

# Regressão Linear Simples

---

- Modelo linear para explicar a variável Y, denominada variável dependente, explicada ou endógena como função da variável X, denominada variável independente, explicativa ou exógena

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

# Propriedades do estimador MQO

---

## ➤ Pressupostos de MQO:


1. O modelo populacional é linear nos parâmetros.
2. Podemos utilizar uma amostra aleatória de tamanho  $n$ .
3. A esperança condicional de  $u$  dado  $x$  é equivalente a zero.

$$E(u/X) = E(u) = 0$$

4. Há variabilidade em  $x$ .


# Correlação e Regressão

---




# Regressão Linear Simples

---



# Regressão Linear Simples

---



# Regressão Linear Simples

---

- Problema: Os parâmetros *beta* são desconhecidos. O objetivo principal de regressão é estimar esses parâmetros a partir de uma amostra de tamanho  $n$   $\{(x_i, y_i): i=1, \dots, n\}$
- Para cada observação na amostra, tem-se:

$$y_i = \beta_0 + \beta_1 x_i + u_i$$

# Método dos Mínimos Quadrados

---

- A idéia de MQO é encontrar uma linha próxima o suficiente dos dados amostrais tal que a soma dos quadrados dos resíduos seja a menor possível.
- Por definição, o resíduo,  $\hat{u}$ , é uma estimativa do termo de erro  $u$ .

# Método dos Mínimos Quadrados

---

➤ Formalmente, tem-se a minimização de:

$$\sum_{i=1}^n (\hat{u}_i)^2 = \sum_{i=1}^n \left( y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i \right)^2$$



# Método dos Mínimos Quadrados

---

- A solução do problema de minimização nos fornece as condições de primeira ordem:

$$\sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

$$\sum_{i=1}^n x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

# Método dos Mínimos Quadrados

---

- Portanto, a estimação dos parâmetros é dada por:

$$\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x},$$

or

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

# Método dos Mínimos Quadrados

---

➤ E,

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

provided that  $\sum_{i=1}^n (x_i - \bar{x})^2 > 0$

# Método dos Mínimos Quadrados

---

- A inclinação da reta é a covariância amostral entre  $x$  e  $y$  dividida pela variância amostral de  $x$ .


# Regressão Linear Simples

---

- A relação entre valor observado de  $Y$  e valor previsto de  $Y$  pelo modelo é dada pelo resíduo:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$

$$y = \hat{y} + \hat{u}$$



# Método dos Mínimos Quadrados

---

Cada observação  $y_i$  tem uma parte explicada e uma parte inexplorada, o resíduo do modelo

$y_i = \hat{y}_i + \hat{u}_i$  . Definimos:

$\sum (y_i - \bar{y})^2$  é a soma dos quadrados totais (SQT)

$\sum (\hat{y}_i - \bar{y})^2$  é a soma dos quadrados explicados (SQE)

$\sum \hat{u}_i^2$  é a soma dos quadrados dos resíduos (SQR)

Then  $SQT = SQE + SQR$

# Regressão Linear Simples

---

- Como o nosso modelo de regressão se ajusta aos dados?
- Mensuração da qualidade do ajuste:

$$\begin{aligned} R^2 &= SSE/SST \\ &= 1 - SSR/SST \end{aligned}$$



# Regressão Linear Simples

---

Dependent Variable: WAGE  
Method: Least Squares  
Date: 04/13/21 Time: 13:31  
Sample: 1 526  
Included observations: 526

Variable	Coefficient	Std. Error	t-Statistic	Prob.
EDUC	0.541359	0.053248	10.16675	0.0000
C	-0.904852	0.684968	-1.321013	0.1871
R-squared	0.164758	Mean dependent var		5.896103
Adjusted R-squared	0.163164	S.D. dependent var		3.693086
S.E. of regression	3.378390	Akaike info criterion		5.276470
Sum squared resid	5980.682	Schwarz criterion		5.292688
Log likelihood	-1385.712	Hannan-Quinn criter.		5.282820
F-statistic	103.3627	Durbin-Watson stat		1.823686
Prob(F-statistic)	0.000000			

# Propriedades do estimador MQO

---

## ➤ Pressupostos de MQO:

1. O modelo populacional é linear nos parâmetros.
2. Podemos utilizar uma amostra aleatória de tamanho  $n$ .
3. A esperança condicional de  $u$  dado  $x$  é equivalente a zero.
4. Há variabilidade em  $x$ .

# Propriedades do estimador MQO

---

- Com base nesses 4 pressupostos, pode-se demonstrar que estimador MQO é não-enviesado:

$$E(\hat{\beta}_1) = \beta_1$$

- Ou seja, a distribuição amostral está centrada no valor verdadeiro do parâmetro.
- E como a distribuição amostral está espalhada?

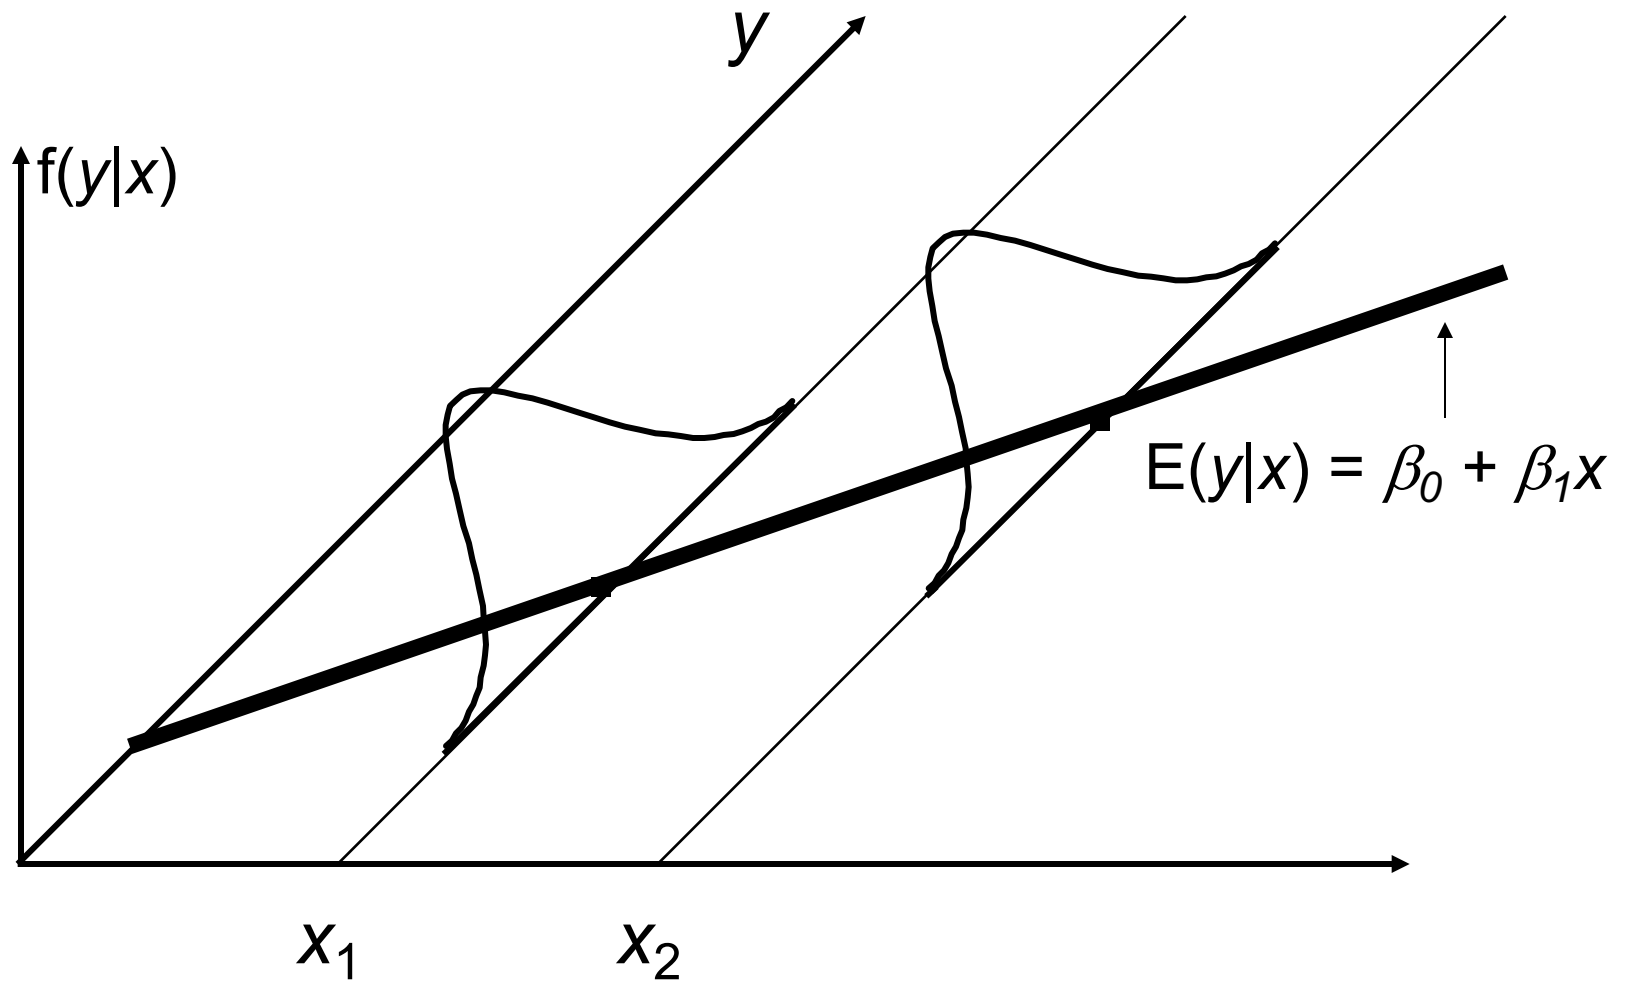
# Propriedades do estimador MQO

---


➤ Assumimos inicialmente homocedasticidade:

$$\text{Var}(u / x) = \text{Var}(u) = \sigma^2$$

# Caso 1: Homocedasticidade



## Caso 2: Heterocedasticidade



# Variância de MQO

---

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{S_x^2}$$

# Variância de MQO

---

- ▶ Quanto maior a variância do erro, maior a variância do estimador beta
- ▶ Quanto maior a variabilidade de  $x$ , menor essa variância.
- ▶ Problema: a variância do erro é desconhecida!



# Variância de MQO

---

Um estimador não-enviesado de  $\sigma^2$  é:

$$\hat{\sigma}^2 = \frac{1}{(n-2)} \sum \hat{u}_i^2 = \text{SQR} / (n-2)$$

# Regressão Linear Múltipla

# Regressão Linear Múltipla

---

- Se a variável dependente for uma função de  $k$  variáveis explicativas, tem-se:

- ▶  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$

- Como anteriormente, os valores dos parâmetros são estimados através da minimização da soma dos quadrados dos resíduos.

# Regressão Linear Múltipla

---

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k, \text{ então}$$

$$\Delta \hat{y} = \hat{\beta}_1 \Delta x_1 + \hat{\beta}_2 \Delta x_2 + \dots + \hat{\beta}_k \Delta x_k,$$

Se mantivermos  $x_2, \dots, x_k$  fixos, tem-se:

$$\Delta \hat{y} = \hat{\beta}_1 \Delta x_1$$

# Pressupostos para ausência de viés

---

- Assuma que o modelo populacional é linear nos parâmetros:  $y = b_0 + b_1x_1 + b_2x_2 + \dots + b_kx_k + u$
- Podemos utilizar uma amostra aleatória  $\{(x_{i1}, x_{i2}, \dots, x_{ik}, y_i): i=1, 2, \dots, n\}$ ,
- $E(u|x_1, x_2, \dots, x_k) = 0$ ,
- Nenhum das variáveis explicativas é constante ou uma combinação linear das demais.

# Variance of OLS (cont)

---

- ▶ Seja  $\mathbf{x} = (x_1, x_2, \dots, x_k)$
- ▶ Assuma homocedasticidade, como no modelo de regressão linear simples,  
$$\text{Var}(u|\mathbf{x}) = s^2$$
- ▶ Os 4 pressupostos para ausência de viés, juntamente com o pressuposto de homocedasticidade, são os pressupostos de Gauss-Markov.

## Variance of OLS (cont)

---

Dados os pressupostos de Gauss-Markov, tem-se:

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j (1 - R_j^2)}, \text{ onde}$$

$$SST_j = \sum (x_{ij} - \bar{x}_j)^2 \text{ e } R_j^2 \text{ é o } R^2 \text{ da}$$

*regressão de  $x_j$  nos demais  $x$ 's*

## Variance of OLS (cont)

---

Dados os pressupostos de Gauss-Markov, MQO é o melhor estimador linear não-enviesado dos parâmetros populacionais!

"OLS is BLUE"





# Inferência

# Regressão Linear Simples - Inferência

---

➤ Considere:

$$\blacktriangleright y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

➤ Utilizamos dados amostrais para calcular as estimativas dos parâmetros.

# Regressão Linear Simples - Inferência

---

➤ Para realizar testes de hipóteses, assumimos que  $u$  tem distribuição normal com média 0 e variância constante.

➤ Nesse caso,

$$\frac{(\hat{\beta}_j - \beta_j)}{se(\hat{\beta}_j)} \sim t_{n-k-1}$$

# Regressão Linear Simples - Inferência

---

- Podemos testar hipóteses com relação aos parâmetros populacionais
- Para isso, precisamos calcular o desvio-padrão associado aos estimadores.

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}, \text{ onde}$$

# Regressão Linear Simples - Inferência

---

➤ Estamos prontos para testar hipóteses com relação aos valores dos parâmetros populacionais

➤ Exemplo:

$$H_0: \beta = 0$$

$$H_1: \beta \neq 0$$

# Regressão Linear Simples - Inferência

---

➤ A estatística do teste é:

$$t = \frac{(\hat{\beta}_j - 0)}{se(\hat{\beta}_j)}$$

# Teste de Hipótese

---

► As etapas do teste são:

1. Escrever as hipóteses alternativas e nulas
2. Escolher o nível de significância do teste  $\alpha$
3. Calcular a estatística  $t$ , conhecida como a **estatística do teste**
4. Encontrar o **valor crítico** do teste  $t^*$ ,
5. Decidir: Se o valor absoluto de  $t$  for maior do que o de  $t^*$ , rejeitar  $H_0$  com um nível de confiança de  $1-\alpha$