

Modelos de Regressão Múltipla - Parte I

Erica Castilho Rodrigues

4 de Outubro de 2016

Regressão Linear Simples na Forma Matricial

ANOVA em forma matricial

Introdução

- ▶ Quando há apenas uma variável explicativa X , temos um problema de regressão linear simples

$$Y_i = \beta_0 + \beta_1 X_i + \epsilon_i$$

onde $\epsilon_i \sim^{iid} N(0, \sigma^2)$.

- ▶ Quando há pelo menos duas variáveis explicativas

$$X_1, X_2, \dots, X_p$$

temos um problema de regressão linear múltipla:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \epsilon_i$$

onde $\epsilon_i \sim^{iid} N(0, \sigma^2)$.

- ▶ Estudamos a influência ou explicação conjunta das variáveis X' na variável Y .
- ▶ A interpretação de β_0 muda?

- ▶ Estudamos a influência ou explicação conjunta das variáveis X' na variável Y .
- ▶ A interpretação de β_0 muda? Não.
- ▶ Qual a interpretação?

- ▶ Estudamos a influência ou explicação conjunta das variáveis X' na variável Y .
- ▶ A interpretação de β_0 muda? Não.
- ▶ Qual a interpretação?
- ▶ β_0 é o valor esperado de Y quando todas variáveis são iguais a zero.
- ▶ Se alguma das variáveis não puder assumir valor zero, β_0 perde essa interpretação.
- ▶ Mesmo assim ele deve continuar na equação.

- ▶ A interpretação dos coeficientes

$$\beta_1, \beta_2, \dots, \beta_p$$

é feita separadamente para cada variável, mantendo as demais fixas.

- ▶ Por exemplo, se $p = 2$.
- ▶ β_1 representa a variação esperada em Y quando X_1 aumenta em uma unidade e X_2 é mantida fixa.
- ▶ Qual interpretação do β_2 ?

► A interpretação dos coeficientes

$$\beta_1, \beta_2, \dots, \beta_p$$

é feita separadamente para cada variável, mantendo as demais fixas.

- Por exemplo, se $p = 2$.
- β_1 representa a variação esperada em Y quando X_1 aumenta em uma unidade e X_2 é mantida fixa.
- Qual interpretação do β_2 ?
- β_2 representa a variação esperada em Y quando X_2 aumenta em uma unidade e X_1 é mantida fixa.

Exemplo

- ▶ Fonte:CRISP- Informativo no 1, dez/2001, pg. 12.
- ▶ Deseja-se analisar incidência de roubos nas unidades de planejamento de Belo Horizonte.
- ▶ Quais variáveis podem explicar?

Exemplo

- ▶ Fonte:CRISP- Informativo no 1, dez/2001, pg. 12.
- ▶ Deseja-se analisar incidência de roubos nas unidades de planejamento de Belo Horizonte.
- ▶ Quais variáveis podem explicar?
- ▶ Renda, porcentagem de área comercial, índice de proteção social.
- ▶ Variável Resposta:
$$Y = \text{logaritmo do número de roubos nas unidades de planejamento.}$$
- ▶ Precisamos da transformação pois a variável Y é uma contagem, logo não segue distribuição normal.

Exemplo (continuação)

- ▶ As variáveis explicativas são as seguintes:

$$X_1 = \{ \text{renda média do chefe da família (dólares)} \}$$

$$X_2 = \{ \text{porcentagem de área comercial} \}$$

$$X_3 = \{ \text{Índice de Proteção Social} \}$$

- ▶ O modelo ajustado é o seguinte

$$\ln(\text{roubo}) = 3.9 + 0.00086(\text{renda}) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

Exemplo (continuação)

- ▶ Vamos interpretar os parâmetros do modelo.
- ▶ Nesse caso β_0 não tem sentido prático.
- ▶ Como a variável resposta está na escala logarítmica, a interpretação modifica um pouco.
- ▶ Vejamos qual interpretação de β_1 .
- ▶ Quais variáveis mantemos fixas?

Exemplo (continuação)

- ▶ Vamos interpretar os parâmetros do modelo.
- ▶ Nesse caso β_0 não tem sentido prático.
- ▶ Como a variável resposta está na escala logarítmica, a interpretação modifica um pouco.
- ▶ Vejamos qual interpretação de β_1 .
- ▶ Quais variáveis mantemos fixas?
- ▶ % de área comercial e IPS.

Exemplo (continuação)

- ▶ Suponha que a renda média do chefe de família aumenta em 1 dólar.
- ▶ Qual aumento esperado no $\ln(\text{roubo})$?

Exemplo (continuação)

- ▶ Suponha que a renda média do chefe de família aumenta em 1 dólar.
- ▶ Qual aumento esperado no $\ln(\text{roubo})$? 0,00086.
- ▶ E se a renda aumenta em 100 dólares?

Exemplo (continuação)

- ▶ Suponha que a renda média do chefe de família aumenta em 1 dólar.
- ▶ Qual aumento esperado no $\ln(\text{roubo})$? 0,00086.
- ▶ E se a renda aumenta em 100 dólares? 0,086

$$\ln(\text{roubo}) = 3.9 + 0.00086(\text{renda}) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

$$\ln(\text{roubo}^*) = 3.9 + 0.00086(\text{renda} + 100) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

$$\ln(\text{roubo}^*) - \ln(\text{roubo}) =$$

Exemplo (continuação)

- ▶ Suponha que a renda média do chefe de família aumenta em 1 dólar.
- ▶ Qual aumento esperado no $\ln(\text{roubo})$? 0,00086.
- ▶ E se a renda aumenta em 100 dólares? 0,086

$$\ln(\text{roubo}) = 3.9 + 0.00086(\text{renda}) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

$$\ln(\text{roubo}^*) = 3.9 + 0.00086(\text{renda} + 100) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

$$\ln(\text{roubo}^*) - \ln(\text{roubo}) = 0.00086(\text{renda} + 100) - 0.00086(\text{renda})$$

=

Exemplo (continuação)

- ▶ Suponha que a renda média do chefe de família aumenta em 1 dólar.
- ▶ Qual aumento esperado no $\ln(\text{roubo})$? 0,00086.
- ▶ E se a renda aumenta em 100 dólares? 0,086

$$\ln(\text{roubo}) = 3.9 + 0.00086(\text{renda}) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

$$\ln(\text{roubo}^*) = 3.9 + 0.00086(\text{renda} + 100) + 0.244(\% \text{ de comércio}) - 0.529(\text{IPS})$$

$$\ln(\text{roubo}^*) - \ln(\text{roubo}) = 0.00086(\text{renda} + 100) - 0.00086(\text{renda})$$

$$= 0.00086(100) = 0.086$$

ou seja

$$\ln(\text{roubo}^*) = \ln(\text{roubo}) + 0.086$$

Exemplo (continuação)

- ▶ Vamos tirar o logaritmo dos dois lados da equação

$$\ln(\textit{roubo}^*) = \ln(\textit{roubo}) + 0.086$$

ficamos com

Exemplo (continuação)

- ▶ Vamos tirar o logaritmo dos dois lados da equação

$$\ln(\textit{roubo}^*) = \ln(\textit{roubo}) + 0.086$$

ficamos com

$$\textit{roubo}^* = \exp\{\ln(\textit{roubo}) + 0.086\} =$$

Exemplo (continuação)

- ▶ Vamos tirar o logaritmo dos dois lados da equação

$$\ln(\textit{roubo}^*) = \ln(\textit{roubo}) + 0.086$$

ficamos com

$$\textit{roubo}^* = \exp\{\ln(\textit{roubo}) + 0.086\} = \textit{roubo}(\exp\{0.086\})$$

como $\exp\{0.086\} = 1.0898$ então

$$\textit{roubo}^* = 1.0898(\textit{roubo}).$$

- ▶ Qual a variação percentual no número de roubos quando a renda aumenta em 100 dólares **e as demais variáveis são mantidas fixas?**

Exemplo (continuação)

- ▶ Vamos tirar o logaritmo dos dois lados da equação

$$\ln(\textit{roubo}^*) = \ln(\textit{roubo}) + 0.086$$

ficamos com

$$\textit{roubo}^* = \exp\{\ln(\textit{roubo}) + 0.086\} = \textit{roubo}(\exp\{0.086\})$$

como $\exp\{0.086\} = 1.0898$ então

$$\textit{roubo}^* = 1.0898(\textit{roubo}).$$

- ▶ Qual a variação percentual no número de roubos quando a renda aumenta em 100 dólares **e as demais variáveis são mantidas fixas?**
- ▶ O roubo aumenta em 8.98%.

Exemplo (continuação)

- ▶ Qual interpretação de β_2 ?
- ▶ Matemos fixas quais variáveis?

Exemplo (continuação)

- ▶ Qual interpretação de β_2 ?
- ▶ Matemos fixas quais variáveis?
- ▶ Renda e IPS.
- ▶ Suponha que a porcentagem de área comercial aumenta em uma unidade (um ponto percentual).
- ▶ Qual aumento esperado no $\ln(\text{roubo})$?

Exemplo (continuação)

- ▶ Qual interpretação de β_2 ?
- ▶ Matemos fixas quais variáveis?
- ▶ Renda e IPS.
- ▶ Suponha que a porcentagem de área comercial aumenta em uma unidade (um ponto percentual).
- ▶ Qual aumento esperado no $\ln(\text{roubo})$? 0.244
- ▶ O que isso significa?

Exemplo (continuação)

- ▶ Qual interpretação de β_2 ?
- ▶ Matemos fixas quais variáveis?
- ▶ Renda e IPS.
- ▶ Suponha que a porcentagem de área comercial aumenta em uma unidade (um ponto percentual).
- ▶ Qual aumento esperado no $\ln(\text{roubo})$? 0.244
- ▶ O que isso significa?

$$\text{roubo}^* = (\exp\{0.244\})\text{roubo}$$

como $(\exp\{0.244\}) = 1.276$ temos que

$$\text{roubo}^* = 1.276\text{roubo}$$

Exemplo (continuação)

- ▶ O que isso significa?

Exemplo (continuação)

- ▶ O que isso significa?
- ▶ Espera-se um aumento de 27.6% no número de roubos quando a ocupação comercial aumenta em um ponto percentual e as demais variáveis são mantidas fixas
- ▶ Vejamos a interpretação de β_3 .
- ▶ Qual variação esperada no $\ln(\text{roubo})$?

Exemplo (continuação)

- ▶ O que isso significa?
- ▶ Espera-se um aumento de 27.6% no número de roubos quando a ocupação comercial aumenta em um ponto percentual e as demais variáveis são mantidas fixas
- ▶ Vejamos a interpretação de β_3 .
- ▶ Qual variação esperada no $\ln(\text{roubo})$? -0.529
- ▶ O que isso significa?

Exemplo (continuação)

- ▶ O que isso significa?
- ▶ Espera-se um aumento de 27.6% no número de roubos quando a ocupação comercial aumenta em um ponto percentual e as demais variáveis são mantidas fixas
- ▶ Vejamos a interpretação de β_3 .
- ▶ Qual variação esperada no $\ln(\text{roubo})$? -0.529
- ▶ O que isso significa?

$$\text{roubo}^* = (\exp\{-0.529\})\text{roubo}$$

como $(\exp\{-0.529\}) = 0.948$ temos que

$$\text{roubo}^* = 0.948\text{roubo}$$

Exemplo (continuação)

- ▶ O que isso significa?

Exemplo (continuação)

- ▶ O que isso significa?
- ▶ Espera-se uma redução de 5.2% no número de roubos quando o IPS aumenta em uma unidade e as demais variáveis são mantidas fixas
- ▶ Observe que uma redução de 5.2% equivale a multiplicar por 0.948.

Regressão Linear Simples na Forma Matricial

- ▶ Podemos escrever o modelo de regressão linear simples de forma matricial.
- ▶ A solução obtida pode ser usada para qualquer modelo de regressão linear.
- ▶ Pode ser usada para um modelo de Regressão Linear Múltipla

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i + \dots + \beta_p X_i + \epsilon_i$$

onde $\epsilon_i \sim^{iid} N(0, \sigma^2)$.

- ▶ O modelo de Regressão Linear Simples é dado por

$$Y_i = \beta_0 + \beta_1 X_i + \epsilon_i \quad \text{para } i = 1, 2, \dots, n$$

ou seja

$$Y_1 = \beta_0 + \beta_1 X_1 + \epsilon_1$$

$$Y_2 = \beta_0 + \beta_1 X_2 + \epsilon_2$$

⋮

$$Y_n = \beta_0 + \beta_1 X_n + \epsilon_n$$

- ▶ Como podemos reescrever esse sistema usando matrizes? (fazer no quadro)

- ▶ Como podemos reescrever esse sistema usando matrizes? (fazer no quadro)

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \beta_0 \\ \beta_0 \\ \vdots \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \beta_1 X_1 \\ \beta_1 X_2 \\ \vdots \\ \beta_1 X_n \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \beta_0 \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} + \beta_1 \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

$$\underbrace{\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}}_{\mathbf{Y}} = \underbrace{\begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix}}_{\mathbf{X}} \underbrace{\begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}}_{\boldsymbol{\beta}} + \underbrace{\begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}}_{\boldsymbol{\epsilon}}$$

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

onde

\mathbf{Y} : vetor $n \times 1$ de observações da variável resposta

\mathbf{X} : matriz $n \times 2$ de observações da variável explicativa

$\boldsymbol{\beta}$: vetor 2×1 de parâmetros

$\boldsymbol{\epsilon}$: vetor $n \times 1$ dos erros

- ▶ Vejamos como ficam os estimadores de mínimos quadrados.
- ▶ Queremos minimizar a soma dos quadrados dos resíduos

$$SQE = \sum_i (Y_i - \hat{Y}_i)^2 = \sum_i e_i^2$$

- ▶ Podemos reescrever da seguinte maneira

$$SQE = \sum_i e_i^2 = [\epsilon_1 \quad e_2 \quad \dots \quad e_n] \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} = \mathbf{e}'\mathbf{e}$$

onde

$$\mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} = \begin{bmatrix} Y_1 - \hat{Y}_1 \\ Y_2 - \hat{Y}_2 \\ \vdots \\ Y_n - \hat{Y}_n \end{bmatrix} = \mathbf{Y} - \mathbf{X}\boldsymbol{\beta}$$

- ▶ Temos então que

$$SQE = \mathbf{e}'\mathbf{e} = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta)$$

(fazer no quadro)

- ▶ Temos então que

$$SQE = \mathbf{e}'\mathbf{e} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$$

(fazer no quadro)

$$\begin{aligned} &= (\mathbf{Y}' - (\mathbf{X}\boldsymbol{\beta})')(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) = (\mathbf{Y}' - \boldsymbol{\beta}'\mathbf{X}')(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \\ &= \mathbf{Y}'\mathbf{Y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \end{aligned}$$

observe que como $\boldsymbol{\beta}$ tem dimensão 2×1 e \mathbf{X} tem dimensão $n \times 2$ então

$$\boldsymbol{\beta}'\mathbf{X}'\mathbf{Y} = \boldsymbol{\beta}'_{1 \times 2} \mathbf{X}'_{2 \times n} \mathbf{Y}_{n \times 1} = (\boldsymbol{\beta}'\mathbf{X}')_{1 \times n} \mathbf{Y}_{n \times 1} = (\boldsymbol{\beta}'\mathbf{X}'\mathbf{Y})_{1 \times 1}$$

- ▶ Portanto $\boldsymbol{\beta}'\mathbf{X}'\mathbf{Y}$ é um escalar e

$$\boldsymbol{\beta}'\mathbf{X}'\mathbf{Y} = (\boldsymbol{\beta}'\mathbf{X}'\mathbf{Y})' = \mathbf{Y}'\mathbf{X}\boldsymbol{\beta}$$

- ▶ Então a SQE fica

$$\begin{aligned}SQE &= \mathbf{Y}'\mathbf{Y} - \beta'\mathbf{X}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}\beta + \beta'\mathbf{X}'\mathbf{X}\beta \\ &= \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}\beta - \mathbf{Y}'\mathbf{X}\beta + \beta'\mathbf{X}'\mathbf{X}\beta \\ &= \mathbf{Y}'\mathbf{Y} - 2\mathbf{Y}'\mathbf{X}\beta + \beta'\mathbf{X}'\mathbf{X}\beta\end{aligned}$$

- ▶ Queremos encontrar o vetor β que minimiza a SQE .
- ▶ Vamos derivar SQE em relação a β .
- ▶ Vamos usar os seguintes resultados

$$\frac{\partial \mathbf{b}'\mathbf{A}\mathbf{x}}{\partial \mathbf{x}} = (\mathbf{b}'\mathbf{A})'$$

se \mathbf{A} é simétrica

$$\frac{\partial \mathbf{x}'\mathbf{A}\mathbf{x}}{\partial \mathbf{x}} = 2\mathbf{A}\mathbf{x}$$

- ▶ Temos que

$$\frac{\partial \mathbf{Y}'\mathbf{X}\beta}{\partial \beta} = (\mathbf{Y}'\mathbf{X})' = \mathbf{X}'\mathbf{Y}$$

$$\frac{\partial \beta'\mathbf{X}'\mathbf{X}\beta}{\partial \beta} = 2\mathbf{X}'\mathbf{X}\beta$$

- ▶ Portanto

$$\frac{\partial SQE}{\partial \beta} = \frac{\partial \mathbf{Y}'\mathbf{Y} - 2\mathbf{Y}'\mathbf{X}\beta + \beta'\mathbf{X}'\mathbf{X}\beta}{\partial \beta} = -2\mathbf{X}'\mathbf{Y} + 2\mathbf{X}'\mathbf{X}\beta.$$

- ▶ Igualando a derivada a zero ficamos com

$$-2\mathbf{X}'\mathbf{Y} + 2\mathbf{X}'\mathbf{X}\beta = 0$$

implica que

$$\mathbf{X}'\mathbf{X}\beta = \mathbf{X}'\mathbf{Y}$$

se $\mathbf{X}'\mathbf{X}$ for inversível, podemos multiplicar por $(\mathbf{X}'\mathbf{X})^{-1}$ dos dois lados

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

- ▶ Concluimos assim que o estimador de mínimos quadrados de β é dado por

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

- ▶ Esse resultado é válido para p variáveis explicativas.
- ▶ No caso da regressão linear simples o vetor β é 2×1 .
- ▶ No caso genérico com p variáveis β é $(p + 1) \times 1$.
- ▶ Aparece $p + 1$ por causa do β_0 .

- ▶ Vamos mostrar que para o caso da regressão linear simples os resultados coincidem com aqueles obtidos anteriormente.
- ▶ A Regressão Linear Simples é um caso particular da Regressão Linear Múltipla.
- ▶ Vamos relembrar alguns resultados sobre matrizes.
- ▶ Seja \mathbf{M} uma matriz 2×2

$$\mathbf{M} = \begin{bmatrix} a & b \\ c & d \end{bmatrix}$$

- ▶ A inversa de \mathbf{M} é dada por

- ▶ A inversa de \mathbf{M} é dada por

$$\mathbf{M}^{-1} = \begin{bmatrix} a & b \\ c & d \end{bmatrix}^{-1} = \frac{1}{D} \begin{bmatrix} d & -b \\ -c & a \end{bmatrix}$$

onde

$$D = \det(\mathbf{M}) = ad - bc.$$

- A matriz $\mathbf{X}'\mathbf{X}$ é dada por

$$\begin{bmatrix} 1 & 1 & \dots & 1 \\ X_1 & X_2 & \dots & X_n \end{bmatrix} \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} = \begin{bmatrix} n & \sum_i X_i \\ \sum_i X_i & \sum_i X_i^2 \end{bmatrix}$$

temos que

$$\det(\mathbf{X}\mathbf{X}') = n \sum_i X_i^2 - \left(\sum_i X_i\right)^2$$

observar que

$$\begin{aligned} n \sum_i (X_i - \bar{X})^2 &= n \left(\sum_i X_i^2 - 2\bar{X} \sum_i X_i + \bar{X}^2 \right) \\ &= n \sum_i X_i^2 - 2n \left(\sum_i X_i \right) / n \left(\sum_i X_i \right) + n^2 \frac{(\sum_i X_i)^2}{n^2} \\ &= n \sum_i X_i^2 - \left(\sum_i X_i \right)^2 \end{aligned}$$

- ▶ E portanto

$$\det(\mathbf{X}'\mathbf{X}) = n \sum_i (X_i - \bar{X})^2$$

- ▶ Como

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} n & \sum_i X_i \\ \sum_i X_i & \sum_i X_i^2 \end{bmatrix}$$

temos que

$$(\mathbf{X}'\mathbf{X})^{-1} = \frac{1}{n \sum_i (X_i - \bar{X})^2} \begin{bmatrix} \sum_i X_i^2 & -\sum_i X_i \\ -\sum_i X_i & n \end{bmatrix}$$

- ▶ Temos ainda que

$$\mathbf{X}'\mathbf{Y} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ X_1 & X_2 & \dots & X_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n X_i Y_i \end{bmatrix}$$

- ▶ Portanto

$$\begin{aligned} \hat{\beta} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} \\ &= \frac{1}{n \sum_i (X_i - \bar{X})^2} \begin{bmatrix} \sum_i X_i^2 & -\sum_i X_i \\ -\sum_i X_i & n \end{bmatrix} \begin{bmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n X_i Y_i \end{bmatrix} \end{aligned}$$

$$= \frac{1}{n \sum_i (X_i - \bar{X})^2} \begin{bmatrix} \sum_i X_i^2 \sum_i Y_i - \sum_i X_i \sum_i X_i Y_i \\ - \sum_i X_i \sum_i Y_i + n \sum_i X_i Y_i \end{bmatrix}$$

- ▶ Vamos verificar o primeiro termo do vetor

$$\frac{\sum_i X_i^2 \sum_i Y_i - \sum_i X_i \sum_i X_i Y_i}{n \sum_i (X_i - \bar{X})^2}$$

somando e subtraindo $n\bar{X}^2 \sum_i Y_i$

$$\frac{\sum_i X_i^2 \sum_i Y_i - n\bar{X}^2 \sum_i Y_i + n\bar{X}^2 \sum_i Y_i - \sum_i X_i \sum_i X_i Y_i}{n \sum_i (X_i - \bar{X})^2}$$

$$= \frac{\sum_i Y_i (\sum_i X_i^2 - n\bar{X}^2) + n \frac{(\sum_i X_i)^2}{n^2} \sum_i Y_i - \sum_i X_i \sum_i X_i Y_i}{n \sum_i (X_i - \bar{X})^2}$$

► Como

$$\sum_i X_i^2 - n\bar{X}^2 = \sum_i (X_i - \bar{X})^2$$

ficamos com

$$\begin{aligned} &= \frac{\sum_i Y_i}{n} \frac{\sum_i (X_i - \bar{X})^2}{\sum_i (X_i - \bar{X})^2} + \frac{\sum_i X_i \left(\frac{\sum_i X_i \sum_i Y_i}{n} - \sum_i X_i Y_i \right)}{n \sum_i (X_i - \bar{X})^2} \\ &= \bar{Y} - \bar{X} \frac{\left(\frac{-\sum_i X_i \sum_i Y_i}{n} + \sum_i X_i Y_i \right)}{\sum_i (X_i - \bar{X})^2} \end{aligned}$$

já vimos que

$$\sum_i X_i Y_i - \frac{\sum_i X_i \sum_i Y_i}{n} = \sum_i (X_i - \bar{X})(Y_i - \bar{Y})$$

- ▶ Portanto ficamos com

$$\bar{Y} - \bar{X} \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_i (X_i - \bar{X})^2}$$

mas

$$\hat{\beta}_1 = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_i (X_i - \bar{X})^2}$$

- ▶ Mostramos assim que o primeiro elemento do vetor $\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$ é dado por

$$\bar{Y} - \bar{X}\hat{\beta}_1$$

que é justamente a expressão que tínhamos para o $\hat{\beta}_0$ no caso da Regressão Linear Simples.

- ▶ Vejamos agora como fica o segundo elemento de

$$\hat{\beta} = \frac{1}{n \sum_i (X_i - \bar{X})^2} \begin{bmatrix} \sum_i X_i^2 \sum_i Y_i - \sum_i X_i \sum_i X_i Y_i \\ - \sum_i X_i \sum_i Y_i + n \sum_i X_i Y_i \end{bmatrix}.$$

- ▶ Temos que

$$\begin{aligned} & \frac{- \sum_i X_i \sum_i Y_i + n \sum_i X_i Y_i}{n \sum_i (X_i - \bar{X})^2} \\ &= \frac{n \left(\sum_i X_i Y_i - \frac{\sum_i X_i \sum_i Y_i}{n} \right)}{n \sum_i (X_i - \bar{X})^2} \end{aligned}$$

já vimos que

$$\sum_i X_i Y_i - \frac{\sum_i X_i \sum_i Y_i}{n} = \sum_i (X_i - \bar{X})(Y_i - \bar{Y})$$

- ▶ Ficamos então com

$$\frac{n \sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{n \sum_i (X_i - \bar{X})^2} = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_i (X_i - \bar{X})^2}$$

que é a expressão que encontramos para $\hat{\beta}_1$ anteriormente.

- ▶ Mostramos assim que

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix}$$

- ▶ Portanto as expressões obtidas para o caso genérico condizem com aquelas que foram obtidas para o modelo de Regressão Linear Simples.

ANOVA em forma matricial

- ▶ As somas de quadrados também podem ser escritas em forma matricial.
- ▶ A Soma de Quadrados Totais pode ser escrita como

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

mas

$$\sum_i Y_i^2 = [Y_1 \quad Y_2 \quad \dots \quad Y_n] \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \mathbf{Y}'\mathbf{Y}$$

portanto a SQT pode ser escrita como

$$SQT = \mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$$

- ▶ A Soma de Quadrados da Regressão pode ser escrita como

$$SQR = \sum_i (\hat{Y}_i - \bar{Y})^2 = \sum_i \hat{Y}_i^2 - 2\bar{Y} \sum_i \hat{Y}_i + n\bar{Y}^2$$

mas sabemos que

$$\sum_i e_i = \sum_i (\hat{Y}_i - Y_i) = 0 \Rightarrow \sum_i \hat{Y}_i = \sum_i Y_i$$

logo

$$\begin{aligned} SQR &= \sum_i \hat{Y}_i^2 - 2\bar{Y} \sum_i \hat{Y}_i + n\bar{Y}^2 = \sum_i \hat{Y}_i^2 - 2\bar{Y} \sum_i Y_i + n\bar{Y}^2 \\ &= \sum_i \hat{Y}_i^2 - 2n\bar{Y} + n\bar{Y}^2 = \sum_i \hat{Y}_i^2 - n\bar{Y}^2. \end{aligned}$$

- ▶ Temos ainda que

$$\sum_i \hat{Y}_i^2 = \hat{\mathbf{Y}}' \hat{\mathbf{Y}}$$

mas

$$\hat{\mathbf{Y}} = \mathbf{X} \hat{\boldsymbol{\beta}} \Rightarrow \hat{\mathbf{Y}}' = \hat{\boldsymbol{\beta}}' \mathbf{X}'$$

e podemos escrever ainda

$$\hat{\mathbf{Y}} = \mathbf{X} \hat{\boldsymbol{\beta}}$$

substituindo $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$ ficamos com

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

- ▶ Substituindo

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

em

$$\sum_i \hat{Y}_i^2 = \hat{\mathbf{Y}}'\hat{\mathbf{Y}}$$

ficamos com

$$\sum_i \hat{Y}_i^2 = \hat{\beta}'\mathbf{X}'\mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} = \hat{\beta}'\mathbf{X}'\mathbf{Y}.$$

- ▶ Portanto

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

- ▶ A Soma de Quadrados do Resíduo é dada por

$$SQE = SQT - SQR .$$

- ▶ Mas vimos que

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

- ▶ Logo

$$\begin{aligned} SQE &= \mathbf{Y}'\mathbf{Y} - n\bar{Y}^2 - (\hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2) \\ &= \mathbf{Y}'\mathbf{Y} - \hat{\beta}'\mathbf{X}'\mathbf{Y} . \end{aligned}$$

- ▶ A tabela ANOVA pode ser escrita matricialmente da seguinte forma

Fonte de Variação	Graus de Liberdade	Soma de Quadrados
Regressão	1	$\hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2$
Resíduo	$n - 2$	$\mathbf{Y}'\mathbf{Y} - \hat{\beta}'\mathbf{X}'\mathbf{Y}$
Total	$n - 1$	$\mathbf{Y}'\mathbf{Y} - n\bar{Y}^2$

Tabela: Tabela ANOVA

- ▶ Vejamos agora como fica a variância e covariância de $\hat{\beta}$ em notação matricial.
- ▶ Vimos que

$$\text{Var}(\hat{\beta}_0) = \frac{\sigma^2 \sum_i X_i^2}{n \sum_i (X_i - \bar{X})^2}$$

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2}$$

- ▶ Temos ainda que

$$\begin{aligned} \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) &= \text{Cov}(\bar{Y} - \hat{\beta}_1 \bar{X}, \hat{\beta}_1) \\ &= \text{Cov}(\bar{Y}, \hat{\beta}_1) + \text{Cov}(-\hat{\beta}_1 \bar{X}, \hat{\beta}_1) \\ &= \text{Cov}(\bar{Y}, \hat{\beta}_1) - \bar{X} \text{Cov}(\hat{\beta}_1, \hat{\beta}_1) \end{aligned}$$

já vimos que

$$\text{Cov}(\bar{Y}, \hat{\beta}_1) = 0$$

além disso

$$\text{Cov}(\hat{\beta}_1, \hat{\beta}_1) = \text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2}$$

portanto

$$\begin{aligned} \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) &= \text{Cov}(\bar{Y}, \hat{\beta}_1) - \bar{X} \text{Cov}(\hat{\beta}_1, \hat{\beta}_1) \\ &= 0 - \bar{X} \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} = -\bar{X} \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} . \end{aligned}$$

- ▶ A matriz de variâncias e covariâncias do vetor $(\hat{\beta}_0, \hat{\beta}_1)'$ é dada por

$$\begin{aligned} \text{Var} \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} &= \begin{bmatrix} \text{Var}(\hat{\beta}_0) & \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) \\ \text{Cov}(\hat{\beta}_1, \hat{\beta}_0) & \text{Var}(\hat{\beta}_1) \end{bmatrix} \\ &= \begin{bmatrix} \frac{\sigma^2 \sum_i X_i^2}{n \sum_i (X_i - \bar{X})^2} & -\bar{X} \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} \\ -\bar{X} \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} & \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} \end{bmatrix} \\ &= \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} \begin{bmatrix} \frac{\sum_i X_i^2}{n} & -\bar{X} \\ -\bar{X} & 1 \end{bmatrix} \end{aligned}$$

- ▶ Vamos agora chegar nesse mesmo resultado, porém usando a notação matricial do vetor $(\hat{\beta}_0, \hat{\beta}_1)'$.
- ▶ Vimos que

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix}$$

- ▶ Vamos usar o seguinte resultado

$$\text{Var}(\mathbf{A}\mathbf{Y}) = \mathbf{A} \text{Var}(\mathbf{Y}) \mathbf{A}'$$

onde \mathbf{A} é uma matriz de constantes e \mathbf{Y} é um vetor aleatório.

- ▶ Observe que esse resultado é o caso geral de

$$\text{Var}(aY) = a^2 \text{Var}(Y).$$

- ▶ Vimos que

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

e $(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'$ é uma matriz de constantes.

- ▶ Logo

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

- ▶ Mas sabemos que os Y_i 's são i.i.d. com variância constante σ^2
- ▶ Portanto a matriz de variâncias e covariâncias do vetor \mathbf{Y} é dada por

$$\text{Var}(\mathbf{Y}) = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & 1 \end{bmatrix} = \sigma^2 \mathbf{I}_n$$

- ▶ E portanto

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

- Já vimos que

$$\begin{aligned}(\mathbf{X}'\mathbf{X})^{-1} &= \frac{1}{n \sum_i (X_i - \bar{X})^2} \begin{bmatrix} \sum_i X_i^2 & -\sum_i X_i \\ -\sum_i X_i & n \end{bmatrix} \\ &= \frac{1}{\sum_i (X_i - \bar{X})^2} \begin{bmatrix} \frac{\sum_i X_i^2}{n} & -\frac{\sum_i X_i}{n} \\ -\frac{\sum_i X_i}{n} & \frac{n}{n} \end{bmatrix} \\ &= \frac{1}{\sum_i (X_i - \bar{X})^2} \begin{bmatrix} \frac{\sum_i X_i^2}{n} & -\bar{X} \\ -\bar{X} & 1 \end{bmatrix}\end{aligned}$$

- ▶ Portanto

$$\begin{aligned} \text{Var}(\hat{\beta}) &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \\ &= \frac{\sigma^2}{\sum_i (X_i - \bar{X})^2} \begin{bmatrix} \frac{\sum_i X_i^2}{n} & -\bar{X} \\ -\bar{X} & 1 \end{bmatrix} \end{aligned}$$

que foi exatamente o mesmo resultado que obtivemos para o caso da Regressão Linear Simples.

- ▶ Observe que o resultado $\text{Var}(\hat{\beta}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$ vale para um número genérico de variáveis.
- ▶ Estamos mostrando aqui que para o caso particular $p = 1$ o resultado coincide com o que obtivemos anteriormente.