

Modelos de Regressão Múltipla - Parte II

Erica Castilho Rodrigues

25 de Outubro de 2016

Modelo de Regressão Linear Múltipla

Estimação de β via mínimos quadrados

Tabela ANOVA

Coeficiente de Determinação Ajustado

Modelo de Regressão Linear Múltipla

- ▶ Uma variável resposta Y e p variáveis explicativas

$$Y = \beta_0 + \beta_1 X_1 + \cdots + \beta_p X_p + \epsilon$$

onde ϵ é o erro aleatório.

- ▶ Com uma amostra de n observações (indivíduos), podemos escrever:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_p X_{ip} \quad \text{para } i = 1, 2, \dots, n.$$

ou seja

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \cdots + \beta_p X_{1p}$$

$$Y_2 = \beta_0 + \beta_1 X_{21} + \beta_2 X_{22} + \cdots + \beta_p X_{2p}$$

⋮

$$Y_n = \beta_0 + \beta_1 X_{n1} + \beta_2 X_{n2} + \cdots + \beta_p X_{np}$$

Interpretação dos Coeficientes

Interpretação do β_j pra $j \geq 1$

Interpretação dos Coeficientes

Interpretação do β_j pra $j \geq 1$

- ▶ Matemos constantes todos X_i com exceção do X_j .
- ▶ β_j representa a variação no Y quando X_j aumenta em uma unidade.
- ▶ Se $\beta_j > 0$, Y aumenta.
- ▶ Se $\beta_j < 0$, Y diminui.
- ▶ Vejamos porque isso é verdade.

- ▶ Para $X_j = x_j$, temos que

$$E(Y|X_j = x_j) =$$

- ▶ Para $X_j = x_j$, temos que

$$E(Y|X_j = x_j) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_p x_p .$$

- ▶ Para $X_j = x_j + 1$, temos

$$E(Y|X_j = x_j + 1) =$$

- ▶ Para $X_j = x_j$, temos que

$$E(Y|X_j = x_j) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_p x_p.$$

- ▶ Para $X_j = x_j + 1$, temos

$$E(Y|X_j = x_j + 1) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j (x_j + 1) + \cdots + \beta_p x_p.$$

- ▶ Assim, a diferença na $E(Y)$ ao se passar de $X_j = x_j$ para $X_j = x_j + 1$ é igual a

$$E(Y|X_j = x_j + 1) - E(Y|X_j = x_j) =$$

- ▶ Para $X_j = x_j$, temos que

$$E(Y|X_j = x_j) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_p x_p.$$

- ▶ Para $X_j = x_j + 1$, temos

$$E(Y|X_j = x_j + 1) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j (x_j + 1) + \cdots + \beta_p x_p.$$

- ▶ Assim, a diferença na $E(Y)$ ao se passar de $X_j = x_j$ para $X_j = x_j + 1$ é igual a

$$\begin{aligned} & E(Y|X_j = x_j + 1) - E(Y|X_j = x_j) = \\ & (\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j (x_j + 1) + \cdots + \beta_p x_p) - \\ & (\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j + \cdots + \beta_p x_p) = \beta_j. \end{aligned}$$

- ▶ Vimos que o modelo de regressão para n observações é dado por

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \cdots + \beta_p X_{1p}$$

$$Y_2 = \beta_0 + \beta_1 X_{21} + \beta_2 X_{22} + \cdots + \beta_p X_{2p}$$

⋮

$$Y_n = \beta_0 + \beta_1 X_{n1} + \beta_2 X_{n2} + \cdots + \beta_p X_{np}$$

- ▶ Podemos reescrever em notação matricial

- ▶ Vimos que o modelo de regressão para n observações é dado por

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \cdots + \beta_p X_{1p}$$

$$Y_2 = \beta_0 + \beta_1 X_{21} + \beta_2 X_{22} + \cdots + \beta_p X_{2p}$$

$$\vdots$$

$$Y_n = \beta_0 + \beta_1 X_{n1} + \beta_2 X_{n2} + \cdots + \beta_p X_{np}$$

- ▶ Podemos reescrever em notação matricial

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \cdots & X_{1p} \\ 1 & X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon$$

Onde

- ▶ **Y** vetor

Onde

- ▶ **Y** vetor $n \times 1$ da variável resposta.
- ▶ **X** é uma matrix

Onde

- ▶ \mathbf{Y} vetor $n \times 1$ da variável resposta.
- ▶ \mathbf{X} é uma matrix $n \times (p + 1)$ da variável explicativa.
- ▶ β é um vetor

Onde

- ▶ \mathbf{Y} vetor $n \times 1$ da variável resposta.
- ▶ \mathbf{X} é uma matrix $n \times (p + 1)$ da variável explicativa.
- ▶ β é um vetor $(p + 1) \times 1$ dos parâmetros.
- ▶ ϵ é um vetor

Onde

- ▶ \mathbf{Y} vetor $n \times 1$ da variável resposta.
- ▶ \mathbf{X} é uma matrix $n \times (p + 1)$ da variável explicativa.
- ▶ β é um vetor $(p + 1) \times 1$ dos parâmetros.
- ▶ ϵ é um vetor $n \times 1$ dos erros.

Suposições do Modelo

- ▶ Os erros

$$\epsilon_1, \epsilon_2, \dots, \epsilon_n$$

tem média igual a zero e variância igual a σ^2 .

- ▶ Isso implica que

$$E(Y_i|\mathbf{X}) = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip}$$

$$\text{Var}(Y_i|\mathbf{X}) = \sigma^2.$$

- ▶ Os erros

$$\epsilon_1, \epsilon_2, \dots, \epsilon_n$$

são não correlacionados.

- ▶ Isso implica que os Y_i são não correlacionados.

- ▶ Os erros

$$\epsilon_1, \epsilon_2, \dots, \epsilon_n$$

têm distribuição normal.

- ▶ Isso implica que os Y_i têm distribuição normal.

Resumindo...

- ▶ Supõe-se que os erros seguem a seguinte distribuição

$$\epsilon \sim$$

Resumindo...

- ▶ Supõe-se que os erros seguem a seguinte distribuição

$$\epsilon \sim N_p(\mathbf{0}, \sigma^2 \mathbf{I})$$

onde

$$\epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \dots \\ \epsilon_n \end{bmatrix}$$

o vetor de médias é dado por

$$\mathbf{0} = \begin{bmatrix} 0 \\ 0 \\ \dots \\ 0 \end{bmatrix} \text{ e a matriz de covariâncias } \sigma^2 \mathbf{I} = \sigma^2 \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}$$

Resumindo...

- ▶ Isso implica que

$$Y \sim$$

Resumindo...

- ▶ Isso implica que

$$\mathbf{Y} \sim N_p(\mathbf{X}\beta, \sigma^2\mathbf{I})$$

onde

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad \mathbf{X}\beta = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1p} \\ 1 & X_{21} & X_{22} & \dots & X_{2p} \\ \vdots & X_{n1} & X_{n2} & \dots & X_{np} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}$$

Estimação de β via mínimos quadrados

- ▶ Queremos encontrar β que minimiza a soma dos quadrados dos erros:

$$\begin{aligned} S &= \sum_{i=1}^n \epsilon_i^2 = (\epsilon_1^2 + \epsilon_2^2 + \dots + \epsilon_n^2) \\ &= (\epsilon_1 \quad \epsilon_2 \quad \dots \quad \epsilon_n) \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \dots \\ \epsilon_n \end{pmatrix} = \epsilon' \epsilon \end{aligned}$$

onde

$$\epsilon = \mathbf{Y} - \mathbf{X}\beta.$$

- ▶ Portanto, a soma de quadrados dos erros é dada por

$$\epsilon' \epsilon = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta).$$

- ▶ Vimos que derivando com relação a β e igualando a zero, obtemos

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y}).$$

- ▶ Vamos usar o seguinte resultado.
- ▶ Se \mathbf{A} é uma matriz de constantes e \mathbf{Y} uma matriz de variáveis aleatórias

$$E(\mathbf{A}\mathbf{Y}) = \mathbf{A}E(\mathbf{Y}).$$

- ▶ Esse é um estimador não viesado

$$E(\hat{\beta}) =$$

- ▶ Portanto, a soma de quadrados dos erros é dada por

$$\epsilon' \epsilon = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta).$$

- ▶ Vimos que derivando com relação a β e igualando a zero, obtemos

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y}).$$

- ▶ Vamos usar o seguinte resultado.
- ▶ Se \mathbf{A} é uma matriz de constantes e \mathbf{Y} uma matriz de variáveis aleatórias

$$E(\mathbf{A}\mathbf{Y}) = \mathbf{A}E(\mathbf{Y}).$$

- ▶ Esse é um estimador não viesado

$$E(\hat{\beta}) = E((\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y})) =$$

- ▶ Portanto, a soma de quadrados dos erros é dada por

$$\epsilon' \epsilon = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta).$$

- ▶ Vimos que derivando com relação a β e igualando a zero, obtemos

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y}).$$

- ▶ Vamos usar o seguinte resultado.
- ▶ Se \mathbf{A} é uma matriz de constantes e \mathbf{Y} uma matriz de variáveis aleatórias

$$E(\mathbf{A}\mathbf{Y}) = \mathbf{A}E(\mathbf{Y}).$$

- ▶ Esse é um estimador não viesado

$$E(\hat{\beta}) = E((\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y})) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E(\mathbf{Y}) =$$

- ▶ Portanto, a soma de quadrados dos erros é dada por

$$\epsilon' \epsilon = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta).$$

- ▶ Vimos que derivando com relação a β e igualando a zero, obtemos

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y}).$$

- ▶ Vamos usar o seguinte resultado.
- ▶ Se \mathbf{A} é uma matriz de constantes e \mathbf{Y} uma matriz de variáveis aleatórias

$$E(\mathbf{A}\mathbf{Y}) = \mathbf{A}E(\mathbf{Y}).$$

- ▶ Esse é um estimador não viesado

$$E(\hat{\beta}) = E((\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y})) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E(\mathbf{Y}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\beta$$

- ▶ Portanto, a soma de quadrados dos erros é dada por

$$\epsilon' \epsilon = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta).$$

- ▶ Vimos que derivando com relação a β e igualando a zero, obtemos

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y}).$$

- ▶ Vamos usar o seguinte resultado.
- ▶ Se \mathbf{A} é uma matriz de constantes e \mathbf{Y} uma matriz de variáveis aleatórias

$$E(\mathbf{A}\mathbf{Y}) = \mathbf{A}E(\mathbf{Y}).$$

- ▶ Esse é um estimador não viesado

$$E(\hat{\beta}) = E((\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y})) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E(\mathbf{Y}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\beta = \beta$$

pois

$$E(\mathbf{Y}) = \mathbf{X}\beta \quad (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X} = \mathbf{I}.$$

- ▶ Vimos ainda que

$$\begin{aligned} \text{Var}(\hat{\beta}) &= [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'] \text{Var}(\mathbf{Y}) [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}']' \\ &= [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'] \sigma^2 \mathbf{I}_n [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}']' \\ &= \sigma^2 [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'] [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}']' \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} . \end{aligned}$$

Tabela ANOVA

- ▶ O valor predito é dado por

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \dots + \hat{\beta}_p X_p .$$

- ▶ O resíduo (estimativa do erro) é dado por

$$e_i = \hat{Y}_i - Y_i .$$

- ▶ Vimos que as somas de quadrados podem ser escritas na forma matricial

$$SQT =$$

- ▶ O valor predito é dado por

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \cdots + \hat{\beta}_p X_p.$$

- ▶ O resíduo (estimativa do erro) é dado por

$$e_i = \hat{Y}_i - Y_i.$$

- ▶ Vimos que as somas de quadrados podem ser escritas na forma matricial

$$SQT = \sum_i (Y_i - \bar{Y})^2 = \mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$$

$$SQR =$$

- ▶ O valor predito é dado por

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \dots + \hat{\beta}_p X_p.$$

- ▶ O resíduo (estimativa do erro) é dado por

$$e_i = \hat{Y}_i - Y_i.$$

- ▶ Vimos que as somas de quadrados podem ser escritas na forma matricial

$$SQT = \sum_i (Y_i - \bar{Y})^2 = \mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$$

$$SQR = \sum_i (\hat{Y}_i - \bar{Y})^2 = \sum_i \hat{Y}_i^2 - n\bar{Y}^2 = \hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2$$

$$SQE =$$

- ▶ O valor predito é dado por

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \dots + \hat{\beta}_p X_p.$$

- ▶ O resíduo (estimativa do erro) é dado por

$$e_i = \hat{Y}_i - Y_i.$$

- ▶ Vimos que as somas de quadrados podem ser escritas na forma matricial

$$SQT = \sum_i (Y_i - \bar{Y})^2 = \mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$$

$$SQR = \sum_i (\hat{Y}_i - \bar{Y})^2 = \sum_i \hat{Y}_i^2 - n\bar{Y}^2 = \hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2$$

$$SQE = \sum_i (\hat{Y}_i - Y_i)^2 = \mathbf{Y}'\mathbf{Y} - \hat{\beta}'\mathbf{X}'\mathbf{Y}$$

- ▶ A Tabela ANOVA fica da seguinte forma

Fonte de Variação	Graus de Liberdade	Soma de Quadrados	Quadrado Médio
Regressão	p	$\hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2$	QMR=SQR/p
Resíduo	$n - p - 1$	$\mathbf{Y}'\mathbf{Y} - \hat{\beta}'\mathbf{X}'\mathbf{Y}$	QME=SQE/(n-p-1)
Total	$n - 1$	$\mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$	

Tabela: Tabela ANOVA

Coefficiente de Determinação Ajustado

- ▶ O coeficiente de determinação pode ser calculado da mesma forma como na regressão linear simples:

$$R^2 =$$

- ▶ O coeficiente de determinação pode ser calculado da mesma forma como na regressão linear simples:

$$R^2 = \frac{SQR}{SQT} = \frac{\sum_i (\hat{Y}_i - \bar{Y})^2}{\sum_i (\hat{Y}_i - Y_i)^2} = \frac{\hat{\beta}' \mathbf{X}' \mathbf{Y} - n \bar{Y}^2}{\mathbf{Y}' \mathbf{Y} - n \bar{Y}^2}.$$

- ▶ Sempre que incluirmos mais uma variável no modelo o R^2 irá aumentar.
- ▶ Exemplos:
 - ▶ se com 2 pontos ajustamos uma reta $\Rightarrow R^2 =$

- ▶ O coeficiente de determinação pode ser calculado da mesma forma como na regressão linear simples:

$$R^2 = \frac{SQR}{SQT} = \frac{\sum_i (\hat{Y}_i - \bar{Y})^2}{\sum_i (\hat{Y}_i - Y_i)^2} = \frac{\hat{\beta}' \mathbf{X}' \mathbf{Y} - n \bar{Y}^2}{\mathbf{Y}' \mathbf{Y} - n \bar{Y}^2} .$$

- ▶ Sempre que incluirmos mais uma variável no modelo o R^2 irá aumentar.
- ▶ Exemplos:
 - ▶ se com 2 pontos ajustamos uma reta $\Rightarrow R^2 = 1$;
 - ▶ se com 3 pontos ajustamos um polinômio de grau 3 $\Rightarrow R^2 =$

- ▶ O coeficiente de determinação pode ser calculado da mesma forma como na regressão linear simples:

$$R^2 = \frac{SQR}{SQT} = \frac{\sum_i (\hat{Y}_i - \bar{Y})^2}{\sum_i (\hat{Y}_i - Y_i)^2} = \frac{\hat{\beta}' \mathbf{X}' \mathbf{Y} - n \bar{Y}^2}{\mathbf{Y}' \mathbf{Y} - n \bar{Y}^2}.$$

- ▶ Sempre que incluirmos mais uma variável no modelo o R^2 irá aumentar.
- ▶ Exemplos:
 - ▶ se com 2 pontos ajustamos uma reta $\Rightarrow R^2 = 1$;
 - ▶ se com 3 pontos ajustamos um polinômio de grau 3 $\Rightarrow R^2 = 1$.
- ▶ Porém um modelo com muitas variáveis não é o mais adequado.
- ▶ O modelo deve ser parcimonioso:
 - ▶ ajustar bem aos dados e ser o mais simples possível.

- ▶ Solução: penalizar a medida de ajuste pelo número de variáveis.
- ▶ Se o modelo ajusta bem aos dados, mas tem muitas variáveis essa medida não fica muito alta.
- ▶ Essa nova medida é chamada **Coefficiente de Determinação Ajustado**.
- ▶ O coeficiente de determinação é dado por

$$R^2 = \frac{SQR}{SQT} = 1 - \frac{SQE}{SQT}.$$

- ▶ O coeficiente de determinação ajustado é dado por

$$R_{ajustado}^2 = 1 - \frac{SQE/(n-p-1)}{SQT/(n-1)} =$$

- ▶ Solução: penalizar a medida de ajuste pelo número de variáveis.
- ▶ Se o modelo ajusta bem aos dados, mas tem muitas variáveis essa medida não fica muito alta.
- ▶ Essa nova medida é chamada **Coefficiente de Determinação Ajustado**.
- ▶ O coeficiente de determinação é dado por

$$R^2 = \frac{SQR}{SQT} = 1 - \frac{SQE}{SQT}.$$

- ▶ O coeficiente de determinação ajustado é dado por

$$\begin{aligned} R^2_{ajustado} &= 1 - \frac{SQE/(n-p-1)}{SQT/(n-1)} = 1 - \left(\frac{n-1}{n-p-1} \right) \left(\frac{SQE}{SQT} \right) \\ &= 1 - (1 - R^2) \left(\frac{n-1}{n-p-1} \right). \end{aligned}$$

Teste F da significância da Regressão

- ▶ Queremos testar as seguintes hipóteses:

$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$, ou seja, nenhum dos β_j é significativo

$H_1 : \beta_j \neq 0$ para pelo menos um $j \geq 1$, ou seja, β_j é significativo

- ▶ A estatística de teste é dada por

$$F = \frac{QMR}{QME} \sim F_{p, n-p-1} \text{ sob } H_0$$

Observação: não estamos testando o intercepto, queremos verificar quais variáveis são significativas.

- ▶ A hipótese nula dever ser rejeitada para valores altos ou baixos de F ?

- ▶ A hipótese nula dever ser rejeitada para valores altos ou baixos de F ? Altos.
- ▶ Se F é grande, SQR é grande e SQE é pequena, ou seja, o modelo explica bem os dados.
- ▶ Esse é um teste **unilateral**.
- ▶ Para um nível de significância α , a região crítica é dada por

$$F > F_{\alpha}$$

onde α é tal que $P(F_{p,n-p-1} > F_{\alpha}) = \alpha$.

- ▶ Se não rejeitamos H_0 :
 - ▶ nenhum dos termos $\beta_j X_j$ é significativo;
 - ▶ nenhuma variável preditora é significativa para explicar a resposta.
- ▶ Se rejeitamos H_0 :
 - ▶ pelo menos um dos termos $\beta_j X_j$ é significativo;
 - ▶ podemos verificar quais são significativos;
 - ▶ isso é feito através de testes t individuais.

Testes t individuais

- ▶ Para $j = 1, 2, \dots, q$, podemos testar a significância do coeficiente β_j na presença dos demais coeficientes no modelo:

$H_0 : \beta_j = 0$ na presença dos demais coeficientes ;

$H_1 : \beta_j \neq 0$ na presença dos demais coeficientes.

- ▶ A estatística de teste é dada por

$$t_j = \frac{\hat{\beta}_j}{\sqrt{\text{Var}(\hat{\beta}_j)}} \sim t_{n-p-1} \text{ sob } H_0 .$$

- ▶ A quantidade $\sqrt{\text{Var}(\hat{\beta}_j)}$ pode ser obtida a partir da matriz de variâncias e covariâncias estimada de $\hat{\beta}$.
- ▶ Essa matriz é dada por

$$\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1} .$$

- ▶ Não sabemos o valor de σ^2 .
- ▶ Estimamos esse parâmetro usando

- ▶ A quantidade $\sqrt{\text{Var}(\hat{\beta}_j)}$ pode ser obtida a partir da matriz de variâncias e covariâncias estimada de $\hat{\beta}$.
- ▶ Essa matriz é dada por

$$\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1} .$$

- ▶ Não sabemos o valor de σ^2 .
- ▶ Estimamos esse parâmetro usando S^2 .
- ▶ A matriz de variâncias estimada fica da seguinte maneira

- ▶ A quantidade $\sqrt{\text{Var}(\hat{\beta}_j)}$ pode ser obtida a partir da matriz de variâncias e covariâncias estimada de $\hat{\beta}$.
- ▶ Essa matriz é dada por

$$\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1} .$$

- ▶ Não sabemos o valor de σ^2 .
- ▶ Estimamos esse parâmetro usando S^2 .
- ▶ A matriz de variâncias estimada fica da seguinte maneira

$$\hat{\text{Var}}(\hat{\beta}) = S^2(\mathbf{X}'\mathbf{X})^{-1} .$$

- ▶ O j -ésimo elemento da diagonal nos fornece o valor de $\text{Var}(\hat{\beta}_j)$.

- ▶ Rejeitamos H_0 para valores altos ou baixos de t .
- ▶ Se $\hat{\beta}_j$ está muito distante de 0, H_0 deve ser rejeitada.
- ▶ O teste é **bilateral**.
- ▶ A região crítica do teste é dada por

- ▶ Rejeitamos H_0 para valores altos ou baixos de t .
- ▶ Se $\hat{\beta}_j$ está muito distante de 0, H_0 deve ser rejeitada.
- ▶ O teste é **bilateral**.
- ▶ A região crítica do teste é dada por

$$t > t_{\alpha/2} \text{ ou } t < -t_{\alpha/2}$$

onde $t_{\alpha/2}$ é tal que $P(t_{n-p-1} > t_{\alpha/2}) = \alpha/2$.

Exemplo:

- ▶ Um estudo realizado na Flórida analisa a ocorrência de doenças mentais.
- ▶ A variável de interesse é deficiência mental.
- ▶ Essa doença apresenta vários sintomas psiquiátricos, como:
 - ▶ ansiedade e depressão.
- ▶ A variável resposta é um score.
- ▶ Valores altos dessa variável indicam altos níveis de deficiência mental.

Exemplo: (continuação)



- ▶ Duas variáveis resposta são analisadas:
 - ▶ X_1 = eventos marcantes;
 - ▶ X_2 = status sócio-econômico (SES).
- ▶ A variável X_1 mede:
 - ▶ o número e a severidade de eventos marcantes na vida do indivíduo nos últimos três anos.
- ▶ Esses eventos podem ser muito severos, como uma morte na família, ou uma condenação criminal.
- ▶ Poucos severos, como a mudança para um novo trabalho, uma nova cidade.
- ▶ Um score alto para X_1 indica um número alto de eventos e eventos muito severos.

Exemplo: (continuação)

- ▶ A variável X_2 é um índice baseado em:
 - ▶ ocupação, salário e educação.
- ▶ Ela é medida em uma escala padronizada e varia de 0 a 100.
- ▶ Quanto maior o valores de X_2 , maior o status sócio-econômico.
- ▶ Um conjunto de 40 adultos foram entrevistados.

Exemplo: (continuação)

- ▶ Gráficos de dispersão de Y em função de X_1 e X_2 .



► Conclusão:

- ▶ Conclusão:
- ▶ As duas variáveis parecem ter relação linear com Y .

- ▶ Conclusão:
- ▶ As duas variáveis parecem ter relação linear com Y .
- ▶ A relação com X_1 é positiva.

- ▶ Conclusão:
- ▶ As duas variáveis parecem ter relação linear com Y .
- ▶ A relação com X_1 é positiva.
- ▶ A relação com X_2 é negativa.

Exemplo: (continuação)

- ▶ Vamos primeiro ajustar modelos de regressão linear simples.
- ▶ Y em função de X_1 apenas.
- ▶ Primeiro modelo ajustado:

$$Y = \beta_0 + \beta_1 X_1 + \epsilon_j \quad \epsilon_j \sim^{iid} N(0, \sigma^2)$$

Call:

```
lm(formula = Y ~ X1)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	23.30949	1.80675	12.901	1.85e-15	***
X1	0.08983	0.03633	2.472	0.018	*

Residual standard error: 5.133 on 38 degrees of freedom
Multiple R-squared: 0.1385, Adjusted R-squared: 0.1159
F-statistic: 6.112 on 1 and 38 DF, p-value: 0.01802

Exemplo: (continuação)

- ▶ Conclusões:

Exemplo: (continuação)

- ▶ Conclusões:
- ▶ X_1 é significativa para explicar Y .

Exemplo: (continuação)

- ▶ Conclusões:
- ▶ X_1 é significativa para explicar Y .
- ▶ A relação entre Y e X_1 é positiva.
- ▶ Quanto maior o score de eventos marcantes, maior a deficiência mental.

Exemplo: (continuação)

- ▶ Conclusões:
- ▶ X_1 é significativa para explicar Y .
- ▶ A relação entre Y e X_1 é positiva.
- ▶ Quanto maior o score de eventos marcantes, maior a deficiência mental.
- ▶ O modelo não explica bem a variabilidade dos dados ($R^2 = 0.1385$).
- ▶ Devemos incluir mais variáveis explicativas.

Exemplo: (continuação)

- ▶ Y em função de X_2 apenas.
- ▶ Segundo modelo ajustado:

$$Y = \beta_0 + \beta_1 X_2 + \epsilon_j \quad \epsilon_j \sim^{iid} N(0, \sigma^2)$$

Call:

```
lm(formula = Y ~ X2)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	32.17201	1.98765	16.186	<2e-16	***
X2	-0.08608	0.03213	-2.679	0.0109	*

Residual standard error: 5.072 on 38 degrees of freedom

Multiple R-squared: 0.1589, Adjusted R-squared: 0.1367

F-statistic: 7.177 on 1 and 38 DF, p-value: 0.01085

Exemplo: (continuação)

- ▶ Conclusões:

Exemplo: (continuação)

- ▶ Conclusões:
- ▶ X_2 é significativa para explicar Y .

Exemplo: (continuação)

- ▶ Conclusões:
- ▶ X_2 é significativa para explicar Y .
- ▶ A relação entre Y e X_2 é negativa.
- ▶ Quanto menor o status sócio-econômico, maior a deficiência mental.

Exemplo: (continuação)

- ▶ Conclusões:
- ▶ X_2 é significativa para explicar Y .
- ▶ A relação entre Y e X_2 é negativa.
- ▶ Quanto menor o status sócio-econômico, maior a deficiência mental.
- ▶ O modelo não explica bem a variabilidade dos dados ($R^2 = 0.1589$).
- ▶ Devemos incluir mais variáveis explicativas.

Exemplo: (continuação)

- ▶ Vamos ajustar agora o modelo com as duas variáveis.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon_j \quad \epsilon_j \sim^{iid} N(0, \sigma^2).$$

- ▶ Vamos realizar primeiramente o teste F .
- ▶ Queremos testar as seguintes hipóteses:

Exemplo: (continuação)

- ▶ Vamos ajustar agora o modelo com as duas variáveis.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon_j \quad \epsilon_j \sim^{iid} N(0, \sigma^2).$$

- ▶ Vamos realizar primeiramente o teste F .
- ▶ Queremos testar as seguintes hipóteses:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0, \text{ ou seja, nenhum dos } \beta_j \text{ é significativo}$$

$$H_1 : \beta_j \neq 0 \text{ para pelo menos um } j \geq 1, \text{ ou seja, } \beta_j \text{ é significativo}$$

- ▶ A estatística de teste é dada por

$$F = \frac{QMR}{QME} \sim F_{p, n-p-1} \text{ sob } H_0.$$

Exemplo: (continuação)

- ▶ Vimos que

$$SQR = \hat{\beta}' \mathbf{X}' \mathbf{Y} - n \bar{Y}^2 = 394.2384$$

logo

$$QMR = \frac{SQR}{p} = \frac{394.2384}{2} = 197.1192$$

- ▶ Além disso

$$SQE = \mathbf{Y}' \mathbf{Y} - \hat{\beta}' \mathbf{X}' \mathbf{Y} = 768.1616$$

e

$$QME = \frac{SME}{n - p - 1} = \frac{768.1616}{37} = 20.76112.$$

Exemplo: (continuação)

- ▶ A tabela ANOVA fica da seguinte forma:

Fonte de Variação	Graus de Liberdade	Soma de Quadrados	Quadrado Médio
Regressão	$p = 2$	$SQR = 394.2384$	$QMR = 394.2384/2$
Resíduo	$n - p - 1 = 37$	$SQE = 768.1616$	$QME = 768.1616/(37)$
Total	$n - 1 = 39$	$SQT = 1162.4$	

Tabela: Tabela ANOVA

Exemplo: (continuação)

- ▶ A estatística F é dada por

$$F = \frac{QMR}{QME} = \frac{197.1192}{20.76112} = 9.494632 .$$

- ▶ Sob H_0 temos que

$$F \sim F_{2,37}$$

- ▶ Fixando $\alpha = 0.05$ temos que $F_{2,37;0.05} \approx F_{2,37;0.05} = 3.232$.
- ▶ A região crítica é dada por

$$F > 3.232 .$$

- ▶ Qual a conclusão?

Exemplo: (continuação)

- ▶ A estatística F é dada por

$$F = \frac{QMR}{QME} = \frac{197.1192}{20.76112} = 9.494632 .$$

- ▶ Sob H_0 temos que

$$F \sim F_{2,37}$$

- ▶ Fixando $\alpha = 0.05$ temos que $F_{2,37;0.05} \approx F_{2,37;0.05} = 3.232$.
- ▶ A região crítica é dada por

$$F > 3.232 .$$

- ▶ Qual a conclusão? Como $F_{obs} = 9.4946 > 3.232$, rejeitamos H_0 .
- ▶ O que isso significa?

Exemplo: (continuação)

- ▶ A estatística F é dada por

$$F = \frac{QMR}{QME} = \frac{197.1192}{20.76112} = 9.494632 .$$

- ▶ Sob H_0 temos que

$$F \sim F_{2,37}$$

- ▶ Fixando $\alpha = 0.05$ temos que $F_{2,37;0.05} \approx F_{2,37;0.05} = 3.232$.
- ▶ A região crítica é dada por

$$F > 3.232 .$$

- ▶ Qual a conclusão? Como $F_{obs} = 9.4946 > 3.232$, rejeitamos H_0 .
- ▶ O que isso significa? Com 5% de significância, podemos dizer que pelo uma das variáveis (X_1 ou X_2) é significativa para explicar Y .

Exemplo: (continuação)

- ▶ Vamos agora fazer os testes t individuais.
- ▶ Para $j = 1, 2$, queremos testar

$H_0 : \beta_j = 0$ na presença dos demais coeficientes ;

$H_1 : \beta_j \neq 0$ na presença dos demais coeficientes.

- ▶ A estatística de teste é dada por

$$t_j = \frac{\hat{\beta}_j}{\sqrt{\text{Var}(\hat{\beta}_j)}} \sim t_{n-p-1} \text{ sob } H_0 .$$

Exemplo: (continuação)

- ▶ Precisamos encontrar a variância estimada $\hat{\beta}_1$ e $\hat{\beta}_2$.
- ▶ Essa variância é obtida através da matriz

$$\text{Var}(\hat{\beta}) = s^2(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 4.72721373 & -0.0403235231 & -0.0426999331 \\ -0.04032352 & 0.0010562090 & -0.0001165824 \\ -0.04269993 & -0.0001165824 & 0.0008459206 \end{bmatrix}$$

- ▶ Temos então que

$$\text{Var}(\hat{\beta}_0) =$$

Exemplo: (continuação)

- ▶ Precisamos encontrar a variância estimada $\hat{\beta}_1$ e $\hat{\beta}_2$.
- ▶ Essa variância é obtida através da matriz

$$\text{Var}(\hat{\beta}) = s^2(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 4.72721373 & -0.0403235231 & -0.0426999331 \\ -0.04032352 & 0.0010562090 & -0.0001165824 \\ -0.04269993 & -0.0001165824 & 0.0008459206 \end{bmatrix}$$

- ▶ Temos então que

$$\text{Var}(\hat{\beta}_0) = 4.7272 \quad \text{Var}(\hat{\beta}_1) =$$

Exemplo: (continuação)

- ▶ Precisamos encontrar a variância estimada $\hat{\beta}_1$ e $\hat{\beta}_2$.
- ▶ Essa variância é obtida através da matriz

$$\text{Var}(\hat{\beta}) = s^2(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 4.72721373 & -0.0403235231 & -0.0426999331 \\ -0.04032352 & 0.0010562090 & -0.0001165824 \\ -0.04269993 & -0.0001165824 & 0.0008459206 \end{bmatrix}$$

- ▶ Temos então que

$$\text{Var}(\hat{\beta}_0) = 4.7272 \quad \text{Var}(\hat{\beta}_1) = 0.0011 \quad \text{Var}(\hat{\beta}_2) = 0.0008$$

Exemplo: (continuação)

- ▶ Vamos considerar primeiro a variável X_1 .
- ▶ Queremos testar

Exemplo: (continuação)

- ▶ Vamos considerar primeiro a variável X_1 .
- ▶ Queremos testar

$$H_0 : \beta_1 = 0 \quad H_1 : \beta_1 \neq 0 .$$

- ▶ A estatística de teste é dada por

$$t_{obs}^{(1)} = \frac{\hat{\beta}_1}{\sqrt{\text{Var}(\hat{\beta}_1)}} = \frac{0.10326}{\sqrt{0.0011}} = 3.177$$

sob H_0 temos que

$$t_{obs}^{(1)} \sim t_{37} \text{ sob } H_0 .$$

- ▶ Fixando $\alpha = 0.05$ temos que $t_{37;0.025} \approx t_{40;0.025} = 2.021$.

Exemplo: (continuação)

- ▶ A região crítica é dada por

Exemplo: (continuação)

- ▶ A região crítica é dada por

$$t_{obs}^{(1)} > 2.021 \quad \text{ou} \quad t_{obs}^{(1)} < -2.021 .$$

- ▶ Rejeitamos ou não H_0 ?

Exemplo: (continuação)

- ▶ A região crítica é dada por

$$t_{obs}^{(1)} > 2.021 \quad \text{ou} \quad t_{obs}^{(1)} < -2.021 .$$

- ▶ Rejeitamos ou não H_0 ? Rejeitamos, pois $t_{obs}^{(1)} = 3.177 > 2.021$.
- ▶ Conclusão:

Exemplo: (continuação)

- ▶ A região crítica é dada por

$$t_{obs}^{(1)} > 2.021 \quad \text{ou} \quad t_{obs}^{(1)} < -2.021 .$$

- ▶ Rejeitamos ou não H_0 ? Rejeitamos, pois $t_{obs}^{(1)} = 3.177 > 2.021$.
- ▶ Conclusão: Com 5% de significância, há evidências de que X_1 é significativa para explicar Y .

Exemplo: (continuação)

- ▶ Vamos considerar primeiro a variável X_2 .
- ▶ Queremos testar

Exemplo: (continuação)

- ▶ Vamos considerar primeiro a variável X_2 .
- ▶ Queremos testar

$$H_0 : \beta_2 = 0 \quad H_1 : \beta_2 \neq 0 .$$

- ▶ A estatística de teste é dada por

$$t_{obs}^{(2)} = \frac{\hat{\beta}_2}{\sqrt{\text{Var}(\hat{\beta}_2)}} = \frac{-0.09748}{\sqrt{0.0008}} = -3.351$$

sob H_0 temos que

$$t_{obs}^{(2)} \sim t_{37} \text{ sob } H_0 .$$

- ▶ Fixando $\alpha = 0.05$ temos que $t_{37;0.025} \approx t_{40;0.025} = 2.021$.

Exemplo: (continuação)

- ▶ A região crítica é dada por

Exemplo: (continuação)

- ▶ A região crítica é dada por

$$t_{obs}^{(1)} > 2.021 \quad \text{ou} \quad t_{obs}^{(1)} < -2.021 .$$

- ▶ Rejeitamos ou não H_0 ?

Exemplo: (continuação)

- ▶ A região crítica é dada por

$$t_{obs}^{(1)} > 2.021 \quad \text{ou} \quad t_{obs}^{(1)} < -2.021 .$$

- ▶ Rejeitamos ou não H_0 ? Rejeitamos, pois $t_{obs}^{(1)} = -3.351 < -2.021$.
- ▶ Conclusão:

Exemplo: (continuação)

- ▶ A região crítica é dada por

$$t_{obs}^{(1)} > 2.021 \quad \text{ou} \quad t_{obs}^{(1)} < -2.021 .$$

- ▶ Rejeitamos ou não H_0 ? Rejeitamos, pois $t_{obs}^{(1)} = -3.351 < -2.021$.
- ▶ Conclusão: Com 5% de significância, há evidências de que X_2 é significativa para explicar Y

Exemplo: (continuação)

- ▶ Vamos agora encontrar o Coeficiente de Determinação ajustado.
- ▶ O Coeficiente de Determinação é dado por

$$R^2 = \frac{SQR}{SQT} = \frac{394.2384}{1162.4} = 0.3392.$$

- ▶ O coeficiente de determinação ajustado é dado por

$$\begin{aligned} R_{ajustado}^2 &= 1 - (1 - R^2) \left(\frac{n - 1}{n - p - 1} \right) \\ &= 1 - (1 - 0.3392) \left(\frac{40 - 1}{40 - 2 - 1} \right) = 0.3034. \end{aligned}$$

- ▶ Interpretação:

Exemplo: (continuação)

- ▶ Vamos agora encontrar o Coeficiente de Determinação ajustado.
- ▶ O Coeficiente de Determinação é dado por

$$R^2 = \frac{SQR}{SQT} = \frac{394.2384}{1162.4} = 0.3392.$$

- ▶ O coeficiente de determinação ajustado é dado por

$$\begin{aligned} R_{ajustado}^2 &= 1 - (1 - R^2) \left(\frac{n - 1}{n - p - 1} \right) \\ &= 1 - (1 - 0.3392) \left(\frac{40 - 1}{40 - 2 - 1} \right) = 0.3034. \end{aligned}$$

- ▶ Interpretação: 30.34% da variabilidade dos dados pode ser explicada pelo modelo de regressão.
- ▶ Esse modelo não explica bem os dados.
- ▶ Talvez devemos incluir mais variáveis.

Exemplo: (continuação)

- ▶ O saída do R nos fornece todos os resultado obtidos até aqui:

Call:

```
lm(formula = Y ~ X1 + X2)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	28.22981	2.17422	12.984	2.38e-15	***
X1	0.10326	0.03250	3.177	0.00300	**
X2	-0.09748	0.02908	-3.351	0.00186	**

Residual standard error: 4.556 on 37 degrees of freedom

Multiple R-squared: 0.3392, Adjusted R-squared: 0.3034

F-statistic: 9.495 on 2 and 37 DF, p-value: 0.0004697

Exemplo: (continuação)

Analysis of Variance Table

Response: Y

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
X1	1	161.05	161.048	7.7572	0.008385	**
X2	1	233.19	233.190	11.2320	0.001863	**
Residuals	37	768.16	20.761			
