

AULA 01

Introdução & Modelo de regressão simples

Ernesto F. L. Amaral

15 de julho de 2013

Análise de Regressão Linear (MQ 2013)

www.ernestoamaral.com/mq13reg.html

Fonte:

**Wooldridge, Jeffrey M. “Introdução à econometria: uma abordagem moderna”. São Paulo:
Cengage Learning, 2008. Capítulo 1 (1-17) e Capítulo 2 (pp.19-63).**

ESTRUTURA DO LIVRO

- **Introdução:** principais conceitos em econometria (capítulo 1).
- **Parte 1:** trata de análise de regressão com dados de corte transversal (capítulos 2 ao 9).
- **Parte 2:** análise de regressão com dados de séries temporais (capítulos 10 ao 12).
- **Parte 3:** tópicos avançados (capítulos 13 ao 19).

DOCUMENTAÇÃO DO LIVRO

– UCLA Academic Technology Services:

<http://www.ats.ucla.edu>

– Introductory Econometrics: A Modern Approach
by Jeffrey M. Wooldridge:

<http://fmwww.bc.edu/gstat/examples/wooldridge/wooldridge.html>

DOCUMENTAÇÃO PARA EXERCÍCIO

- Vamos utilizar a Pesquisa Nacional por Amostra de Domicílios (PNAD) de 2007 de Minas Gerais para as demonstrações em sala de aula e a PNAD de 2011 do Brasil para o exercício final do curso.
- Os bancos de dados, questionário, livro de códigos e demais arquivos estão disponíveis no site do Instituto Brasileiro de Geografia e Estatística (IBGE):

<http://www.ibge.gov.br/home/estatistica/populacao/trabalhoerendimento/pnad2011/microdados.shtm>

CAPÍTULO 1 - WOOLDRIDGE
INTRODUÇÃO:
PRINCIPAIS CONCEITOS EM ECONOMETRIA

ECONOMETRIA

- A econometria evoluiu como uma disciplina separada da estatística matemática, porque enfoca problemas inerentes à coleta e à análise de dados econômicos não-experimentais.
- **Dados não-experimentais** não são acumulados por meio de experimentos controlados de indivíduos, firmas ou segmentos da economia.
- Dados não-experimentais são também chamados de **dados observacionais** para enfatizar o fato de que o pesquisador é um coletor passivo de dados.
- **Dados experimentais** são frequentemente coletados em ambientes de laboratório nas ciências naturais, mas são muito mais difíceis de serem obtidos nas ciências sociais.
- O método de análise da **regressão múltipla** é utilizado por econometristas e estatísticos matemáticos, mas o foco e interpretação pode diferir significativamente.

ANÁLISE ECONÔMICA EMPÍRICA

- Os métodos econométricos são usados para testar uma teoria econômica ou para analisar relações que apresentam importância para análises de políticas públicas.
- Uma análise empírica usa dados para testar uma teoria ou estimar uma relação.
- O primeiro passo em qualquer análise empírica é a formulação cuidadosa da questão de interesse, a qual pode ser a de testar efeitos de uma política governamental ou, até mesmo, de testar hipóteses e teorias.
- O modelo econômico formal consiste em equações matemáticas que descrevem relações para testar teorias.

MICROECONOMIA

- Os indivíduos fazem escolhas para maximizar seu bem-estar (**maximização da utilidade**), sujeitas às restrições de recursos.
- Isso oferece um arcabouço para criar modelos econômicos para fazer previsões entre variáveis.
- A maximização da utilidade leva a um conjunto de **equações de demanda**, no contexto das decisões de consumo.
- Em uma equação de demanda, a quantidade demandada de cada produto depende do seu próprio preço, do preço dos bens substitutos e complementares, da renda do consumidor e das características individuais que influem no gosto.

MODELO ECONÔMICO

- O modelo econômico é a formulação teórica de uma relação entre variáveis econômicas.
- A quantidade de tempo gasto na atividade criminosa é uma função de vários fatores (Gary Becker 1968):

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

y = horas gastas em atividades criminosas.

x_1 = “salário” por hora ocupada em atividade criminosa.

x_2 = salário-hora em emprego legal.

x_3 = renda de outras atividades que não o crime ou um emprego legal.

x_4 = probabilidade de ser capturado.

x_5 = probabilidade de ser condenado se capturado.

x_6 = sentença esperada se condenado.

x_7 = idade.

MODELO ECONOMÉTRICO

- Após elaborar o modelo econômico, é especificado um modelo econométrico, que será aplicado a dados existentes.
- A forma da função $f(.)$ deveria ser especificada antes de realizar uma análise econométrica.
- Se uma variável não pode ser obtida, é possível utilizar uma variável que se aproxima desta que se quer medir (**proxy**).
- Outros fatores são considerados no termo de erro u (ou termo de perturbação):
 - **Erro amostral** é a diferença entre o resultado amostral e o verdadeiro resultado da população (devidos ao acaso).
 - **Erro não-amostral** ocorre quando os dados amostrais são coletados, registrados ou analisados incorretamente.
- Modelo econométrico de Becker (1968):

$$\textit{crime} = \beta_0 + \beta_1 \textit{salário} + \beta_2 \textit{outrenda} + \beta_3 \textit{freqpris} + \beta_4 \textit{freqcond} + \beta_5 \textit{sentmed} + \beta_6 \textit{idade} + u$$

MODELO ECONOMÉTRICO NA PRÁTICA

- Na maioria dos casos, a análise econométrica começa pela especificação de um modelo econométrico, sem consideração de detalhes da criação do modelo econômico.
- É comum começar com um modelo econométrico e usar o raciocínio econômico e conhecimentos científicos como guias para escolher as variáveis.
- Após a especificação do modelo econométrico, várias hipóteses podem ser formuladas em termos das direções e influências dos parâmetros desconhecidos (independentes) sobre a variável de interesse (dependente).
- Após os dados terem sido coletados, os métodos econométricos são usados para estimar os parâmetros do modelo econométrico e para testar as hipóteses de interesse.

DESENHOS BÁSICOS DE *SURVEY*: BANCOS DE DADOS

- Após especificar os objetivos e unidades de análise da pesquisa, é preciso escolher entre diversos desenhos diferentes:
 - *Surveys* interseccionais (*cross-sectional*).
 - *Surveys* longitudinais (tendências, coortes ou painel).
 - *Surveys* interseccionais servindo como longitudinais.
- Wooldridge (2008) classifica os dados econômicos em:
 - Dados de corte transversal = *surveys* interseccionais.
 - Cortes transversais agrupados = estudos de tendências.
 - Dados de séries de tempo = estudos de coortes.
 - Dados de painel ou longitudinais = estudos de painel.

DADOS DE CORTE TRANSVERSAL (Wooldridge)

SURVEYS INTERSECCIONAIS (Babbie)

- Um conjunto de dados de corte transversal consiste em uma amostra de uma unidade de análise, tomada em um determinado ponto no tempo.
- Esses dados são muito utilizados em economia e em outras ciências sociais.
- Dados em um determinado ponto do tempo são importantes para testar hipóteses e avaliar políticas.
- Dados podem ter problemas de seleção amostral, no caso de determinados indivíduos não revelarem informações acuradas.
- Amostragem deve ser realizada de forma acurada para evitar que coleta se concentre em unidades com características semelhantes.

EXEMPLO DE DADOS DE CORTE TRANSVERSAL

– Conjunto de dados de corte transversal para o ano de 1976 de 526 trabalhadores (Wooldridge 2008):

| Número da observação | Salário por hora | Anos de escolaridade | Anos de experiência no mercado de trabalho | Feminino | Estado civil (casado) |
|----------------------|------------------|----------------------|--|----------|-----------------------|
| 1 | 3,10 | 11 | 2 | 1 | 0 |
| 2 | 3,24 | 12 | 22 | 1 | 1 |
| 3 | 3,00 | 11 | 2 | 0 | 0 |
| 4 | 6,00 | 8 | 44 | 0 | 1 |
| 5 | 5,30 | 12 | 7 | 0 | 1 |
| ... | ... | ... | ... | ... | ... |
| 525 | 11,56 | 16 | 5 | 0 | 1 |
| 526 | 3,50 | 14 | 5 | 1 | 0 |

CORTES TRANSVERSAIS AGRUPADOS (Wooldridge)

ESTUDOS DE TENDÊNCIAS (Babbie)

- Uma população pode ser amostrada e estudada em ocasiões diferentes.
- Um mesmo conjunto de variáveis é coletado em diferentes períodos do tempo, em **distintas** amostras aleatórias de uma mesma população (Censo Demográfico, Pesquisa Nacional por Amostra de Domicílios – PNAD).
- Agrupar cortes transversais de diferentes anos é eficaz para analisar os efeitos de uma política pública.
- O ideal é coletar dados de anos anteriores e posteriores a uma importante mudança de política governamental.
- Além de aumentar o tamanho da amostra, a análise de corte transversal agrupada é importante para estimar como uma relação fundamental mudou ao longo do tempo.
- Geralmente são utilizados dados secundários, coletados por outros pesquisadores ou instituições.

EXEMPLO DE CORTES TRANSVERSAIS AGRUPADOS

– Conjunto de dados sobre os preços da moradia em 1993 e 1995 nos Estados Unidos (Wooldridge 2008):

| Número da observação | Ano | Preço comercializado | Impro | Arquad | Quantidade de dormitórios | Quantidade de banheiros |
|----------------------|------|----------------------|-------|--------|---------------------------|-------------------------|
| 1 | 1993 | 85.500 | 42 | 1.600 | 3 | 2,0 |
| 2 | 1993 | 67.300 | 36 | 1.440 | 3 | 2,5 |
| 3 | 1993 | 134.000 | 38 | 2.000 | 4 | 2,5 |
| ... | ... | ... | ... | ... | ... | ... |
| 250 | 1993 | 243.600 | 41 | 2.600 | 4 | 3,0 |
| 251 | 1995 | 65.000 | 16 | 1.250 | 2 | 1,0 |
| 252 | 1995 | 182.400 | 20 | 2.200 | 4 | 2,0 |
| 253 | 1995 | 97.500 | 15 | 1.540 | 3 | 2,0 |
| ... | ... | ... | ... | ... | ... | ... |
| 520 | 1995 | 57.200 | 16 | 1.100 | 2 | 1,5 |

DADOS DE SÉRIES DE TEMPO (Wooldridge)

ESTUDOS DE COORTES (Babbie)

- Um conjunto de dados de séries de tempo consiste em observações sobre variáveis ao longo do tempo.
- Como eventos passados podem influenciar eventos futuros, o tempo é uma dimensão importante em um conjunto de dados de séries de tempo.
- A análise desses dados pode ser dificultada, porque observações econômicas não são independentes ao longo do tempo (variáveis possuem padrões sazonais).
- Há uma série de frequências possíveis: diárias, semanais, mensais, trimestrais, anuais, decenais...
- Estes dados são também chamados de estudos de coorte, em que mesma população é analisada, mas amostras estudadas podem ser diferentes:
 - Pessoas com 10 anos em 2000, 20 anos em 2010, 30 anos em 2020, 40 anos em 2030...

EXEMPLO DE DADOS DE SÉRIES DE TEMPO

– Conjunto de dados de séries de tempo sobre efeitos do salário mínimo em Porto Rico (apud Wooldridge 2008):

| Número da observação | Ano | Salário mínimo médio no ano | Taxa de trabalhadores cobertos pela lei de salário mínimo | Taxa de desemprego | Produto Nacional Bruto (PNB) |
|----------------------|------|-----------------------------|---|--------------------|------------------------------|
| 1 | 1950 | 0,20 | 20,1 | 15,4 | 878,7 |
| 2 | 1951 | 0,21 | 20,7 | 16,0 | 925,0 |
| 3 | 1952 | 0,23 | 22,6 | 14,8 | 1.015,9 |
| ... | ... | ... | ... | ... | ... |
| 37 | 1986 | 3,35 | 58,1 | 18,9 | 4.281,6 |
| 38 | 1987 | 3,35 | 58,2 | 16,8 | 4.496,7 |

DADOS DE PAINEL OU LONGITUDINAIS (Wooldridge) ESTUDOS DE PAINEL (Babbie)

- Um conjunto de dados de painel consiste em uma série de tempo para **cada** membro do corte transversal.
- Os dados de painel são distintos dos dados de corte transversal agrupados (tendências) e de séries de tempo (coortes), porque as **mesmas** unidades são acompanhadas ao longo de um determinado período.
- Dados de painel podem ser coletados para indivíduos, domicílios, instituições ou unidades geográficas.
- Esses dados são os mais sofisticados para fins explicativos, mas são mais difíceis e caros de se obter.
- Pode haver problema de grande número de não respostas nas últimas ondas de entrevistas.
- A análise dos dados pode se tornar complicada quando se tentar avaliar as mudanças dos indivíduos no tempo.

EXEMPLO DE DADOS DE PAINEL OU LONGITUDINAIS

- Conjunto de dados de painel sobre crime e estatísticas relacionadas em 1986 e 1990 em 150 cidades nos Estados Unidos (Wooldridge 2008):

| Número da observação | Cidade | Ano | Homicídios | População | Desemprego | Polícia |
|----------------------|--------|------|------------|-----------|------------|---------|
| 1 | 1 | 1986 | 5 | 350.000 | 8,7 | 440 |
| 2 | 1 | 1990 | 8 | 359.200 | 7,2 | 471 |
| 3 | 2 | 1986 | 2 | 64.300 | 5,4 | 75 |
| 4 | 2 | 1990 | 1 | 65.100 | 5,5 | 75 |
| ... | ... | ... | ... | ... | ... | ... |
| 297 | 149 | 1986 | 10 | 260.700 | 9,6 | 286 |
| 298 | 149 | 1990 | 6 | 245.000 | 9,8 | 334 |
| 299 | 150 | 1986 | 25 | 543.000 | 4,3 | 520 |
| 300 | 150 | 1990 | 32 | 546.200 | 5,2 | 493 |

CORTE TRANSVERSAL USADO COMO LONGITUDINAL

- Alguns mecanismos podem ser utilizados num *survey* interseccional (corte transversal) para aproximar o estudo de processo ou mudança (longitudinal).
- Podem ser realizadas perguntas referentes ao passado (renda no ano anterior, local de residência anterior):
 - Há problemas de erro de memória.
 - Os dados devem ser interpretados como amostra da população atual, e não de população passada.
- Por exemplo, é possível utilizar um único banco de dados de corte transversal para comparar pessoas de diferentes idades (jovens e idosos) e coortes (calouros e veteranos).

VARIAÇÕES DOS DESENHOS BÁSICOS

- Os desenhos básicos de pesquisa apresentados anteriormente podem ser modificados para se enquadrarem aos objetivos de um estudo:
 - **Amostras paralelas:** amostras separadas de populações diferentes, utilizando mesmo questionário (exemplo é a pesquisa sobre preconceito na UFMG).
 - **Estudos contextuais:** uso de dados sobre o ambiente ou meio da pessoa para descrever o contexto do indivíduo.
 - **Estudos sociométricos:** intenção é de observar as inter-relações entre membros da população estudada (redes de amizades, por exemplo).

ESCOLHENDO O DESENHO APROPRIADO

- **Dados de corte transversal** são mais apropriados se objetivo é descrição de tempo único.
- **Mudanças ao longo do tempo** são mais difíceis de realizar, porque dados de painel exigem tempo e recursos:
 - É possível utilizar dados de corte transversal e comparar pessoas que passaram por uma experiência no passado, com aqueles que não passaram.
- **Estudos de painel** são mais viáveis economicamente quando o fenômeno estudado tem duração curta (por exemplo, opinião de voto durante uma campanha eleitoral).
- **Estudos de tendências** podem ser realizados quando dados antigos são complementados com dados coletados pelo pesquisador.

CAUSALIDADE

- Na avaliação de políticas públicas, o objetivo do pesquisador é inferir que uma variável tem um **efeito causal** sobre outra variável.
- Encontrar uma associação entre duas ou mais variáveis pode ser sugestivo (correlação), mas somente será convincente se for possível estabelecer uma causalidade.
- A noção de ***ceteris paribus*** é importante, já que significa “outros fatores (relevantes) permanecendo iguais”.
- Se outros fatores não forem mantidos fixos, não poderemos conhecer o efeito causal de uma variável sobre outra.
- Como a maioria dos dados coletados nas ciências sociais são não-experimentais (não são experimentos controlados como nas ciências naturais), descobrir relações causais é uma tarefa complexa.

CAPÍTULO 2 - WOOLDRIDGE

MODELO DE REGRESSÃO SIMPLES

MODELO DE REGRESSÃO SIMPLES

- O modelo de regressão linear simples explica uma variável (y) com base em modificações em outra variável (x).
- Ou seja, é usado para avaliar a relação entre duas variáveis.
- Esse tipo de regressão não é muito utilizada em ciências sociais aplicadas, devido à sua simplicidade.
- No entanto, serve como ponto de partida, já que sua álgebra e interpretações são fáceis de entender.
- O entendimento do modelo de regressão simples é importante para estudar a regressão múltipla.

PREMISSA E EXEMPLOS

- Premissa da análise econométrica:
 - y e x são duas variáveis que representam uma população.
 - Estamos interessados em explicar y em termos de x .
 - Ou seja, queremos estudar como y varia com variações em x .

- Exemplos:
 - y é o rendimento do trabalhador, e x são os anos de escolaridade.
 - y é a escala ideológica esquerda/direita, e x é o partido político do deputado.
 - y é o índice de tradicionalismo/secularismo, e x é o nível de escolaridade.

PERGUNTAS IMPORTANTES

- Como nunca há uma relação exata entre duas variáveis, como consideramos outros fatores que afetam y ?
- Qual é a relação funcional entre y e x ?
- Como podemos estar certos de que estamos capturando uma relação *ceteris paribus* (outros fatores constantes) entre y e x ?

MODELO DE REGRESSÃO LINEAR SIMPLES

- Também chamado de modelo de regressão linear de duas variáveis ou modelo de regressão linear bivariada.

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

- Terminologia:

| y | x | Uso |
|----------------------|-----------------------|------------------------|
| Variável Dependente | Variável Independente | Econometria |
| Variável Explicada | Variável Explicativa | |
| Variável de Resposta | Variável de Controle | Ciências Experimentais |
| Variável Prevista | Variável Previsora | |
| Regressando | Regressor | |
| | Covariável | |

VOLTANDO ÀS PERGUNTAS IMPORTANTES

- Como nunca há uma relação exata entre duas variáveis, como consideramos outros fatores que afetam y ?
 - Variável u é o termo erro ou perturbação da relação.
 - Na análise de regressão simples, todos fatores (além de x) que afetam y são tratados como não-observados.

OUTRA PERGUNTA

– Qual é a relação funcional entre y e x ?

- Se os outros fatores em u são mantidos fixos, de modo que a variação em u é zero ($\Delta u=0$), então x tem um efeito linear sobre y , tal como: $\Delta y=\beta_1\Delta x$; se $\Delta u=0$.
- A linearidade do modelo de regressão linear simples implica que uma variação de uma unidade em x tem o mesmo efeito sobre y , independentemente do valor inicial de x .
- Isso não é realista. Por exemplo, o próximo ano de escolaridade teria um efeito maior sobre os salários, em relação ao anterior. Esse problema será tratado adiante.

E O PROBLEMA DO *CETERIS PARIBUS*?

- Estamos capturando uma relação *ceteris paribus* (outros fatores constantes) entre y e x ?
 - A variação em y é β_1 multiplicado pela variação em x .
 - β_1 : **parâmetro de inclinação** da relação entre y e x , mantendo fixos os outros fatores em u .
 - β_0 : **parâmetro de intercepto** é raramente analisado.
 - β_1 mede o efeito de x sobre y , mantendo todos os outros fatores (em u) fixos.
 - No entanto, estamos ignorando todos os outros fatores.
 - Os estimadores de β_0 e β_1 serão confiáveis em uma amostra aleatória, se o termo não-observável (u) estiver relacionado à variável explicativa (x) de modo que o valor médio de u na população seja zero: $E(u)=0$.

HIPÓTESE SOBRE A RELAÇÃO ENTRE x E u

- Se u e x não estão correlacionados, então (como variáveis aleatórias) não são linearmente relacionados.
- No entanto, a correlação mede somente a dependência linear entre u e x .
- Na correlação, é possível que u seja não-correlacionado com x e seja correlacionado com funções de x , tal como x^2 .
- Melhor seria pensar na distribuição condicional de u , dado qualquer valor de x .
- Para um valor de x , podemos obter o valor esperado (ou médio) de u para um grupo da população.
- A hipótese é que o valor médio de u não depende de x :

$$E(u|x) = E(u) = 0$$

- Ou seja, para qualquer valor de x , a média dos fatores não-observáveis é a mesma e, portanto, é igual ao valor médio de u na população (**hipótese de média condicional zero**).

FUNÇÃO DE REGRESSÃO POPULACIONAL


- Quando $E(u|x)=E(u)=0$ é verdadeiro, é útil dividir y em:
 - Parte sistemática (parte de y explicada por x): $\beta_0 + \beta_1 x$
 - Parte não-sistemática (parte de y não explicada por x): u
- Considerando o valor esperado de $y=\beta_0+\beta_1 x+u$ condicionado a x , e usando $E(u|x)=0$, temos a **função de regressão populacional** (FRP), que é uma função linear de x :

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

- **Linearidade**: o aumento de uma unidade em x faz com que o valor esperado de y varie segundo a magnitude de β_1 .
- Para qualquer valor de x , a distribuição de y está centrada ao redor de $E(y|x)$.

Figura 2.1

$E(y/x)$ como função linear de x .



ESTIMATIVA DE MÍNIMOS QUADRADOS ORDINÁRIOS

- Para a estimação dos parâmetros β_0 e β_1 , é preciso considerar uma amostra da população:

$$\{(x_i, y_i): i=1, \dots, n\}$$


- A equação do modelo de regressão simples é escrito como:

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

- u_i é o termo erro para a observação i , já que contém todos os fatores, além de x_i , que afetam y_i .
- Um exemplo é a poupança anual para a família i (y_i), dependendo da renda anual desta família (x_i), em um determinado ano.

Figura 2.2

Gráfico da dispersão de poupança e renda de 15 famílias e a regressão populacional $E(\text{poup}|\text{renda}) = \beta_0 + \beta_1 \text{renda}$.



ESTIMATIVA DE MÍNIMOS QUADRADOS ORDINÁRIOS

- Como obter estimativas do intercepto (β_0) e da inclinação (β_1) na regressão populacional da poupança sobre a renda?
- Na população, u tem média zero. O valor esperado de u é zero: $E(u)=0$
- Além disso, u é não-correlacionado com x . A covariância entre x e u é zero: $Cov(x,u)=E(xu)=0$
- $E(u)=0$ pode ser escrita como: $E(y-\beta_0-\beta_1x)=0$
- $Cov(x,u)=E(xu)=0$ pode ser escrita como: $E[x(y-\beta_0-\beta_1x)]=0$
- Como há dois parâmetros desconhecidos para estimar (β_0 e β_1), é possível utilizar uma amostra de dados para calcular as estimativas:

$$\hat{\beta}_0 \quad \text{e} \quad \hat{\beta}_1$$

EQUAÇÕES DA POPULAÇÃO E AMOSTRA

– Média de u na população:

$$E(y - \beta_0 - \beta_1 x) = 0$$

– Média de u na amostra:

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

– Covariância entre x e u na população:

$$E[x(y - \beta_0 - \beta_1 x)] = 0$$

– Covariância entre x e u na amostra:

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

ESTIMATIVAS DE $\hat{\beta}_0$ E $\hat{\beta}_1$

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

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n}$$

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

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

ESTIMATIVAS DE MQO DE $\hat{\beta}_0$ E $\hat{\beta}_1$

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

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

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



$$\hat{\beta}_1 = \frac{\text{Covariância amostral entre x e y}}{\text{Variância amostral de x}}$$


- Se x e y são positivamente correlacionados na amostra, $\hat{\beta}_1$ é positivo e vice-versa.

VARIÂNCIA DE x DEVE SER MAIOR QUE ZERO

- A hipótese necessária para calcular estimativas de mínimos quadrados ordinários (MQO) é que a variância amostral de x seja maior que zero.
- Ou seja, os valores de x_i na amostra não devem ser todos iguais a um mesmo valor.

Figura 2.3

Gráfico da dispersão de salários e educação, quando $educ_i = 12$ para todo i .



VALORES ESTIMADOS E RESÍDUOS

- Encontrados o intercepto e a inclinação, teremos um valor estimado para y para cada observação (x) na amostra:


$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

- O resíduo é a diferença entre o valor verdadeiro de y_i e seu valor estimado:

$$\hat{u}_i = y_i - \hat{y}_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i$$

Figura 2.4

Valores estimados e resíduos.



MINIMIZANDO A SOMA DOS RESÍDUOS QUADRADOS

- Suponha que escolhemos o intercepto e a inclinação estimados com o propósito de tornar a soma dos resíduos quadrados:

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

- O nome “mínimos quadrados ordinários” é utilizado porque as estimativas do intercepto e da inclinação minimizam a soma dos resíduos quadrados.
- Não é utilizada a minimização dos valores absolutos dos resíduos, porque a teoria estatística para isto seria muito complicada.

MINIMIZANDO A SOMA DOS RESÍDUOS QUADRADOS

- Reta de regressão de MQO ou função de regressão amostral (FRA) é a versão estimada da função de regressão populacional (FRP):

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

- O coeficiente de inclinação indica o quanto o valor estimado (previsto) de y varia quando x aumenta em uma unidade:


$$\hat{\beta}_1 = \Delta \hat{y} / \Delta x$$

- Da mesma forma, dada qualquer variação em x , podemos calcular a variação prevista em y :

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

Figura 2.5

A reta de regressão de MQO $\hat{\text{salário}} = 963,191 + 18,501 rma$ e a função de regressão populacional (desconhecida).









Figure 2.10 “All clear” e -versus- \hat{Y} plot (artificial data).




Influential Case



Curvilinear Relation



Nonnormal Residual Distribution



Heteroscedasticity

Figure 2.11 Examples of trouble seen in e -versus- \hat{Y} plots (artificial data).

PROPRIEDADES ALGÉBRICAS DAS ESTATÍSTICAS

- A soma dos resíduos de MQO é zero, já que as estimativas de MQO de $\hat{\beta}_0$ e $\hat{\beta}_1$ são escolhidas para fazer com que a soma dos resíduos seja zero:

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

- A covariância amostral entre os regressores e os resíduos de MQO é zero:

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

- Se inserirmos a média de x no lugar de x_i , o valor estimado é a média de y (este ponto está sempre sobre a reta):

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

SOMAS DOS QUADRADOS

- Soma dos quadrados total (SQT) é uma medida da variação amostral total em y_i (mede a dispersão dos y_i na amostra):

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

- Soma dos quadrados explicada (SQE) mede a variação amostral em:

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

- Soma dos quadrados dos resíduos (SQR) mede a variação amostral em:

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

- Variação total em y é a soma da variação explicada e da variação não-explicada:

$$SQT = SQE + SQR$$

GRAU DE AJUSTE

- Visa mensurar o quanto a variável independente (x) explica a variável dependente (y).
- É um número que resume o quão bem a reta de regressão de MQO se ajusta aos dados.
- R^2 : razão entre a variação explicada (SQE) e a variação total (SQT).
- R^2 : fração da variação amostral em y que é explicada por x.

$$SQT = SQE + SQR$$

$$SQT/SQT = (SQE + SQR)/SQT$$

$$1 = SQE/SQT + SQR/SQT$$

$$SQE/SQT = 1 - SQR/SQT$$

- Usar o R^2 como principal padrão de medida de sucesso de uma análise econométrica pode levar a confusões.

MUDANÇAS DAS UNIDADES DE MEDIDA

- Ao mudar unidades de medida das variáveis dependente e/ou independente, estimativas de MQO são afetadas.
- Se a **variável dependente** é multiplicada pela constante c (cada valor na amostra é multiplicado por c), então as estimativas de MQO de intercepto e de inclinação também são multiplicadas por c .
- Se a **variável independente** é dividida (ou multiplicada) por alguma constante diferente de zero (c) então o coeficiente de inclinação de MQO é multiplicado (ou dividido) por c , respectivamente.
- Mudar as unidades de medida da variável independente não afeta o intercepto.
- O grau de ajuste do modelo (R^2) não depende das unidades de medida das variáveis.

NÃO-LINEARIDADE NA REGRESSÃO SIMPLES

- Formas funcionais populares usadas em economia e outras ciências sociais aplicadas podem ser incorporadas à análise de regressão.
- Até agora foram analisadas relações lineares entre as variáveis dependente e independente.
- No entanto, relações lineares não são suficientes para todas as aplicações econômicas e sociais.
- É fácil incorporar não-linearidade na análise de regressão simples.

EXEMPLO DE NÃO-LINEARIDADE

- Para cada ano adicional de educação, há um aumento fixo no salário. Esse é o aumento tanto para o primeiro ano de educação quanto para anos mais avançados:

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

- Suponha que o aumento percentual no salário é o mesmo, dado um ano a mais de educação formal. Um modelo que gera um efeito percentual constante é dado por:

$$\log(\textit{salário}) = \beta_0 + \beta_1 \textit{educ} + u$$

- Se $\Delta u = 0$, então:


$$\% \Delta \textit{salário} = (100 * \beta_1) \Delta \textit{educ}$$

- Para cada ano adicional de educação, há um aumento de ?% sobre o salário.

- Como a variação percentual no salário é a mesma para cada ano adicional de educação, a variação no salário aumenta quando a educação formal aumenta.

Figura 2.6

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



INTERPRETAÇÃO DOS COEFICIENTES

- Aumento de uma unidade em x aumenta y em β_1 unidades:

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

- Aumento de 1% em x aumenta y em $(\beta_1/100)$ unidades:

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

- Aumento de uma unidade em x aumenta y em $(100*\beta_1)\%$. O cálculo da semi-elasticidade $\{\exp(\beta_1) - 1\} * 100$ indica a diferença percentual exata:

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

- Aumento de 1% em x aumenta y em $\beta_1\%$ (modelo de elasticidade constante):

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

- Elasticidade é a razão entre o percentual de mudança em uma variável e o percentual de mudança em outra variável.

FORMAS FUNCIONAIS ENVOLVENDO LOGARITMOS

| Modelo | Variável Dependente | Variável Independente | Interpretação de β_1 |
|-------------|---------------------|-----------------------|--|
| nível-nível | y | x | $\Delta y = \beta_1 \Delta x$ |
| nível-log | y | log(x) | $\Delta y = (\beta_1 / 100) \% \Delta x$ |
| log-nível | log(y) | x | $\% \Delta y = (100 \beta_1) \Delta x$ |
| log-log | log(y) | log(x) | $\% \Delta y = \beta_1 \% \Delta x$ |

SIGNIFICADO DE REGRESSÃO LINEAR

- O modelo de regressão linear permite relações não-lineares.
- Esse modelo é linear nos parâmetros: β_0 e β_1 .
- Não há restrições de como y e x se relacionam com as variáveis dependente e independente originais, já que podemos utilizar: logaritmo natural, quadrado, raiz quadrada...
- A interpretação dos coeficientes depende das definições de como x e y são construídos.
- “É muito mais importante tornar-se proficiente em interpretar coeficientes do que eficiente no cálculo de fórmulas.”
(Wooldridge, 2008: 45)

UTILIZAÇÃO DE PESOS

DIFERENTES PESOS

| Indivíduo | Número de observações coletadas na amostra | Peso para expandir para o tamanho da população (N) | Peso para manter o tamanho da amostra (n) |
|------------------|---|---|--|
| João | 1 | 4 | 0,8 |
| Maria | 1 | 6 | 1,2 |
| Total | 2 | 10 | 2 |

EXEMPLO:

Peso amostral do João =

Peso de frequência do João * (Peso amostral total / Peso de frequência total)

PESO DE FREQUÊNCIA NO STATA

– FWEIGHT:

- Expande os resultados da amostra para o tamanho populacional.
- Utilizado em tabelas para gerar frequências.
- O uso desse peso é importante na amostra do Censo Demográfico e na Pesquisa Nacional por Amostra de Domicílios (PNAD) do Instituto Brasileiro de Geografia e Estatística (IBGE) para expandir a amostra para o tamanho da população do país, por exemplo.
- Somente pode ser usado em tabelas de frequência quando o peso é uma variável discreta (não decimal).

```
tab x [fweight = peso]
```

PESO AMOSTRAL PARA PROGRAMADORES NO STATA

– IWEIGHT:

- Não tem uma explicação estatística formal.
- Esse peso é utilizado por programadores que precisam implementar técnicas analíticas próprias.
- Pode ser utilizado em tabelas de frequência, mesmo que o peso seja decimal.

```
tab x [iweight = peso]
```

PESO AMOSTRAL ANALÍTICO NO STATA

– AWEIGHT:

- Inversamente proporcional à variância da observação.
- Número de observações na regressão é escalonado para permanecer o mesmo que o número no banco.
- Utilizado para estimar uma regressão linear quando os dados são médias observadas, tais como:

| group | x | y | n |
|-------|-----|------|---|
| 1 | 3.5 | 26.0 | 2 |
| 2 | 5.0 | 20.0 | 3 |

- Ao invés de:

| group | x | y |
|-------|---|----|
| 1 | 3 | 22 |
| 1 | 4 | 30 |
| 2 | 8 | 25 |
| 2 | 2 | 19 |
| 2 | 5 | 16 |

UM POUCO MAIS SOBRE O AWEIGHT

- De uma forma geral, não é correto utilizar o **AWEIGHT** como um peso amostral, porque as fórmulas utilizadas por esse comando assumem que pesos maiores se referem a observações medidas de forma mais acurada.
- Uma observação em uma amostra não é medida de forma mais cuidadosa que nenhuma outra observação, já que todas fazem parte do mesmo plano amostral.
- Usar o **AWEIGHT** para especificar pesos amostrais fará com que o Stata estime valores incorretos de variância e de erros padrões para os coeficientes, assim como valores incorretos de "p" para os testes de hipótese.

```
regress y x1 x2 [aweight = peso]
```

PESO AMOSTRAL NAS REGRESSÕES DO STATA

– PWEIGHT:

- Ideal para ser usado nas regressões do Stata.
- Usa o peso amostral como o número de observações na população que cada observação representa.
- São estimadas proporções, médias e parâmetros da regressão corretamente.
- Há o uso de uma técnica de estimação robusta da variância que automaticamente ajusta para as características do plano amostral, de tal forma que variâncias, erros padrões e intervalos de confiança são calculados de forma mais precisa.
- É o inverso da probabilidade da observação ser incluída no banco, devido ao desenho amostral.

```
regress y x1 x2 [pweight = peso]
```

OUTRAS OBSERVAÇÕES SOBRE PESOS NO STATA

| PESOS EM TABELAS DE FREQUÊNCIA | | |
|---------------------------------------|---|--|
| Tipo do peso | Expandir para o tamanho da população (N) | Manter o tamanho da amostra (n) |
| Discreto | fweight | aweight |
| Decimal | iweight | |

| PESOS EM MODELOS DE REGRESSÃO devem manter o tamanho da amostra (n) | |
|--|--|
| Erro padrão robusto | R² ajustado, SQT, SQE, SQR |
| pweight | aweight |
| reg y x, robust | outreg2 |

PLANO AMOSTRAL COMPLEXO

- Estatísticas descritivas e modelos de regressão devem levar em consideração a estrutura de planos amostrais complexos.
- PNAD tem amostra complexa (Silva, Pessoa, Lila, 2002):
 - Considerar variáveis de estrato de município autorrepresentativo e não autorrepresentativo (v4617) e de unidade primária de amostragem (v4618), do banco de domicílios.
 - Agregar variáveis acima ao banco de pessoas, o qual possui peso da pessoa (v4729).
 - Lidar com problema de alguns estratos terem somente uma unidade primária de amostragem. Pode-se especificar média deste estrato como sendo a média geral, ao invés da média do próprio estrato.

```
svyset [pweight=v4729], strata(v4617) psu(v4618) singleunit(centered)
```

- Tabelas e regressões devem ser precedidas de “svy:”.

EXEMPLOS COM PNAD DE MINAS GERAIS DE 2007

- O banco de dados de pessoas possui informação de anos de escolaridade (anest), rendimento no trabalho principal (renpri), logaritmo do rendimento no trabalho principal (lnrenpri) e peso da pessoa (v4729):

| | anest | renpri | lnrenpri | v4729 |
|----|-------|--------|----------|-------|
| 1 | 4 | 380 | 5,940171 | 613 |
| 2 | 4 | 530 | 6,272877 | 613 |
| 3 | 11 | 800 | 6,684612 | 613 |
| 4 | 6 | 350 | 5,857933 | 613 |
| 5 | 11 | 1600 | 7,377759 | 613 |
| 6 | 11 | 743 | 6,610696 | 613 |
| 7 | 11 | 500 | 6,214608 | 613 |
| 8 | 14 | 580 | 6,363028 | 613 |
| 9 | 4 | 380 | 5,940171 | 613 |
| 10 | 11 | 400 | 5,991465 | 613 |
| 11 | 11 | 8000 | 8,987197 | 612 |
| 12 | 8 | 459 | 6,12905 | 613 |
| 13 | 8 | 380 | 5,940171 | 613 |
| 14 | 0 | 120 | 4,787492 | 612 |
| 15 | 8 | 600 | 6,39693 | 612 |
| 16 | 8 | 550 | 6,309918 | 612 |
| 17 | 8 | 600 | 6,39693 | 612 |
| 18 | 10 | 400 | 5,991465 | 613 |
| 19 | 4 | 380 | 5,940171 | 613 |
| 20 | 4 | 380 | 5,940171 | 613 |

...

EXEMPLO 1: PNAD DE MINAS GERAIS DE 2007

– Escolaridade explicando rendimento:

```
. reg renpri anest [aweight=v4729]
(sum of wgt is 8.7563e+06)
```



| Source | SS | df | MS |
|----------|------------|-------|------------|
| Model | 2.5086e+09 | 1 | 2.5086e+09 |
| Residual | 2.3809e+10 | 16230 | 1466951.75 |
| Total | 2.6317e+10 | 16231 | 1621416.61 |

```
Number of obs = 16232
F( 1, 16230) = 1710.07
Prob > F      = 0.0000
R-squared     = 0.0953
Adj R-squared = 0.0953
Root MSE     = 1211.2
```

| renpri | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] |
|--------|----------|-----------|-------|-------|----------------------|
| anest | 94.24418 | 2.279019 | 41.35 | 0.000 | 89.77705 98.71131 |
| _cons | 65.81278 | 20.36991 | 3.23 | 0.001 | 25.88551 105.7401 |


EXEMPLO 1: PNAD DE MINAS GERAIS DE 2007

– Renda predita por anos de escolaridade:



EXEMPLO 1: PNAD DE MINAS GERAIS DE 2007

– Resíduos por renda predita:



EXEMPLO 2: PNAD DE MINAS GERAIS DE 2007

– Escolaridade explicando logaritmo do rendimento:





```
. reg lnrenpri anest [aweight=v4729]
(sum of wgt is 8.7563e+06)
```

| Source | SS | df | MS | | | |
|----------|------------|-------|------------|-----------------|---------|--|
| Model | 2204.86541 | 1 | 2204.86541 | Number of obs = | 16232 | |
| Residual | 10035.5653 | 16230 | .618334278 | F(1, 16230) = | 3565.81 | |
| Total | 12240.4307 | 16231 | .754139039 | Prob > F = | 0.0000 | |
| | | | | R-squared = | 0.1801 | |
| | | | | Adj R-squared = | 0.1801 | |
| | | | | Root MSE = | .78634 | |

| lnrenpri | Coef. | Std. Err. | t | P> t | [95% Conf. Interval] | |
|----------|----------|-----------|--------|-------|----------------------|----------|
| anest | .088355 | .0014796 | 59.71 | 0.000 | .0854548 | .0912552 |
| _cons | 5.565065 | .0132249 | 420.80 | 0.000 | 5.539142 | 5.590987 |



EXEMPLO 2: PNAD DE MINAS GERAIS DE 2007

– Renda predita por anos de escolaridade:



EXEMPLO 2: PNAD DE MINAS GERAIS DE 2007

– Resíduos por renda predita:



GRÁFICOS FORAM GERADOS COM ESTAS VARIÁVEIS

- Cálculo do valor predito: $y\text{-predito} = \beta_0 + \beta_1 x$
- Cálculo do resíduo: $u = y\text{-observado} - y\text{-predito}$
- Na 2ª regressão, calculamos ainda o exponencial do predito.

| | anest | renpri | renpre | renres | lnrenpri | lnrenpre | lnrenres | explnrenpre | v4729 |
|----|-------|--------|----------|-----------|----------|----------|-----------|-------------|-------|
| 1 | 4 | 380 | 437,8324 | -57,83244 | 5,940171 | 5,941878 | -,0017066 | 380,649 | 613 |
| 2 | 4 | 530 | 437,8324 | 92,16756 | 6,272877 | 5,941878 | ,3309994 | 380,649 | 613 |
| 3 | 11 | 800 | 1094,848 | -294,8484 | 6,684612 | 6,538908 | ,145704 | 691,531 | 613 |
| 4 | 6 | 350 | 625,5513 | -275,5513 | 5,857933 | 6,112458 | -,2545248 | 451,4469 | 613 |
| 5 | 11 | 1600 | 1094,848 | 505,1516 | 7,377759 | 6,538908 | ,8388512 | 691,531 | 613 |
| 6 | 11 | 743 | 1094,848 | -351,8484 | 6,610696 | 6,538908 | ,071788 | 691,531 | 613 |
| 7 | 11 | 500 | 1094,848 | -594,8484 | 6,214608 | 6,538908 | -,3242996 | 691,531 | 613 |
| 8 | 14 | 580 | 1376,427 | -796,4268 | 6,363028 | 6,794778 | -,4317498 | 893,1708 | 613 |
| 9 | 4 | 380 | 437,8324 | -57,83244 | 5,940171 | 5,941878 | -,0017066 | 380,649 | 613 |
| 10 | 11 | 400 | 1094,848 | -694,8484 | 5,991465 | 6,538908 | -,5474432 | 691,531 | 613 |
| 11 | 11 | 8000 | 1094,848 | 6905,151 | 8,987197 | 6,538908 | 2,448289 | 691,531 | 612 |
| 12 | 8 | 459 | 813,2701 | -354,2701 | 6,12905 | 6,283038 | -,1539876 | 535,4126 | 613 |
| 13 | 8 | 380 | 813,2701 | -433,2701 | 5,940171 | 6,283038 | -,3428666 | 535,4126 | 613 |
| 14 | 0 | 120 | 62,39473 | 57,60527 | 4,787492 | 5,600718 | -,813226 | 270,6206 | 612 |
| 15 | 8 | 600 | 813,2701 | -213,2702 | 6,39693 | 6,283038 | ,1138919 | 535,4126 | 612 |
| 16 | 8 | 550 | 813,2701 | -263,2701 | 6,309918 | 6,283038 | ,0268806 | 535,4126 | 612 |
| 17 | 8 | 600 | 813,2701 | -213,2702 | 6,39693 | 6,283038 | ,1138919 | 535,4126 | 612 |
| 18 | 10 | 400 | 1000,989 | -600,989 | 5,991465 | 6,453618 | -,4621532 | 634,9956 | 613 |
| 19 | 4 | 380 | 437,8324 | -57,83244 | 5,940171 | 5,941878 | -,0017066 | 380,649 | 613 |
| 20 | 4 | 380 | 437,8324 | -57,83244 | 5,940171 | 5,941878 | -,0017066 | 380,649 | 613 |