

ACH3657

# Métodos Quantitativos para Avaliação de Políticas Públicas

Aula Teórica 02  
Análise de Regressão

Alexandre Ribeiro Leichsenring  
[alexandre.leichsenring@usp.br](mailto:alexandre.leichsenring@usp.br)



# Introdução

- Modelo de regressão simples pode ser usado para estudar a relação entre duas variáveis
- Tem algumas limitações
- Adequado como ferramenta empírica
- Aprender a interpretar o modelo de regressão simples: boa prática para estudar regressão múltipla

# Definição do Modelo de Regressão Simples

- Premissa:  $y$  e  $x$  são duas variáveis e estamos interessados em explicar  $y$  em termos de  $x$
- Ou: Estudar como  $y$  varia com variações em  $x$

## Exemplos

- $y$  é a produção de soja;  $x$  é a quantidade de fertilizante
- $y$  é o salário;  $x$ , anos de educação
- $y$  é a taxa de criminalidade;  $x$  é o número de policiais

## Questões


- i Nunca há uma relação exata entre duas variáveis, como consideramos outros fatores que afetam  $y$ ?
- ii Qual a relação funcional entre  $x$  e  $y$ ?
- iii Como podemos estar certos de capturar a relação *ceteris paribus* entre  $x$  e  $y$ ?



- Uma equação simples é:

$$y = \beta_0 + \beta_1 x + u. \quad (1)$$

- A equação acima define o **modelo de regressão linear simples**



## Terminologia para a Regressão Simples

<b><math>y</math></b>	<b><math>x</math></b>
Variável Dependente	Variável Independente
Variável Explicada	Variável Explicativa
Variável de Resposta	Variável de Controle
Variável Prevista	Variável Previsora
Regressando	Regressor

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


- A variável  $u$ , chamada **termo de erro** ou **perturbação**, representa outros fatores, além, de  $x$ , que afetam  $y$
- A regressão simples trata todos os fatores que afetam  $y$ , além de  $x$ , como **não-observados**
- Podemos pensar em  $u$  como o **não-observado**
- A equação também trata da relação funcional entre  $y$  e  $x$ 
  - ▶ Se  $\Delta u = 0$ , então  $x$  tem um efeito linear sobre  $y$ ;

$$\Delta u = 0 \Rightarrow \Delta y = \beta_1 \Delta x$$

- A variação em  $y$  é igual a  $\beta_1$  multiplicado pela variação em  $x$



- $\beta_1$  é o **parâmetro de inclinação** da relação entre  $y$  e  $x$
- $\beta_0$  é o **parâmetro de intercepto** (raramente central em uma análise)



## Exemplo: Produção de Soja e Fertilizantes

- Suponha que a produção de soja seja dada pelo modelo:

$$producao = \beta_0 + \beta_1 fertilizante + u$$

de modo que:

- ▶  $y = producao$
- ▶  $x = fertilizantes$
- O pesquisador agrícola está interessado no efeito dos fertilizantes sobre a produção, mantendo outros fatores fixos. (Efeito dado por  $\beta_1$ )
- O termo erro  $u$  contém fatores como qualidade da terra, chuva etc.
- O coeficiente  $\beta_1$  mede o efeito dos fertilizantes sobre a produção, mantendo outros fatores fixos:

$$\Delta producao = \beta_1 \Delta fertilizante$$


## Exemplo: Equação Simples do Salário

- Um modelo que relaciona o salário de uma pessoa à educação observada e outros fatores não-observados é

$$\textit{salario} = \beta_0 + \beta_1 \textit{educ} + u$$

- Se *salario* é medido em reais por hora e *educ* corresponde a anos de educação formal,  $\beta_1$  mede a variação no salário-hora dado um ano a mais de educação, mantendo todos os outros fatores fixos
- Alguns desses fatores incluem experiência da força de trabalho, aptidão inata, permanência com o empregador atual, ética no trabalho, etc

- A linearidade do modelo implica que uma variação de uma unidade em  $x$  tem o mesmo efeito sobre  $y$ , independentemente do valor inicial de  $x$
- Irreal em algumas aplicações
- Na equação salário x educação, podemos querer considerar retornos *crescentes*: o próximo ano de educação teria, em relação ao anterior, um efeito *maior* sobre os salários
- A questão mais difícil é saber se o modelo realmente nos permite tirar conclusões *ceteris paribus* sobre como  $x$  afeta  $y$
- Acabamos de ver que  $\beta_1$  mede o efeito de  $x$  sobre  $y$ , mantendo todos os outros fatores (em  $u$ ) fixos
- Isso não encerra, entretanto, a questão da causalidade!
- Como podemos aprender algo sobre o efeito *ceteris paribus* de  $x$  sobre  $y$ , mantendo todos os outros fatores constantes, se estamos ignorando todos os outros fatores?!



- Veremos que para obter estimadores confiáveis de  $\beta_0$  e  $\beta_1$ , precisaremos restringir a maneira como se relacionam o termo não-observável  $u$  e a variável explicativa  $x$
- Sem tal restrição, não é possível estimar o efeito *ceteris paribus*,  $\beta_1$ .
- Antes, vamos supor o seguinte sobre  $u$ :

$$\mathbf{E}(u) = 0 \quad (2)$$

- A hipótese (2) não diz nada sobre a relação entre  $u$  e  $x$
- Ela apenas faz uma afirmação sobre a distribuição dos fatores não-observáveis na população.

Relembrando a definição de covariância e de *coeficiente de correlação*...

### Covariância

Dados  $n$  pares de valores  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ , observações de duas variáveis  $X$  e  $Y$ , chamamos de *covariância* entre  $X$  e  $Y$  a

$$\text{cov}(X, Y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n}$$




### Coeficiente de Correlação

Chamamos de *coeficiente de correlação* entre  $X$  e  $Y$  a

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\text{dp}(X) \cdot \text{dp}(Y)},$$

onde  $\text{dp}(X)$  = desvio padrão de  $X$ , e  $\text{dp}(Y)$  = desvio padrão de  $Y$ .

$$-1 \leq \text{corr}(X, Y) \leq 1$$



- Vamos voltar à hipótese sobre a relação entre  $u$  e  $x$
- Para qualquer valor de  $x$ , podemos obter o valor esperado (ou médio) de  $u$  para aquela fatia da população descrita pelo valor de  $x$
- A hipótese crucial é que o valor médio de  $u$  não depende do valor de  $x$ . Podemos escrever isso como:

$$\mathbf{E}(u|x) = \mathbf{E}(u) = 0 \quad (3)$$

- A hipótese (3) diz que, para qualquer valor de  $x$ , a média dos fatores não-observáveis é a mesma e, portanto, deve igualar-se ao valor médio de  $u$  na população.
- A hipótese (3) é chamada **hipótese de média condicional zero**

- Vamos ver, por exemplo, o que a hipótese de média condicional zero acarreta no exemplo dos salários
- Para simplificar, vamos supor que  $u$  seja o mesmo que aptidão inata
- Então, (3) requer que o nível médio de aptidão seja o mesmo, independentemente dos anos de educação formal
- Por exemplo, se:
  - ▶  $E(\text{aptidao}|\text{educ} = 8)$  representa a aptidão média para o grupo de todas as pessoas com oito anos de educação formal, e
  - ▶  $E(\text{aptidao}|\text{educ} = 16)$  representa a aptidão média entre pessoas na população com 16 anos de educação formal
- Então (3) implica que essas médias devem ser as mesmas
- Se, por exemplo, entendemos que a aptidão média aumenta com os anos de educação formal, então (3) é falsa
  - ▶ Isso aconteceria se, em média, pessoas com maior aptidão escolhessem tornar-se mais escolarizadas

- Como não podemos observar aptidão inata, não temos um modo de saber se a aptidão média é ou não a mesma para todos os níveis de educação
- Essa é uma questão que devemos resolver antes de aplicar a análise de regressão simples
- No exemplo dos fertilizantes, se as quantidades de fertilizantes são escolhidas independentemente de outras características dos lotes, então (3) se sustentará
  - ▶ a qualidade média da terra não dependerá da quantidade de fertilizantes
- Entretanto, se mais fertilizantes forem usados em lotes de terra de melhor qualidade, então o valor esperado de  $u$  varia com o nível de fertilizantes, e (3) não se sustenta

## Questão

Suponha que a nota de um exame final (*nota*) dependa da frequência às aulas (*freq*) e de fatores não-observados que afetam o desempenho dos estudantes (tal como a aptidão). Então:

$$nota = \beta_0 + \beta_1 freq + u$$

Em que situação você espera que esse modelo satisfaça a hipótese de média condicional zero?

- Considerando o valor esperado de

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

condicionado a  $x$  are usando  $\mathbf{E}(u|x) = 0$ , obtém-se

$$\mathbf{E}(y|x) = \beta_0 + \beta_1 x$$

- A equação acima mostra que a função de regressão populacional,  $\mathbf{E}(y|x)$ , é uma função linear de  $x$ :
  - ▶ o aumento de uma unidade em  $x$  faz com que o valor esperado de  $y$  varie  $\beta_1$

- Para qualquer valor dado de  $x$ , a distribuição de  $y$  está centrada em  $\mathbf{E}(y|x)$ :

$\mathbf{E}(y|x)$  como função linear de  $x$

