

Variável Binária e Interação

Gilberto A. Paula

Departamento de Estatística
IME-USP, Brasil
giapaula@ime.usp.br

1^o Semestre 2023

- 1 Introdução
- 2 Variável Explicativa Binária
- 3 Variável Explicativa Categórica
- 4 Referências

Objetivos

Neste material serão apresentados os seguintes conceitos:

- Variável Explicativa Binária
- Ausência e Presença de Interação
- Variável Explicativa Categórica
- Ausência e Presença de Interação

1 Introdução

2 Variável Explicativa Binária

3 Variável Explicativa Categórica

4 Referências

Ausência de Interação

Supor o seguinte modelo de regressão linear múltipla:

$$y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + \epsilon_i,$$

em que y_1, \dots, y_n são valores observados da variável resposta, x_{i2} representa os valores de uma variável aleatória binária tal que

$$x_{i2} = \begin{cases} 1 & \text{grupo A} \\ 0 & \text{grupo B,} \end{cases}$$

enquanto x_{i3} representa valores observados de uma variável contínua e $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$, para $i = 1, \dots, n$.

Ausência de Interação

Portanto, tem-se dois submodelos de regressão

- (Grupo A) $y_i = \beta_1 + \beta_2 + \beta_3 x_{i3} + \epsilon_i$
- (Grupo B) $y_i = \beta_1 + \beta_3 x_{i3} + \epsilon_i$

com valores esperados

- $E_A(Y_i | x_{i3}) = \beta_1 + \beta_2 + \beta_3 x_{i3}$
- $E_B(Y_i | x_{i3}) = \beta_1 + \beta_3 x_{i3},$

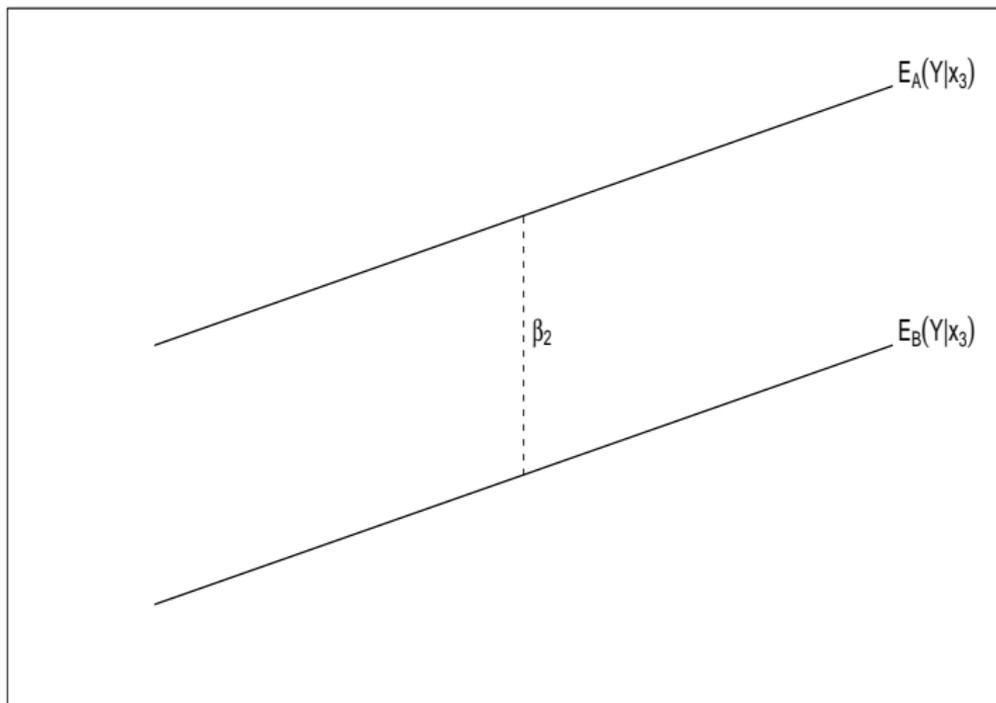
para $i = 1, \dots, n.$

Assim, $E_A(Y_i | x_{i3}) - E_B(Y_i | x_{i3}) = \beta_2$, ausência de interação entre as variáveis explicativas X_2 e X_3 .

Definição

A diferença entre os valores esperados entre dois níveis (valores) quaisquer de um fator (variável) **não muda** à medida que variam os níveis do outro fator (outra variável). Neste modelo tem-se que β_2 **não muda à medida que variam os valores de X_3** .

Ilustração Ausência de Interação



Ausência de Interação

Supondo que o grupo A tem n_1 elementos e o grupo B n_2 elementos o modelo com ausência de interação entre a variável binária X_2 e a variável contínua X_3 pode ser expresso na forma alternativa:

$$y_{ij} = \beta_1 + \beta_2 X_{i2} + \beta_3 X_{ij3} + \epsilon_{ij},$$

em que $j = 1, \dots, n_j$ e $i = 1, 2$.

Ausência de Interação

Em forma matricial o modelo fica dado por

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon},$$

em que $\mathbf{y} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top)^\top$ com $\mathbf{y}_1 = (y_{11}, \dots, y_{1n_1})^\top$, $\mathbf{y}_2 = (y_{21}, \dots, y_{2n_2})^\top$, $\boldsymbol{\beta} = (\beta_1, \beta_2, \beta_3)^\top$ e matriz \mathbf{X} de dimensão $(n_1 + n_2) \times 3$ dada por

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & x_{113} \\ \vdots & \vdots & \vdots \\ 1 & 1 & x_{1n_13} \\ 1 & 0 & x_{213} \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_{2n_23} \end{bmatrix}.$$

Presença de Interação

Supor agora o seguinte modelo de regressão linear múltipla:

$$y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i2} x_{i3} + \epsilon_i,$$

em que y_1, \dots, y_n são valores observados da variável resposta, x_{i2} representa os valores de uma variável aleatória binária tal que

$$x_{i2} = \begin{cases} 1 & \text{grupo A} \\ 0 & \text{grupo B,} \end{cases}$$

enquanto x_{i3} representa valores observados de uma variável contínua e $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$, para $i = 1, \dots, n$.

Presença de Interação

Portanto, tem-se dois submodelos de regressão

- (Grupo A) $y_i = \beta_1 + \beta_2 + \beta_3 X_{i3} + \beta_4 X_{i3} + \epsilon_i$
- (Grupo B) $y_i = \beta_1 + \beta_3 X_{i3} + \epsilon_i$

com valores esperados

- $E_A(Y_i|X_{i3}) = \beta_1 + \beta_2 + \beta_3 X_{i3} + \beta_4 X_{i3}$
- $E_B(Y_i|X_{i3}) = \beta_1 + \beta_3 X_{i3},$

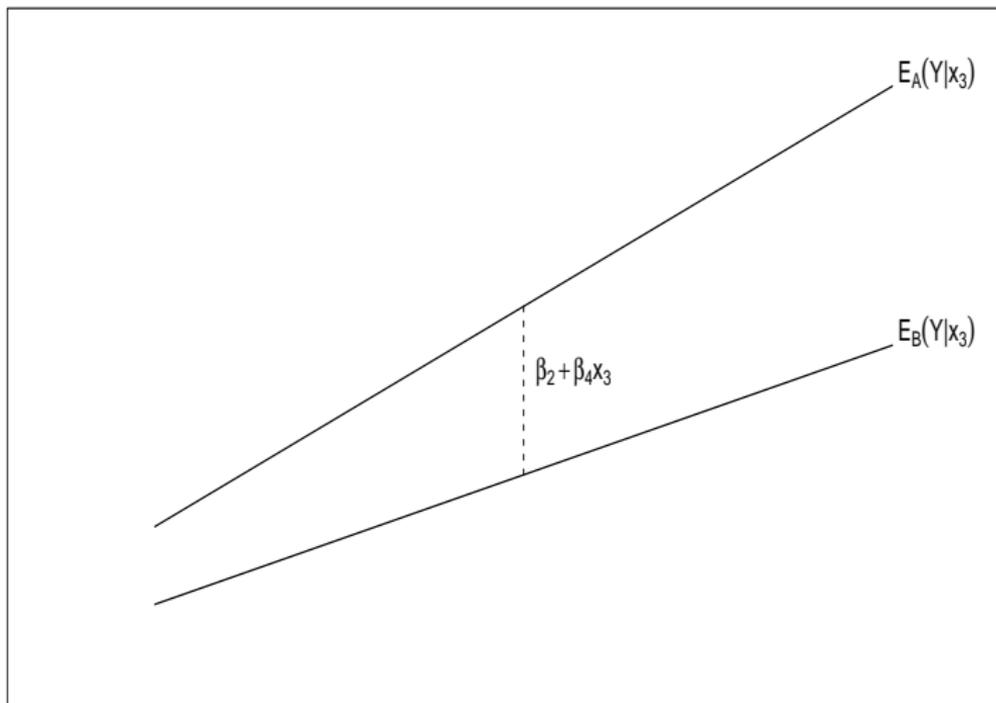
para $i = 1, \dots, n.$

Assim, $E_A(Y_i|X_{i3}) - E_B(Y_i|X_{i3}) = \beta_2 + \beta_4 X_{i3}$, presença de interação entre as variáveis explicativas X_2 e X_3 .

Definição

A diferença entre os valores esperados entre dois níveis (valores) quaisquer de um fator (variável) **não é constante** à medida que variam os níveis do outro fator (outra variável). Neste modelo tem-se que **a diferença entre os valores esperados para os grupos A e B depende dos valores da variável X_3 .**

Ilustração Presença de Interação



Presença de Interação

Supondo que o grupo A tem n_1 elementos e o grupo B n_2 elementos o modelo com presença de interação entre a variável binária X_2 e a variável contínua X_3 pode ser expresso na forma alternativa:

$$y_{ij} = \beta_1 + \beta_2 X_{i2} + \beta_3 X_{ij3} + \beta_4 X_{i2} X_{ij3} + \epsilon_{ij},$$

em que $j = 1, \dots, n_j$ e $i = 1, 2$.

Presença de Interação

Em forma matricial o modelo fica dado por

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon},$$

em que $\mathbf{y} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top)^\top$ com $\mathbf{y}_1 = (y_{11}, \dots, y_{1n_1})^\top$, $\mathbf{y}_2 = (y_{21}, \dots, y_{2n_2})^\top$, $\boldsymbol{\beta} = (\beta_1, \beta_2, \beta_3, \beta_4)^\top$ e matriz \mathbf{X} de dimensão $(n_1 + n_2) \times 4$ dada por

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & x_{113} & x_{113} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & x_{1n_13} & x_{1n_13} \\ 1 & 0 & x_{213} & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_{2n_23} & 0 \end{bmatrix}.$$

- 1 Introdução
- 2 Variável Explicativa Binária
- 3 Variável Explicativa Categórica**
- 4 Referências

Formulação do Modelo

Supor variável explicativa com três níveis

$$X = \begin{cases} 1 & \text{grupo A} \\ 2 & \text{grupo B} \\ 3 & \text{grupo C.} \end{cases}$$

Um maneira de representar essa variável explicativa num modelo de regressão é atribuindo a cada grupo uma variável binária:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \epsilon_i,$$

em que y_1, \dots, y_n denotam os valores observados da variável resposta, x_{i1} , x_{i2} e x_{i3} são os valores observados das variáveis binárias representando os grupos e $\epsilon_j \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$, para $j = 1, \dots, n$.

Formulação do Modelo

Supondo que os grupos A, B e C têm n_1 , n_2 e n_3 elementos, respectivamente, o modelo pode ser expresso na forma matricial

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon},$$

em que $\mathbf{y} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top, \mathbf{y}_3^\top)^\top$ com $\mathbf{y}_i = (y_{i1}, \dots, y_{in_i})^\top$, para $i = 1, 2, 3$, $\boldsymbol{\beta} = (\beta_0, \beta_1, \beta_2, \beta_3)^\top$ e matriz \mathbf{X} de dimensão $(n_1 + n_2 + n_3) \times 4$.

Formulação do Modelo

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 1 \end{bmatrix} .$$

Note que a matriz \mathbf{X} **não tem posto coluna completo**, a 1ª coluna é a soma das outras três colunas.

Formulação do Modelo

Uma solução é reduzir o número de colunas da matriz modelo impondo alguma restrição nos parâmetros. Procedimentos mais utilizados:

- Restrição nos Parâmetros: $\beta_1 + \beta_2 + \beta_3 = 0$, que implica em $\beta_1 = -\beta_2 - \beta_3$.
- Casela de Referência: um dos coeficientes é fixado como sendo zero. Por exemplo, fazendo $\beta_1 = 0$ o grupo A será denominado casela de referência.

Nesses dois casos $\beta = (\beta_0, \beta_2, \beta_3)^T$ e a matriz modelo terá dimensão $n \times 3$ com posto coluna completo.

Formulação do Modelo

Matriz modelo quando $\beta_1 = -\beta_2 - \beta_3$:

$$\mathbf{X} = \begin{bmatrix} 1 & -1 & -1 \\ \vdots & \vdots & \vdots \\ 1 & -1 & -1 \\ 1 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 1 & 1 & 0 \\ 1 & 0 & 1 \\ \vdots & \vdots & \vdots \\ 1 & 0 & 1 \end{bmatrix} .$$

Formulação do Modelo

Matriz modelo quando $\beta_1 = 0$:

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 \\ \vdots & \vdots & \vdots \\ 1 & 0 & 0 \\ 1 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 1 & 1 & 0 \\ 1 & 0 & 1 \\ \vdots & \vdots & \vdots \\ 1 & 0 & 1 \end{bmatrix} .$$

Ausência de Interação

O modelo com casela de referência **no grupo A** pode ser expresso na seguinte forma:

$$y_i = \beta_0 + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \epsilon_i,$$

em que y_1, \dots, y_n denotam os valores observados da variável resposta, x_{i2} e x_{i3} são valores de variáveis binárias representando os grupos B e C, respectivamente, enquanto x_{i4} representa os valores observados de uma variável contínua e $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$, para $i = 1, \dots, n$.

Ausência de Interação

Portanto, tem-se três submodelos

- (Grupo A) $y_i = \beta_0 + \beta_4 x_{i4} + \epsilon_i$
- (Grupo B) $y_i = \beta_0 + \beta_2 + \beta_4 x_{i4} + \epsilon_i$
- (Grupo C) $y_i = \beta_0 + \beta_3 + \beta_4 x_{i4} + \epsilon_i$

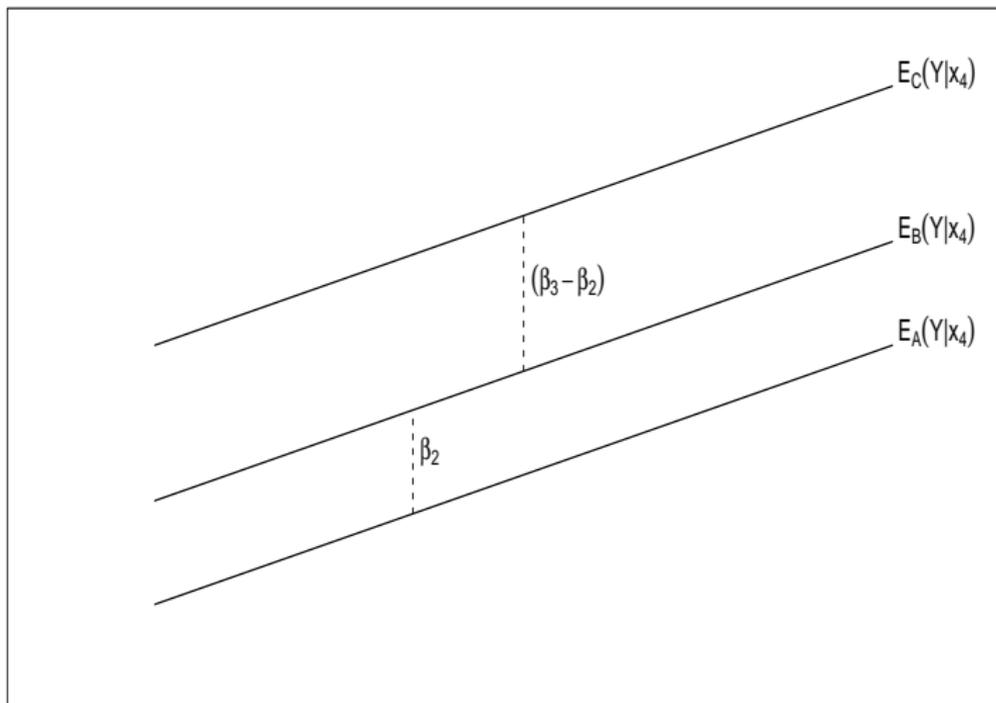
com diferenças de valores esperados

- $E_B(Y_i|x_{i4}) - E_A(Y_i|x_{i4}) = \beta_2$
- $E_C(Y_i|x_{i4}) - E_A(Y_i|x_{i4}) = \beta_3,$

para $i = 1, \dots, n$.

Assim, os efeitos β_2 e β_3 são incrementos nos valores esperados dos grupos B e C, respectivamente, com relação ao grupo A.

Ilustração Ausência de Interação



Ausência de Interação

Em forma matricial o modelo com ausência de interação fica dado por $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$, em que $\mathbf{y} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top, \mathbf{y}_3^\top)^\top$ com $\mathbf{y}_i = (y_{i1}, \dots, y_{in_i})^\top$, para $i = 1, 2, 3$, $\boldsymbol{\beta} = (\beta_0, \beta_2, \beta_3, \beta_4)^\top$ e matriz \mathbf{X} dada por

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & x_{114} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & x_{1n_14} \\ 1 & 1 & 0 & x_{214} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 0 & x_{2n_24} \\ 1 & 0 & 1 & x_{314} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 1 & x_{3n_34} \end{bmatrix} .$$

Presença de Interação

O modelo com interação entre a variável categórica X e a variável contínua X_4 pode ser expresso na seguinte forma:

$$y_i = \beta_0 + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \beta_5 x_{i2} x_{i4} + \beta_6 x_{i3} x_{i4} + \epsilon_i,$$

em que y_1, \dots, y_n denotam os valores observados da variável resposta, x_{i2} e x_{i3} são valores de variáveis binárias representando os grupos B e C, respectivamente, enquanto x_{i4} representa os valores observados de uma variável contínua e $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$, para $i = 1, \dots, n$.

Presença de Interação

Portanto, tem-se três submodelos

- (Grupo A) $y_i = \beta_0 + \beta_4 x_{i4} + \epsilon_i$
- (Grupo B) $y_i = \beta_0 + \beta_2 + \beta_4 x_{i4} + \beta_5 x_{i4} + \epsilon_i$
- (Grupo C) $y_i = \beta_0 + \beta_3 + \beta_4 x_{i4} + \beta_6 x_{i4} + \epsilon_i$

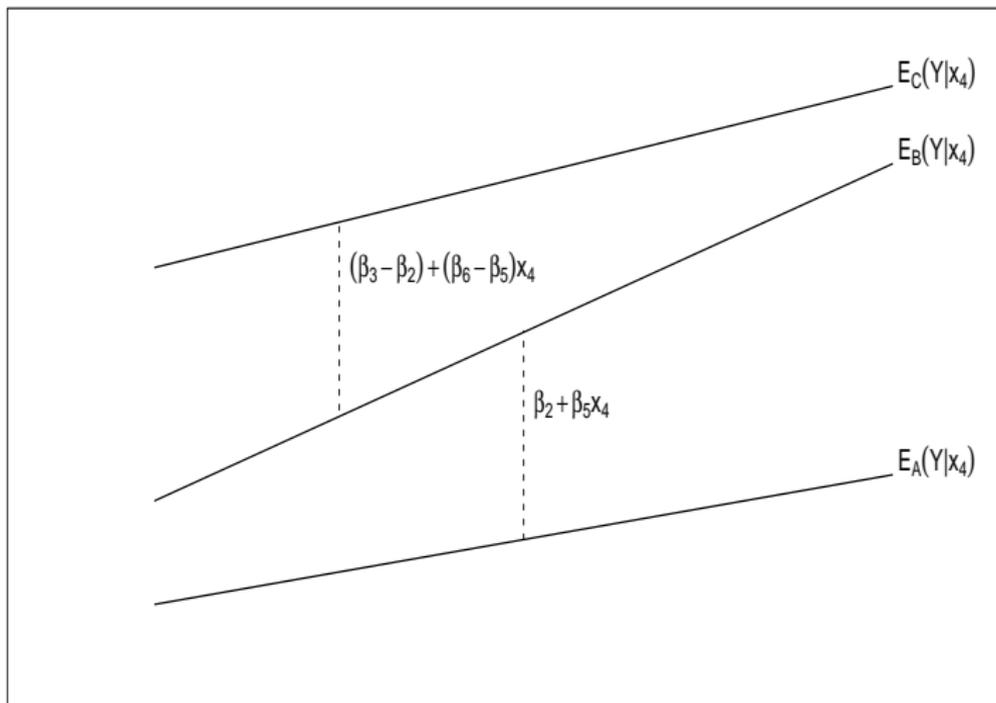
com diferenças de valores esperados

- $E_B(Y_i|x_{i4}) - E_A(Y_i|x_{i4}) = \beta_2 + \beta_5 x_{i4}$
- $E_C(Y_i|x_{i4}) - E_A(Y_i|x_{i4}) = \beta_3 + \beta_6 x_{i4},$

para $i = 1, \dots, n.$

Assim, nota-se que as diferenças entre os valores esperados dependem dos valores da variável explicativa X_4 .

Ilustração Presença de Interação



Presença de Interação

Em forma matricial o modelo com presença de interação fica dado por $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$, em que $\mathbf{y} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top, \mathbf{y}_3^\top)^\top$ com $\mathbf{y}_i = (y_{i1}, \dots, y_{in_i})^\top$, para $i = 1, 2, 3$, $\boldsymbol{\beta} = (\beta_0, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6)^\top$ e matriz \mathbf{X} dada por

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & x_{114} & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & x_{1n_14} & 0 & 0 \\ 1 & 1 & 0 & x_{214} & x_{214} & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 0 & x_{2n_24} & x_{2n_24} & 0 \\ 1 & 0 & 1 & x_{314} & 0 & x_{314} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 1 & x_{3n_34} & 0 & x_{3n_34} \end{bmatrix}.$$

- 1 Introdução
- 2 Variável Explicativa Binária
- 3 Variável Explicativa Categórica
- 4 Referências**

Referência

- Montgomery, D. C.; Peck, E. A. e Vining, G. G. (2021). *Introduction to Linear Regression Analysis, 6th Edition*. Hoboken: Wiley.