

# Regressão Linear Simples – Aula 06a

Statistics for Business and Economics 7 edição, by Paul Newbold , William Carlson , Betty Thorne (cap. Simple Regression)

Bussab e Morettin (Cap 16 Regressão Linear Simples)

Statistics for Economics, Accounting and Business Studies, capítulo 7, Barrow (Correlation and Simple Regression)

Marislei Nishijima

# Econometria

- Consiste no desenvolvimento de métodos estatísticos para estimar relações econômicas, testar teorias, avaliar e implementar políticas de governo e de negócios.
- Foca problema de coleta de dados não experimentais

Campos de estudo assemelhados

- Sociometria
- Cliometria

# Passos para análise empírica

- Formulação cuidadosa da questão de interesse

Ex. Modelo de crime de Gary Becker (crimes têm recompensas econômicas, mas também custos)

$$y=f(x_1, x_2, x_3, x_4, x_5, x_6, x_7)$$

y horas gastas em atividades criminosas

x1 “salário” por hora ocupada em atividade criminosa

x2 salário hora em emprego legal

x3 renda de outras atividades não criminosas e não emprego legal

x4 probabilidade de ser capturado

x5 probabilidade de ser condenado caso seja capturado

x6 sentença esperada se condenado, e

x7 idade

# Tipos de dados

- **Dados de corte transversal:** indivíduos, empresas, cidades, estados e outras unidades tomados num único ponto do tempo.
- **Dados de série de tempo:** observações de uma variável (ou conjunto de variáveis) ao longo do tempo. Ex. Índice de Gini no Brasil, renda per capita do país.
- **Dados de cortes transversais agrupados:** exemplo suplemento de saúde da PNAD 1998 e 2003 com informações por indivíduos (340 mil indivíduos entrevistados).
- **Dados de Painel ou longitudinal:** vários indivíduos ou unidades (os mesmos) observados ao longo do tempo.

# Causalidade e a noção de Ceteris Paribus na análise econométrica

- Causalidade: encontrar uma simples relação entre duas ou mais variáveis pode ser sugestivo, mas é preciso determinar qual variável afeta (causa) qual.
- Ceteris Paribus: realiza-se alteração em  $x$  e verifica-se seu impacto sobre  $y$  quando todas as demais variáveis explicativas permanecem constantes.
- Veja Exemplos de correlação espúria:
- <https://www.tylervigen.com/spurious-correlations>

# Exemplos

- Mais policiais na rua reduz criminalidade?
- Medindo o retorno da educação: a maior escolaridade afeta positivamente o salário recebido?
- Qual o efeito dos novos fertilizantes sobre a agricultura?
- Qual o efeito do salário mínimo sobre o desemprego?

## *Medidas de Posição*

**Moda** é o elemento de maior frequência.

**Mediana** é o valor que divide um conjunto ordenado sequencialmente ao meio.

A **mediana**, ao contrário da média, **não é sensível a valores extremos.**

# Estimadores

- Média

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

- Variância

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$



# *Medidas de Dispersão*

## Variância

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

## Desvio-Padrão

$$\text{dp}(X) \equiv \sigma_X = \sqrt{\text{var}(X)}$$

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i \bar{X} + \bar{X}^2)$$

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n X_i^2 - \frac{1}{n} \sum_{i=1}^n 2X_i \bar{X} + \frac{1}{n} \sum_{i=1}^n \bar{X}^2$$

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X} \frac{1}{n} \sum_{i=1}^n X_i + \frac{1}{n} n\bar{X}^2$$

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X}^2 + \bar{X}^2$$

$$\text{var}(X) = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

Ou, em outras palavras:

$\text{var}(X) = \text{m\u00e9dia dos quadrados} - \text{quadrado da m\u00e9dia}$

# Relações entre variáveis

Covariância: mede a existência de associação linear entre 2 variáveis aleatórias

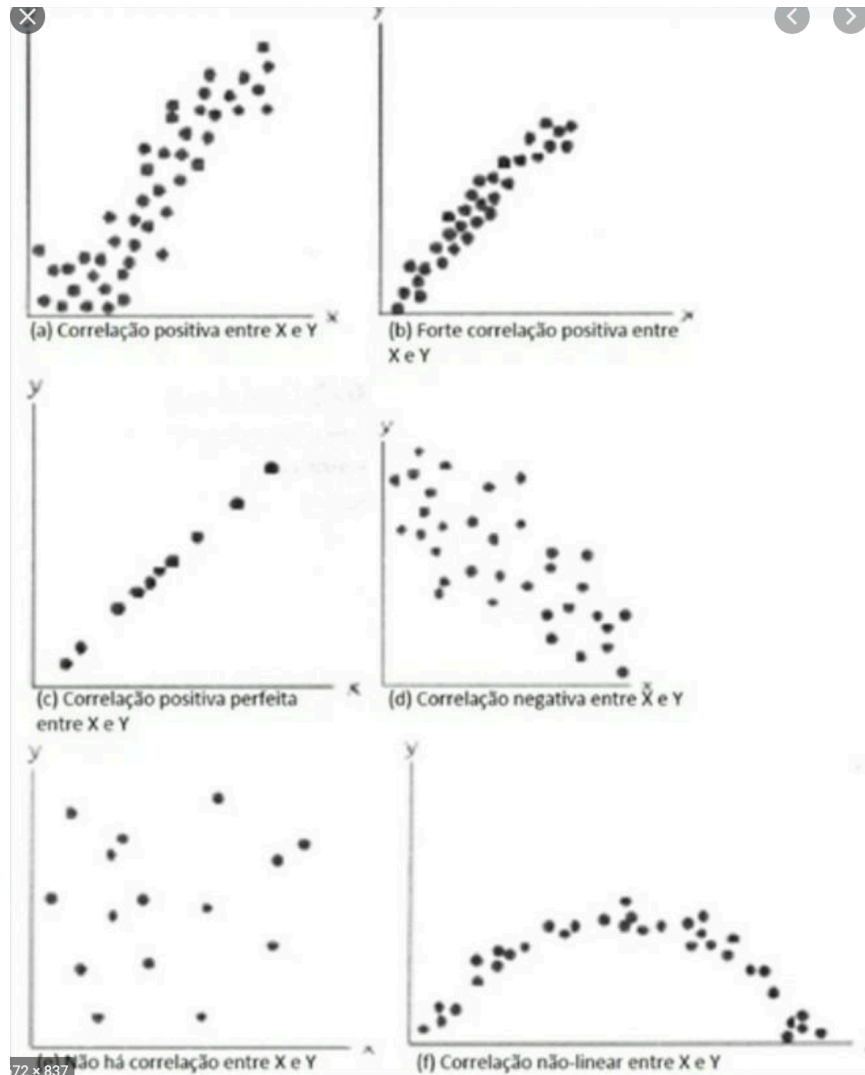
$$\text{covar}(X, Y) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

Coeficiente de correlação: valores entre -1 e 1

Mede a relação (grau de associação) linear entre as variáveis

$$\text{corr}(X, Y) \equiv \rho_{XY} = \frac{\text{covar}(X, Y)}{\text{dp}(X) \cdot \text{dp}(Y)}$$

# Exemplos de correlações



Sejam  $X$  e  $Y$  variáveis aleatórias (v.a.)

## Propriedades de variáveis aleatórias

$$\text{covar}(aX, bY) = a.b.\text{covar}(X, Y) \quad , \quad a \text{ e } b \text{ constantes}$$

$$\text{I) } \text{var}(aX) = a^2\text{var}(X)$$

$$\text{II) } \text{dp}(aX) = a.\text{dp}(X)$$

$$\text{III) } \text{var}(X+a) = \text{var}(X)$$

$$\text{IV) } \text{dp}(X+a) = \text{dp}(X)$$

V)  $\text{covar}(X, Y) = \text{média dos produtos} - \text{produto da média}$

$$\text{covar}(X, Y) = \frac{1}{n} \sum_{i=1}^n X_i Y_i - \bar{X}\bar{Y}$$

Sejam  $X$  e  $Y$  variáveis aleatórias (v.a.)

Propriedades de variáveis aleatórias

$$\text{VI) } \text{covar}(aX, bY) = a.b.\text{covar}(X, Y)$$

$$\text{VII) } \text{var}(X+Y) = \text{var}(X) + \text{var}(Y) + 2\text{covar}(X, Y)$$

$$\text{VIII) } \text{var}(X-Y) = \text{var}(X) + \text{var}(Y) - 2\text{covar}(X, Y)$$

Se  $X$  e  $Y$  independentes  $\text{covar}(X, Y)=0$

# Modelo de Regressão

- relação entre 2 variáveis  $X$  e  $Y$
- Quanto de  $Y$  pode ser explicado por  $X$ ?
- Nunca há relação exata entre  $X$  e  $Y$ , como considerar outros fatores que afetam  $X$ ?

## Equação Linear Simples

$$y = \beta_0 + \beta_1 X + \mu \quad \mu \sim N(0, \sigma)$$

$\mu$  → termo erro: representa outros fatores não observados, além de  $X$ , que afetam  $Y$

# Modelo de Regressão

Se outros fatores fixos  $\Delta\mu = 0$  então  $\Delta Y = \beta_1 \Delta X$

$\beta_1$  → Parâmetro de interesse (inclinação entre Y e X)

$\beta_0$  → Intercepto

Exemplo 1: Produção de Soja

Produção =  $\beta_0 + \beta_1 \cdot fertilizante + \mu$

Exemplo 2: Impacto da educação sobre rendimento

Salário =  $\beta_0 + \beta_1 \cdot educ + \mu$  (salário hora e número de anos de estudo)

$\beta_1$  → mede a variação no salário hora dado um ano a mais de educação, mantendo os demais fatores fixos.

$$y = \beta_0 + \beta_1 X + \mu \quad \mu \sim N(0, \sigma)$$



# Hipóteses do modelo de regressão

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

O valor médio de  $u$  não depende do valor de  $X$ .

Hipótese de média condicional zero

Exemplo:

Sob esta hipótese:  $E(\text{aptidão} | 8) = E(\text{aptidão} | 16)$

Ou seja, aptidão não muda com anos de educação.

$$E(u / X) = 0 \Rightarrow E(y / X) = \beta_0 + \beta_1 X$$

A função de regressão populacional,  $E(y/X)$ , é uma função linear de  $X$ : o valor esperado de  $y$  varia de acordo com a magnitude de  $\beta_1$ .

Para qualquer valor de  $X$ , a distribuição de  $y$  está centrada em  $E(y/X)$

Se  $E(u/X)=0$  vale:  $\beta_0 + \beta_1 X$  é a parte sistemática (explicada) de  $y$ ;

$u$  é a parte não sistemática (não explicada) de  $y$ .


$$y = \beta_0 + \beta_1 X + \mu \quad \mu \sim N(0, \sigma)$$

# Derivação dos Mínimos Quadrados Ordinários


De  $E(u / X) = E(u) = 0$ , sabe-se que  $E(u)=0 \Rightarrow E(y - \beta_0 - \beta_1 X) = 0$   
e  $\text{Cov}(X,u)=0 \Rightarrow E[X(y - \beta_0 - \beta_1 X)] = 0$

$$Y = \underbrace{\beta_0 + \beta_1 X}_{\text{Componente determinística}} + \underbrace{\mu}_{\text{Componente aleatória}}$$

$Y$  = variável dependente  
 $X$  = variável independente  
 $\mu$  = erro aleatório  
 $\beta_1$  = declive da linha  
 $\beta_0$  = ponto que intercepta o eixo  $y$



## Significado dos parâmetros do modelo de regressão linear simples



$\beta_0$  (intercepto); quando a região experimental inclui  $X=0$ ,  $\beta_0$  é o valor da média da distribuição de  $Y$  em  $X=0$ , cc, não tem significado prático como um termo separado (isolado) no modelo;  $\beta_1$  (inclinação) expressa a *taxa de mudança* em  $Y$ , isto é, é a mudança em  $Y$  quando ocorre a mudança de uma unidade em  $X$ . Ele indica a mudança na média da distribuição de probabilidade de  $Y$  por unidade de acréscimo em  $X$ .

# Derivação dos Mínimos Quadrados Ordinários

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

$$\text{Reescrevendo } \bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}, \text{ onde } \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \text{ e } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

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

Minimizando a soma dos resíduos quadrados:

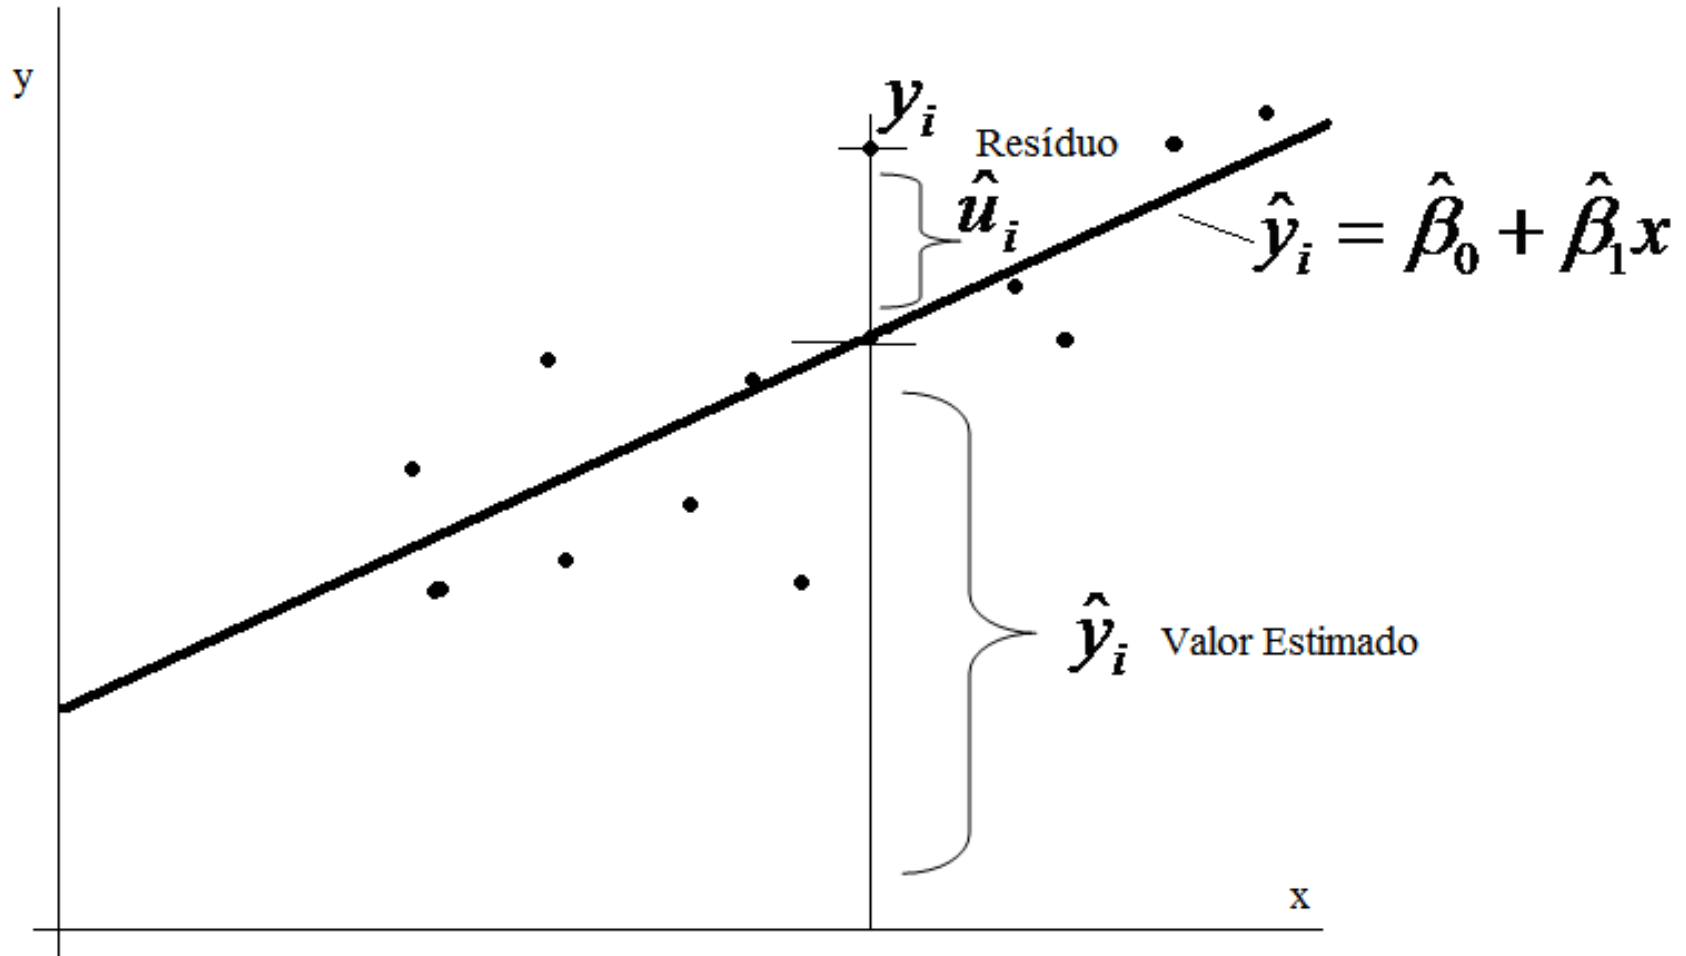
$$\min_{\beta_0, \beta_1} \sum_{i=1}^n \hat{u}_i^2$$

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

$$\text{Resulta em } \hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \hat{\beta}_1 = \frac{\text{Cov}(x, y)}{\text{Var}(x)}$$

# Derivação dos Mínimos Quadrados Ordinários

Importante: x deve ter variabilidade



# Resultado

Estimamos o modelo populacional:

$$y = \beta_0 + \beta_1 X + \mu \quad \mu \sim N(0, \sigma)$$

Usando uma amostra, por:

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

O resíduo  $\mu$  que é não observado  $\mu = y - \hat{y}$

pode ser estimado, então, por resíduo

como:  $\hat{\mu} = y - \hat{y}$

Então, os MQO minimizam o erro ao quadrado

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


A reta de Regressão de MQO

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x \quad (\text{amostral, pode apresentar valores}$$

diferentes conforme a amostra)

É a função de regressão amostral (FRA) estimada da função de regressão populacional

$$E(y / x) = \beta_0 + \beta_1 x \quad (\text{populacional, fixo e desconhecido})$$



(c) Médias alinhadas: distribuições normais e homocedásticas.

A figura mostra a distribuição de  $Y$  para vários valores de  $X$ . Mostra onde cai a observação  $Y_1$ . Mostra que o erro é a diferença entre  $Y_1$  e  $E(Y_1)$ . Observe que as distribuições de probabilidade apresentam a mesma variabilidade.



Exemplo: Salários de Diretores Executivos e Retornos de Ações

Modelo postulado a ser estimado:

$$\textit{salário} = \beta_0 + \beta_1 rma + u$$

y → salário anual em mil dólares: salário

x → retorno médio da ação sobre o patrimônio: rma

n = 209 observações

Modelo de Regressão de MQO:

$$\hat{\textit{salário}} = 963,191 + 18,501.rma$$

$$\hat{\beta}_0 = 963,191 \quad \hat{\beta}_1 = 18,501$$

Se a amostra mudar, pode-se obter outra reta

## Exemplo: Resultados Eleitorais e Gastos em Campanha

Modelo postulado a ser estimado:

$$votoA = \beta_0 + \beta_1 partA + u$$

y → percentagem de votos recebidos pelo candidato A: *votoA*

x → percentagem dos gastos totais de campanha que cabem ao candidato A: *partA*

n = 179 observações

Modelo de Regressão de MQO:

$$vo\hat{t}oA = 26,81 + 0,464 \cdot partA$$

$$\hat{\beta}_0 = 26,81 \quad \hat{\beta}_1 = 0,464$$

# 15 primeiras observações de Salários de Diretores Executivos e Retornos de Ações e valores estimados

n obs.	y=salário	x=rma	y chapéu	u chapéu
1	1095	14.1	1224.058	-129.058
2	1001	10.9	1164.854	-163.854
3	1122	23.5	1397.969	-275.969
4	578	5.9	1072.348	-494.348
5	1368	13.8	1218.508	149.492
6	1145	20	1333.215	-188.215
7	1078	16.4	1266.611	-188.611
8	1094	16.3	1264.761	-170.761
9	1237	10.5	1157.454	79.546
10	833	26.3	1449.773	-616.773
11	567	25.9	1442.372	-875.372
12	933	26.8	1459.023	-526.023
13	1339	14.8	1237.009	101.991
14	937	22.3	1375.768	-438.768
15	2011	56.3	2004.808	6.192

## Propriedades Algébricas de MQO

(1) A soma, e a média amostral, dos resíduos de MQO é zero

$$\sum_i^n \hat{u}_i = 0$$

(2) A covariância amostral entre os regressores e os resíduos de MQO é zero

$$\sum_i^n x_i \cdot \hat{u}_i = 0$$

## Outra interpretação de MQO

$y_i = \hat{y}_i + \hat{u}_i$ , a média amostral dos valores estimados,  $\hat{y}_i$ , é a mesma média amostral de  $y_i$ , ou seja  $\bar{y}_i$ .

$$\text{SQT} = \text{SQE} + \text{SQR}$$

Soma dos quadrados total = soma dos quadrados Explicada + Soma dos quadrados dos resíduos

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Grau de Ajuste: Mede o quanto a variável explicativa (x) mede a variável explicada (y)

R-quadrado da regressão :  $R^2$  é a percentagem da variação amostral em y que é explicada por x

$$R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT}$$

Então  $0 \leq R^2 \leq 1$

Se  $R^2 = 1$ , ajuste perfeito dos dados

Se  $R^2 \cong 0$ , ajuste ruim da reta de MQO

Exemplo1: Salários de Diretores Executivos e Retornos de Ações

$$\hat{sal\acute{a}rio} = 963,191 + 18,501.rma$$

$$n=209 \quad , R^2=0,0132$$

Vemos que a variação nos salários é pouco explicada pelo retorno das ações. O retorno das ações explica somente 1,3% das variações de salário desta amostra de 209 diretores executivos. Ou seja, 98,7% das variações salariais desses diretores são deixadas sem explicação.

Valores baixos são freqüentes nas ciências sociais

Exemplo2: resultados Eleitorais e Gastos de Campanha

$$\hat{vo\acute{t}oA} = 26,81 + 0,464.partA$$

$$n=179 \quad , R^2= 0,856$$

A participação nos gastos do candidato explica 85,6% dos votos eleitorais nesta pesquisa

## Unidades de Medida e Forma Funcional

Efeitos de mudança de medida da variável

Salário anual medido em mil dólares

$$\hat{sal\acute{a}rio} = 963,191 + 18,501.rma$$

Salário anual medido em dólares

$$\hat{sal\acute{a}rio} = 963191,00 + 18501.rma$$

Retorno da ação medido (percentual) dividido por 100

$$\hat{sal\acute{a}rio} = 963,191 + 1850,1.rma$$

## Unidades de Medida e Forma Funcional

### Incorporação de Não-Linearidade na Regressão

Muitas vezes é preciso considerar modelos não lineares

Exemplo: efeito da escolaridade sobre salário

ganhos crescentes de salários a cada ano adicional de estudo

$n = 526$ ,  $R^2 = 0,186$

$$saláριοh = \beta_0 + \beta_1 educ + u$$

$$\hat{saláριοh} = -0,9 + 0,54educ + u$$

Para cada ano adicional de escolaridade é previsto US\$0,54 a mais no salário hora (o que vale tanto para o 1º ano de educação quanto para o 20º)

$$\log(saláριοh) = \beta_0 + \beta_1 educ + u$$

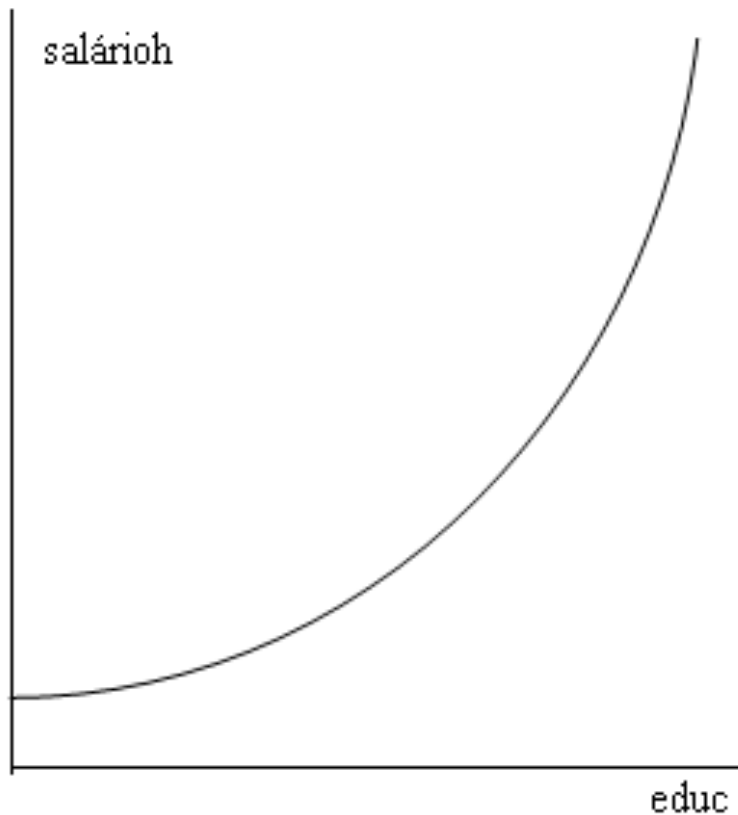
$$\% \Delta saláριοh \approx (100 \cdot \beta_1) \Delta educ$$

$$\log(\hat{saláριοh}) = 0,584 + 0,083 \cdot educ$$

O aumento percentual depende do valor inicial



$$\text{saláριο} = \exp(\beta_0 + \beta_1 \text{educ}) \text{ com } \beta_1 > 0$$



Note que

$$\log(y) = \beta_0 + \beta_1 x + u$$

pode ser reescrito como:

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

O método de estimação não muda. O que muda é a maneira como se usa a variável

# Significado de “Linear”

O modelo de regressão é linear nos parâmetros  $\beta_0$  e  $\beta_1$ . Pois é possível fazer transformações nas variáveis –  $\log X$ ,  $X^2$ ,  $X^{1/2}$ , etc.- e usar o método de MQO.

## Interpretação do coeficiente associado à variável explicativa X

Modelo	Variável dependente	Variável independente	Interpretação de $\beta_1$
nível-nível	y	x	$\Delta y = \beta_1 \cdot \Delta x$
nível-log	y	log(x)	$\Delta y = (\beta_1 / 100)\% \cdot \Delta x$
log-nível	log(y)	x	$\% \Delta y = (100 \beta_1) \cdot \Delta x$
log-log	log(y)	log(x)	$\% \Delta y = \beta_1 \cdot \% \Delta x$

## Valores Esperados e Variâncias dos Estimadores de MQO

Hipótese 1 (linearidade nos parâmetros): No modelo populacional, a variável dependente  $y$  está relacionada à variável independente  $x$  e ao erro  $u$  como:

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

### Hipótese 2 (amostragem aleatória)

Pode-se usar uma amostra aleatória de tamanho  $n$ ,  $\{(x_i, y_i) : i=1, 2, \dots, n\}$ , proveniente de um modelo populacional.

### Hipótese 3 (média condicional zero)

$$E(u/x)=0 \quad \text{ou} \quad E(y/x) = \beta_0 + \beta_1 x$$

3 e 2  $\Rightarrow$  tecnicamente tratar o  $x_i$  fixo em amostras repetidas.

### Hipótese 4 (variação amostral na variável independente)

Na amostra, as variáveis independentes  $x_i$ ,  $i=1, 2, \dots, n$  não são todas iguais a uma mesma constante. Isso exige uma variação em  $x$  na população.

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

Vemos que  $\hat{\beta}_1$  é uma variável aleatória.

Reescrevendo: 
$$\hat{\beta}_1 = \beta_1 + \frac{\sum_{i=1}^n (x_i - \bar{x})u_i}{SQT_x} = \beta_1 + (1/SQT_x) \sum_{i=1}^n d_i \cdot u_i$$
 em que  $d_i = x_i - \bar{x}$

Condicionada aos valores de  $x_i$ , a aleatoriedade em  $\hat{\beta}_1$  depende dos erros,  $u_i$ . O fato de que os erros sejam, em geral, diferentes de zero é que faz com que  $\hat{\beta}_1$  seja diferente de  $\beta_1$ .

**Teorema 1: As Hipóteses de 1 até 4 garantem a inexistência de viés em MQO :**

$$E(\hat{\beta}_0) = \beta_0 \text{ e } E(\hat{\beta}_1) = \beta_1$$

## Preocupações com a Hipótese 3, $E(u/x)=0$

Usar a regressão simples quando  $u$  contém fatores que afetam  $y$  e que também estão correlacionados com  $x$  pode resultar em correlação **espúria** (uma relação entre  $x$  e  $y$  que se deve a outros valores que afetam  $y$  e também são correlacionados com  $x$ )

Exemplo: efeito da merenda sobre o desempenho escolar

$$mate10 = \beta_0 + \beta_1 prgalm + u$$

$y$  = % de alunos do primeiro ano do ensino médio aprovados num exame de matemática: *mate10*

$x$  = % de estudantes aptos para participar do programa de merenda escolar: *prgalm*

$u$  possui característica da escola e do aluno que afetam o desempenho escolar total.

$$\hat{mate10} = 32,14 + 0,319 prgalm$$

n=408, R<sup>2</sup>=0,171

Devemos aceitar que a maior participação na merenda piora o desempenho escolar? Muito provavelmente não.

Explicação: o termo erro, u, está correlacionado com prgalm (u contém fatores como taxa de pobreza das crianças que freqüentam a escola, qualidade e recursos da escola, que estão correlacionados com y (desempenho) e com x (elegibilidade ao programa de merenda)) [caracterizando um problema de variável relevante omitida].

## Variância dos Estimadores de MQO

Além de saber que a distribuição amostral de  $\hat{\beta}_1$  está centrada em torno de  $\beta_1$  ( $\hat{\beta}_1$  é não viesado), é preciso saber quão distante, em média,  $\hat{\beta}_1$  está de  $\beta_1$ .

MQO oferecem o estimador com menor variância entre os estimadores lineares.

Hipótese 5 de Homoscedasticidade ou de variância constante:

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

Implica que os estimadores de MQO são eficientes



## Exemplo de heteroscedasticidade na equação de salários

$$\textit{saláριο}h = \beta_0 + \beta_1 \textit{educ} + u$$

Pessoas com maior nível de educação têm maiores possibilidades de emprego, o salário pode variar bastante. Pessoas com baixa escolaridade em geral trabalham pelo valor do salário mínimo, portanto apresentam menor variância de ganhos.

Variâncias amostrais em MQO sob as hipóteses de 1 a 5

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2} = \sigma^2 / SQT_x$$

$$\text{Var}(\hat{\beta}_0) = \frac{\sigma^2 n^{-1} \sum_{i=1}^n x_i^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

## Estimação da Variância do Erro

As fórmulas anteriores de variância dos estimadores são desconhecidas, a menos que  $\sigma^2$  seja conhecido. Por isso é necessário estimá-las.

$y_i = \beta_0 + \beta_1 x_i + u_i$  modelo populacional descrito em termos de uma observação extraída aleatoriamente, em que  $u_i$  é o erro da observação.

$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + \hat{u}_i$  modelo estimado,  $\hat{u}_i$  é o resíduo.

$$\hat{u}_i = y_i - \hat{y}_i = \beta_0 + \beta_1 x_i + u_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)$$

Resíduo é a “estimativa” do erro.

Como  $u_i$  é não observado e  $\hat{u}_i$  é observado (calculado),

Usamos  $\hat{u}_i = y_i - \hat{y}_i$  para calcular a variância do erros

$$\hat{\sigma}^2 = \frac{1}{(n-2)} \sum_{i=1}^n \hat{u}_i^2 \quad \text{que é um estimador não viesado}$$

dos erros de MQO.

(perde-se 2 graus de liberdade por causa das restrições  $\sum_{i=1}^n \hat{u}_i = 0$  e

$$\sum_{i=1}^n x_i \cdot \hat{u}_i = 0)$$

Sob as hipóteses 1 até 5  $E(\hat{\sigma}^2) = \sigma^2$