - n\bar{y}^2 \right) - \left(\hat{\beta}_1 \right)^2 \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \right] = \\ &= \frac{1}{14} (3034.4375) - (-1.0236)^2 (1965.9375) \approx 69.62\end{aligned}$$

v) o coeficiente de determinação e interprete o valor obtido.

O valor para o coeficiente de determinação é

$$r^2 = \frac{\left(\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right)^2}{\left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \left(\sum_{i=1}^n y_i^2 - n\bar{y}^2 \right)} = \frac{(-2012.3125)^2}{(1965.9375)(3034.4375)} \approx 0.679.$$

Este valor indica que cerca de 67% da variabilidade deste índice de massa muscular é explicada pela idade (da mulher).

Exercício b)

b) O nutricionista pensa que (na gama de idades considerada) a massa muscular é significativamente influenciada pela idade. Acha que as observações confirmam esta hipótese? Use um nível de significância de 5% e indique as hipóteses de trabalho de que necessita para efetuar o teste.

O que o nutricionista pretende testar pode ser traduzido no seguinte teste de hipóteses:

Hipóteses: $H_0 : \beta_1 = 0$ vs $H_1 : \beta_1 \neq 0$

Para se efetuar este teste de hipóteses é necessário considerar a seguinte hipótese de trabalho:

$$\varepsilon_i \underset{i.i.d.}{\sim} N(0, \sigma^2), \quad \forall i, \quad i = 1, 2, \dots, 16.$$

$$\text{Estatística de teste: } T_{H_0} = \frac{\hat{\beta}_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \underset{\text{Sob } H_0}{\sim} t_{(14)}.$$

Exercício b)

Valor observado da estatística de teste:

$$t_{obs} = \frac{-1.0236}{\sqrt{\frac{69.62}{1965.9375}}} \approx -5.44$$

Região Crítica para T_{H_0} ao nível de significância $\alpha = 0.05$:

$RC_{0.05} = (-\infty, -c) \cup (c, +\infty)$, onde $c : P(T_{H_0} \in RC|H_0) = 0.05$. Então o valor de c será dado por

$$c = F_{t(14)}^{-1}\left(1 - \frac{\alpha}{2}\right) = F_{t(14)}^{-1}(1 - 0.025) = F_{t(14)}^{-1}(0.975) = 2.145,$$

logo

$$RC_{0.05} = (-\infty, -2.145) \cup (2.145, +\infty).$$

Decisão:

Como o valor observado da estatística de teste, $t_{obs} = -5.44 \in RC_{0.05}$, devemos rejeitar H_0 ao nível de significância de 5%, ou seja, parece haver evidência de que a idade da mulher influencia a sua massa muscular.

Exercício c)

- c) Calcule o intervalo de confiança a 99% para o valor esperado da massa muscular para uma mulher de 45 anos. Acha legítimo usar o mesmo procedimento tratando-se de uma mulher com 20 anos em vez de 45?

Pretende-se um intervalo de confiança a 99% para $E[Y|x = 45]$.
Observar que $x = 45 \in (\min(x_i), \max(x_i))$.

Variável aleatória fulcral:

$$T = \frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \sim t_{(14)},$$

com $x_0 = 45$.

Exercício c)

Como $1 - \alpha = 0.99$ então $\alpha = 0.01$ e

$$a = F_{t(14)}^{-1}\left(1 - \frac{\alpha}{2}\right) = F_{t(14)}^{-1}(1 - 0.005) = F_{t(14)}^{-1}(0.995) = 2.977.$$

Como a distribuição da t-Student é simétrica vem:

$$P\left(-2.977 \leq \frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - (\beta_0 + \beta_1 x_0)}{\sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}} \leq 2.977\right) = 0.99$$
$$\equiv P\left((\hat{\beta}_0 + \hat{\beta}_1 x_0) - 2.977 \sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2} \leq (\beta_0 + \beta_1 x_0) \leq (\hat{\beta}_0 + \hat{\beta}_1 x_0) + 2.977 \sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}\right) \hat{\sigma}^2}\right) = 0.99$$

Exercício c)

Obtendo-se então o intervalo aleatório:

$$IAC_{99\%}(\beta_0 + \beta_1 x_0) = \left((\hat{\beta}_0 + \hat{\beta}_1 x_0) \pm 2.977 \sqrt{\left(\frac{1}{n} + \frac{(\bar{x} - x_0)^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right) \hat{\sigma}^2} \right)$$

Concretização: O intervalo de confiança, a 99% de confiança é dado por:

$$\begin{aligned} IC_{99\%}(\beta_0 + \beta_1 \times 45) &= \\ \left((148.05 - 1.0236 \times 45) \pm 2.977 \sqrt{\left(\frac{1}{16} + \frac{\left(\frac{967}{16} - 45\right)^2}{1965.9375} \right) 69.62} \right) &= \\ &= (91.34, 112.63) \end{aligned}$$

Para $x = 20$ anos não é correto utilizar o mesmo procedimento pois este valor não pertence ao $(\min(x_i), \max(x_i))$. Qualquer extrapolação para valores que não fizeram parte do ajuste do modelo será um abuso.

Obrigada!

Questões?

