



DCP098

Fundamentos para Avaliação Quantitativa de Políticas Públicas

Regressão simples: como interpretar e calcular coeficientes

Aula 06
18 de abril de 2022

Ana Paula Karruz

Interpretação dos coeficientes estimados




FIGURE 1.3: Regression Line for Weight and Donuts in Springfield

Fonte: Adaptado de Bailey (2016, p 9).

1 libra = 0,454 quilograma
1 quilograma = 2,205 libras

- Estimação da linha de regressão fornece os seguintes resultados:

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 * X_i$$

$$\hat{Y}_i = 121.6 + 9.2 * X_i$$

onde Y = peso em libras, X = donuts por semana, e i é o subscrito que indexa indivíduos

- **Intercepto (constante):** Estima-se que indivíduos que não consomem donuts pesem 121,6 pounds, em média
- **Coeficiente de inclinação:** Estima-se que o consumo de um donut adicional por semana está associado a um aumento 9,2 pounds no peso

ceteris paribus?




FIGURE 1.4: Examples of Lines Generated by Core Statistical Model

Discussion Questions

For each of the panels in Figure 1.4, determine whether β_0 and β_1 are greater than, equal to, or less than zero. (Be careful with β_0 in panel (d)!)

Como são calculados os coeficientes de regressão?




FIGURE 3.1: Relationship Between Income Growth and Vote for the Incumbent President's Party, 1948-

Fonte: Bailey (2016: 66).

Nota: The income change variable refers to the last year of incumbent party's term.

- A partir de dados como os do painel (a), estimamos a **linha que melhor caracterize a relação** entre as duas variáveis

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

$$\text{Incumbent party vote share}_i = \beta_0 + \beta_1 \text{Income change}_i + \varepsilon_i$$

ε_i = all other factors affecting elections (e.g., wars, scandals)

- Um **algoritmo (regra de cálculo)** poderoso para estimação dos parâmetros (β_0 e β_1) é **Mínimos Quadrados Ordinários (MQO, OLS em inglês)**

Como MQO “encontra” a linha que melhor descreve os dados?




FIGURE 3.3: Fitted Values and Residuals for Observations in Table 3.1

Fonte: Bailey (2016: 76).

- MQO identifica a **linha que minimiza a soma da distância entre cada valor observado de Y_i e a linha** (linha informa o valor estimado de Y_i , aka \hat{Y}_i ou **fitted value**)
- Essa **distância** corresponde ao **resíduo**; o resíduo é a **manifestação empírica do erro aleatório “verdadeiro”** (o ε_i do modelo populacional):

$$\text{Resíduo}_i = Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i)$$

Há várias representações de resíduo, entre elas:

$$e_i, \hat{e}_i, r_i, \hat{\varepsilon}_i, Y_i - \hat{Y}_i$$


- Especificamente, MQO minimiza a seguinte expressão, em que $\hat{e}_i = \text{resíduo}$:

$$\sum_{i=1}^N \hat{e}_i^2 = \sum (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)^2$$

Especificamente, MQO identifica a linha que minimiza a soma do quadrado dos resíduos

- Valores elevados ao quadrado são sempre positivos
- Resíduos são elevados ao quadrado para que erros de estimação “para cima” e “para baixo” não se anulem


Cenário 1



Soma dos resíduos = 0
Soma dos resíduos² = 0



Cenário 2



Soma dos resíduos = 0
Soma dos resíduos² = 350

- Outra possibilidade seria minimizar a média do módulo do resíduo (i.e., o desvio médio), mas essa ideia não se convencionou (Gorard, S. Revisiting a 90-year-old debate: the advantages of the mean deviation, *British Journal of Educational Studies*, v. 53, n. 4, December 2005, p. 417-430.

<https://doi.org/10.1111/j.1467-8527.2005.00304.x>

Minimização da soma do quadrado dos resíduos

- Queremos identificar a combinação de coeficientes estimados (β_0 e β_1) que minimiza a soma dos quadrados dos resíduos; aqui, usaremos a letra a para designar o β_0 , a letra b para designar o β_1 , e a letra e para designar o resíduo:

$$Z = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n [Y_i - (a + bX_i)]^2$$

- No ponto em que a soma do quadrado dos resíduos (Z) for mínima, a derivada parcial de Z em relação a a e a derivada parcial de Z em relação a b serão nulas; assim, a minimização passa por obter essas derivadas e igualá-las a zero:

$$\frac{\partial Z}{\partial a} = -2 \sum [Y_i - (a + bX_i)] = 0$$

$$\frac{\partial Z}{\partial b} = 2 \sum [Y_i - (a + bX_i)](-X_i) = 0$$

- Os valores de a e de b que minimizam Z (ou seja, que fazem ambas as derivadas nulas) atendem ao seguinte sistema de equações normais:

$$\begin{cases} na + b \sum X_i = \sum Y_i \\ a \sum X_i + b \sum X_i^2 = \sum X_i Y_i \end{cases}$$

- Na prática, determinamos b em primeiro lugar:

$$b = \frac{n \sum XY - (\sum X)(\sum Y)}{n \sum X^2 - (\sum X)^2} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sum (X - \bar{X})^2}$$

$$a = \frac{\sum Y}{n} - b \frac{\sum X}{n} = \bar{Y} - b\bar{X}$$

Fonte: Hoffmann (2016)

Essa minimização produz equações para as estimativas dos coeficientes de inclinação e intercepto

Coeficiente: inclinação

$$\hat{\beta}_1 = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^N (X_i - \bar{X})^2}$$



Fonte:
<https://weeklyblabber.wordpress.com/2018/01/12/deja-vu-evoking-memories/>

- **Numerador** é chamado de **soma dos produtos cruzados** (mesmo numerador do coeficiente de correlação)
- Conceitualmente, numerador é uma medida de quanto os valores dos **pares ordenados (X_i, Y_i)** são **relacionados entre si**
- Denominador “**padroniza**” o **numerador**, fazendo com que $\hat{\beta}_1$ seja a variação em Y esperada quando X varia em **uma unidade**

Essa minimização produz equações para as estimativas dos coeficientes de inclinação e intercepto

Coeficiente: Intercepto

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

- A estimativa do intercepto corresponde à **diferença entre a média de Y (i.e., \bar{Y}), de um lado, e $\hat{\beta}_1$ vezes a média de X (i.e., \bar{X}), de outro**
- Esta fórmula é obtida a partir da **solução de um sistema de equações com incógnitas $\hat{\beta}_0$ e $\hat{\beta}_1$** (detalhes no slide oculto “Minimização da soma dos quadrados dos resíduos”)
- Na regressão simples, essa fórmula implica que a **reta estimada passará, necessariamente, pela coordenada (\bar{X}, \bar{Y}) .**

Voltaremos a este ponto

Alerta:

Não confunda $\hat{\beta}_0$ com a média amostral de Y para X = 0




FIGURE 1.3: Regression Line for Weight and Donuts in Springfield

Fonte: Adaptado de Bailey (2016, p. 9).

- $\hat{\beta}_0$ é o valor estimado do peso para indivíduos que não consumiram donuts na última semana: 121,6 libras
- Note que $\hat{\beta}_0$ não é o peso médio dos indivíduos que não consumiram donuts na última semana (apenas Marge e Lisa):
 $\bar{Y} = 171,8$
 $(\bar{Y}|X=0) = 105,5$
 $(\bar{Y}|X>0) = 183,9$
- Modelo sobrestima o peso médio das pessoas que não consumiram donuts, pois há poucos casos nessa condição; no processo de “encaixe” da reta, o padrão prevalente é aquele das pessoas que consumiram donut

Voltando ao exemplo: Bivariate OLS and presidential elections




FIGURE 3.3: Fitted Values and Residuals for Observations in Table 3.1

Fonte: Bailey (2016: 76).

Sobre a diferença entre ponto percentual e variação percentual, vide:
<https://educacao.uol.com.br/disciplinas/matematica/ponto-percentual-nao-confunda-com-porcentagem.htm>

$$\begin{aligned} \widehat{\text{Incumbent party vote share}}_i &= \hat{\beta}_0 + \hat{\beta}_1 \text{Income change}_i \\ &= 45.9 + 2.3 \times \text{Income change}_i \end{aligned}$$



Table 3.1: Selected Observations from Election and Income Data

Year	Income change (X)	Incumbent party vote share (Y)	Fitted value (\hat{Y})	Residual ($\hat{\epsilon}$)
1960	0.58	49.9	47.2	2.7
1964	5.58	61.3	58.7	2.6
2000	3.85	50.2	54.7	-4.5

Fonte: Bailey (2016: 77).

Como interpretar coeficientes estimados, valores previstos (\hat{Y}) e resíduos?

Estima-se que o percentual de votos recebidos pelo partido do incumbente no cenário de estagnação econômica (i.e., variação percentual da renda = 0) seja 45,9%.

Estima-se que o aumento de um ponto percentual na variação percentual da renda (e.g., passar de um crescimento de 3% para 4%) esteja associado com um aumento de 2,3 pontos percentuais no percentual de votos recebidos pelo partido do incumbente.



DCP098

Fundamentos para Avaliação Quantitativa de Políticas Públicas

Regressão simples: como interpretar e calcular coeficientes

Aula 06

18 de abril de 2022

Ana Paula Karruz