

# **AULAS 14 E 15**

# **Modelo de regressão**

# **simples**

**Ernesto F. L. Amaral**

**10 e 15 de outubro de 2013**  
**Avaliação de Políticas Públicas (DCP 046)**

**Fonte:**

**Wooldridge, Jeffrey M. “Introdução à econometria: uma abordagem moderna”. São Paulo: Cengage Learning, 2008. pp.20-63 (capítulo 2).**

# 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 EXEMPLIFICAÇÕES

- Vamos utilizar a Pesquisa Nacional por Amostra de Domicílios (PNAD) de 2007 de Minas Gerais para as demonstrações em sala de aula.
- 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>

# 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:

| <b>y</b>             | <b>x</b>              | <b>Uso</b>             |
|----------------------|-----------------------|------------------------|
| 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  $\beta_1$  multiplicado pela variação em  $x$ .
  - $\beta_1$ : **parâmetro de inclinação** da relação entre  $y$  e  $x$ , mantendo fixos os outros fatores em  $u$ .
  - $\beta_0$ : **parâmetro de intercepto** é raramente analisado.
  - $\beta_1$  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  $\beta_0$  e  $\beta_1$  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

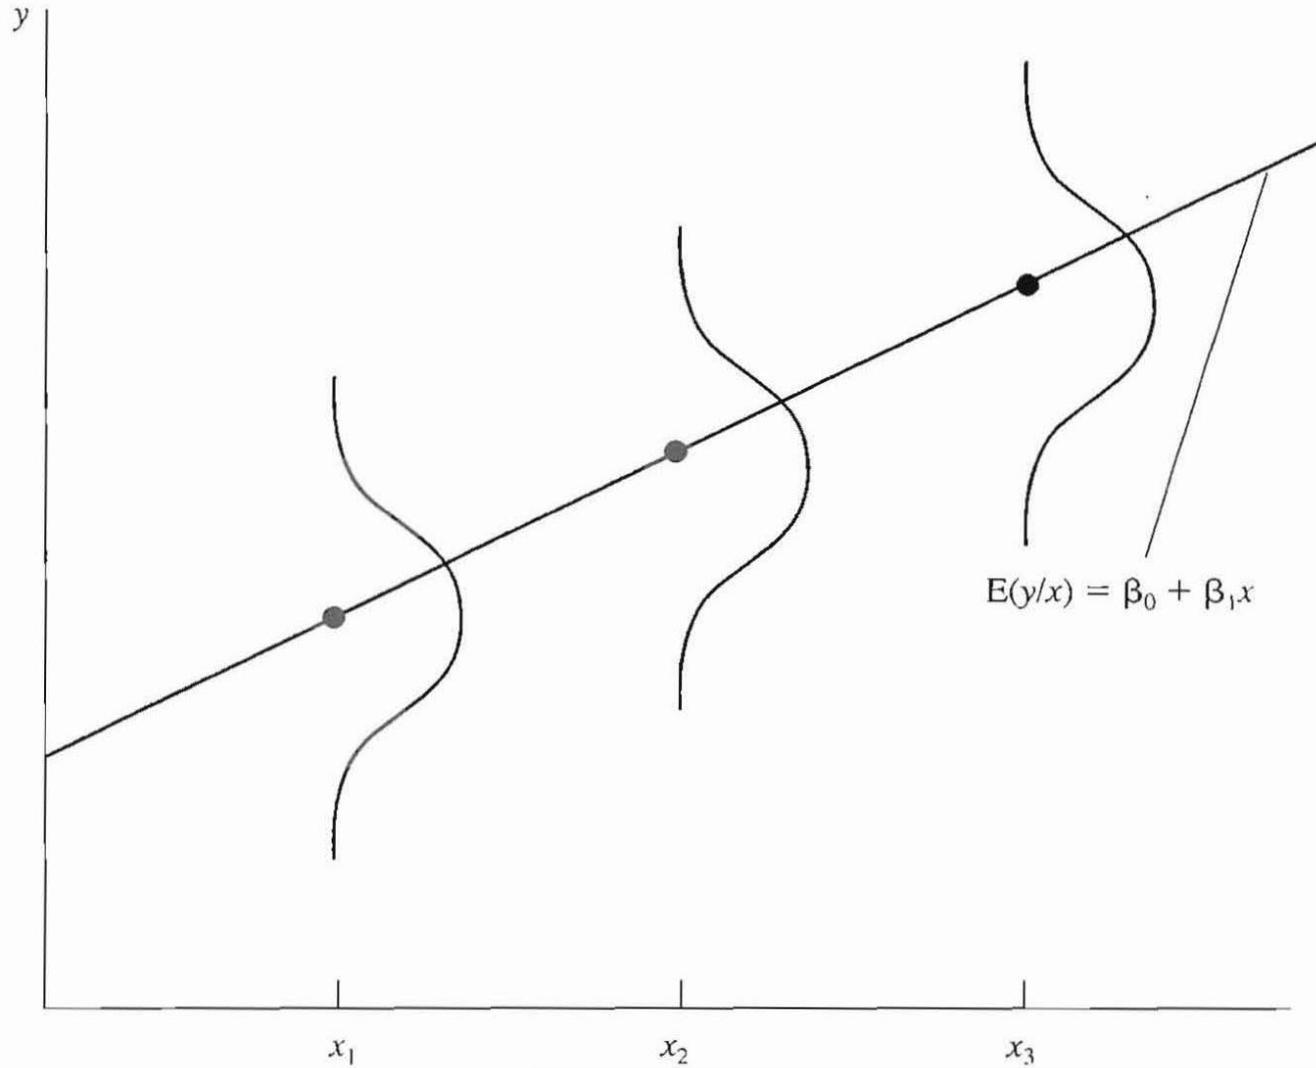
- Quando  $E(u|x)=E(u)=0$  é verdadeiro, é útil dividir  $y$  em:
  - Parte sistemática (parte de  $y$  explicada por  $x$ ):  $\beta_0 + \beta_1 x$
  - Parte não-sistemática (parte de  $y$  não explicada por  $x$ ):  $u$
- Considerando o valor esperado de  $y=\beta_0+\beta_1 x+u$  condicionado a  $x$ , 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  $\beta_1$ .
- 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  $\beta_0$  e  $\beta_1$ , é preciso considerar uma amostra da população:

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

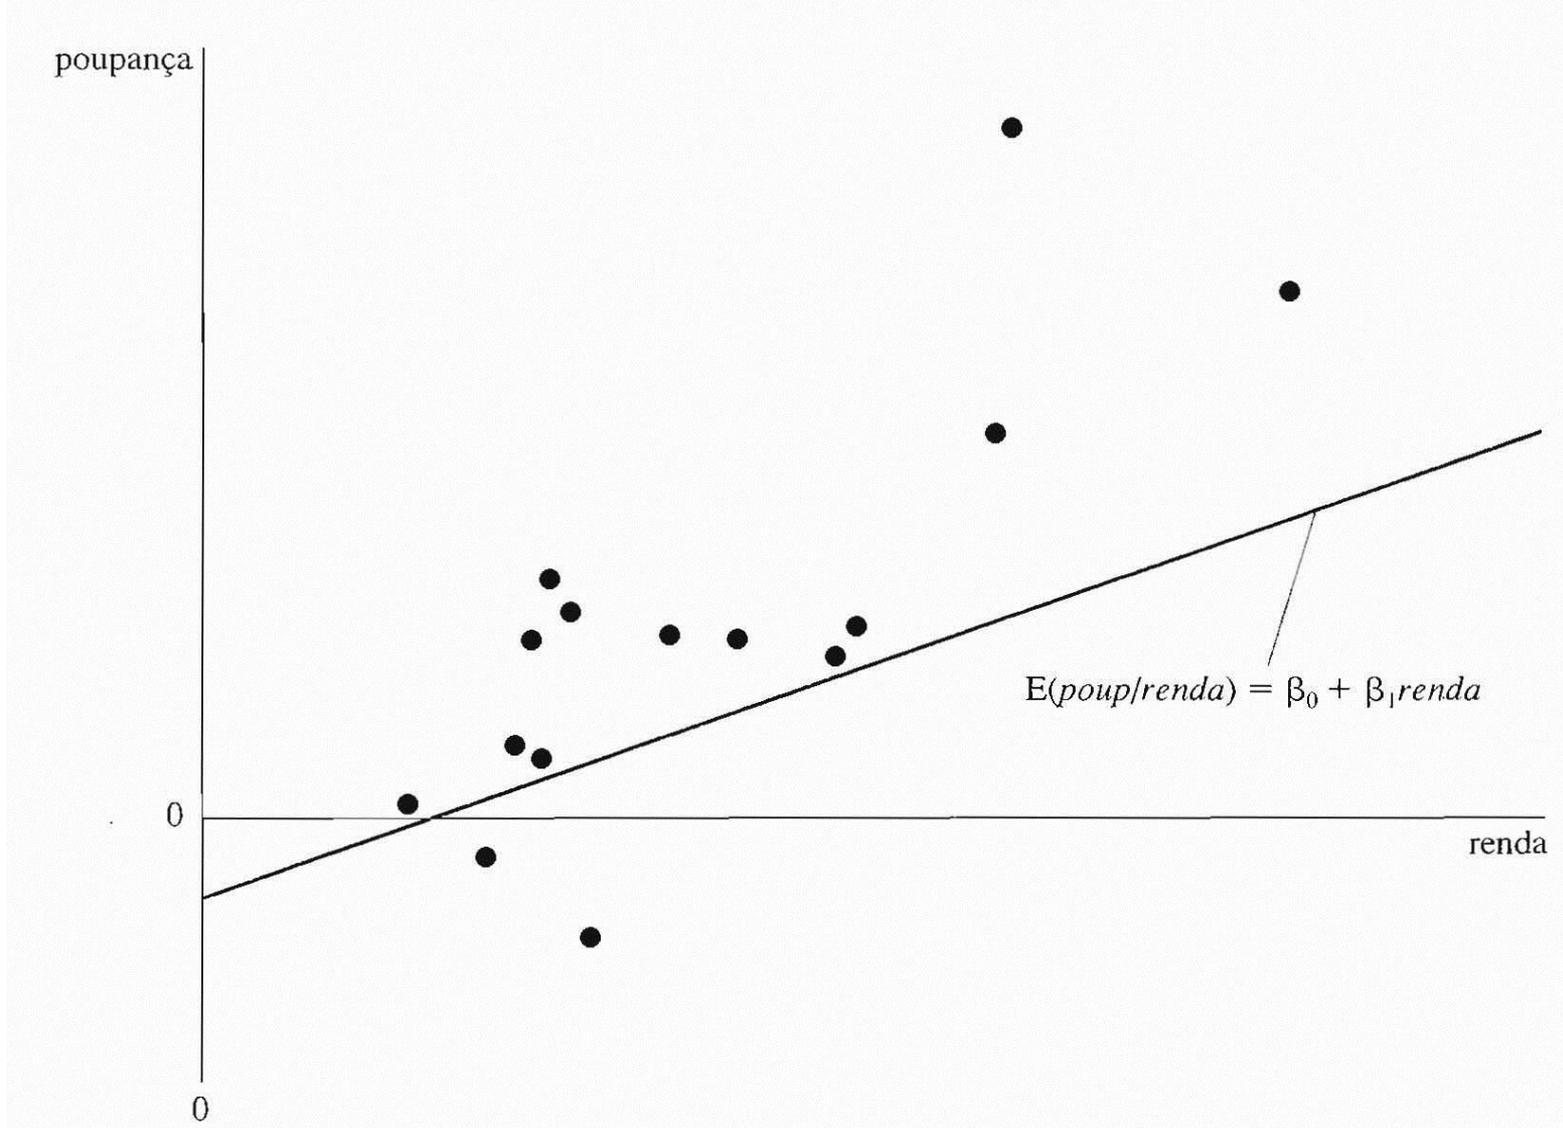
- A equação do modelo de regressão simples é escrito como:

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

- $u_i$  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 ( $\beta_0$ ) e da inclinação ( $\beta_1$ ) 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 ( $\beta_0$  e  $\beta_1$ ), 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 $\hat{\beta}_1$

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

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

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



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

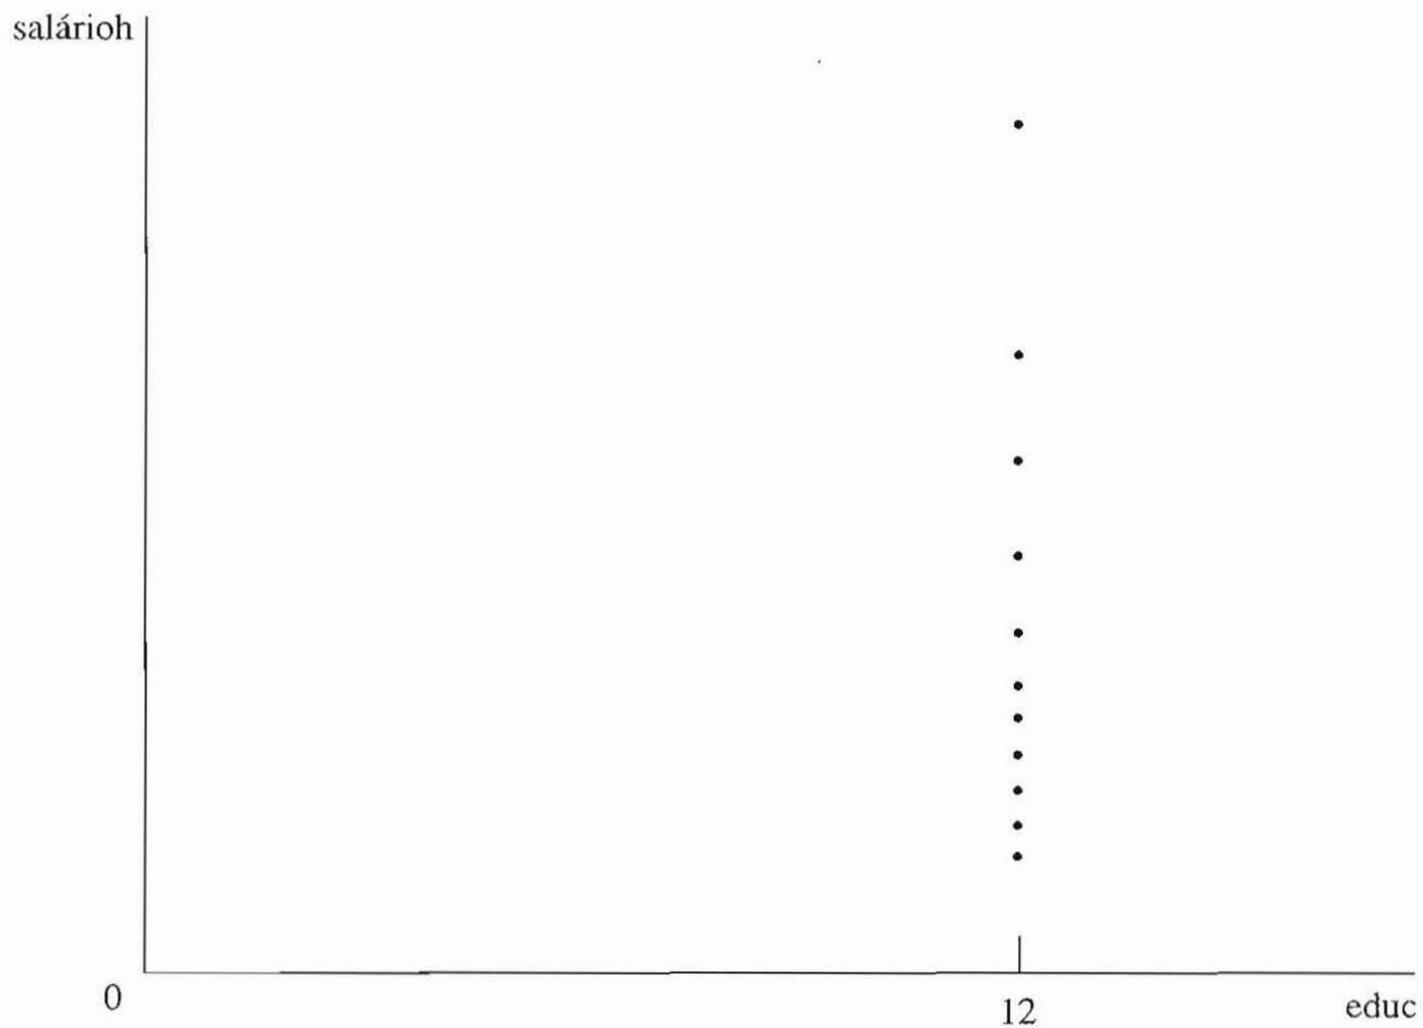
- Se x e y são positivamente correlacionados na amostra,  $\hat{\beta}_1$  é positivo e vice-versa.

## 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:

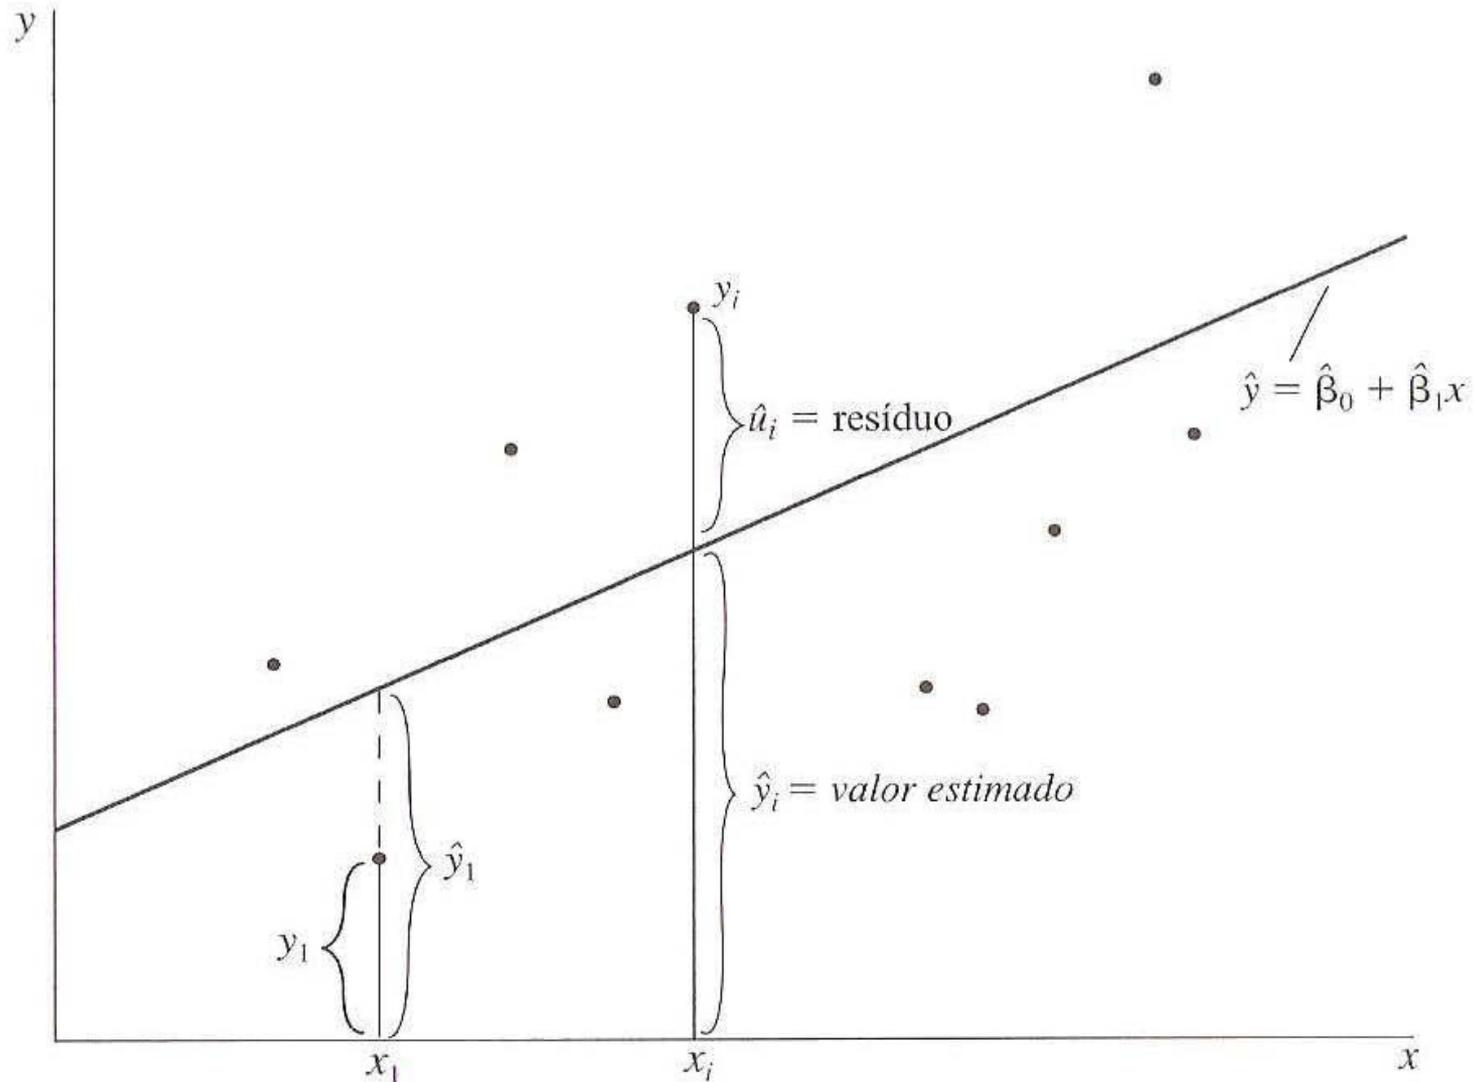
$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

- 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:

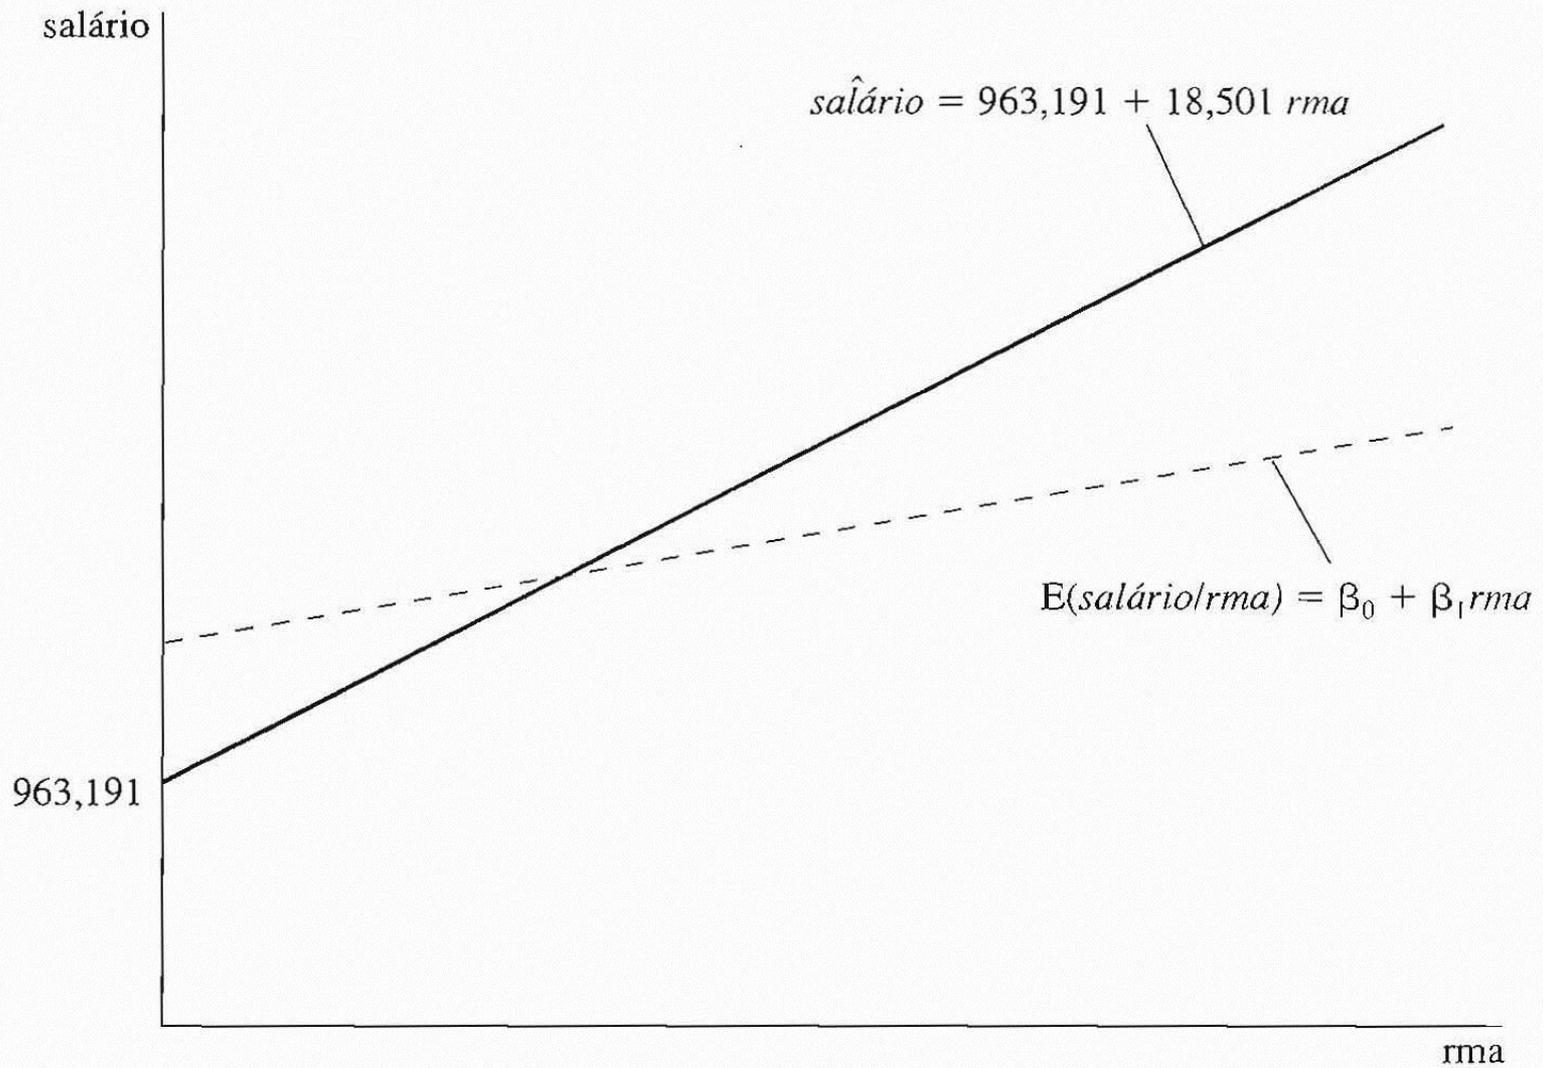
$$\hat{\beta}_1 = \Delta \hat{y} / \Delta x$$

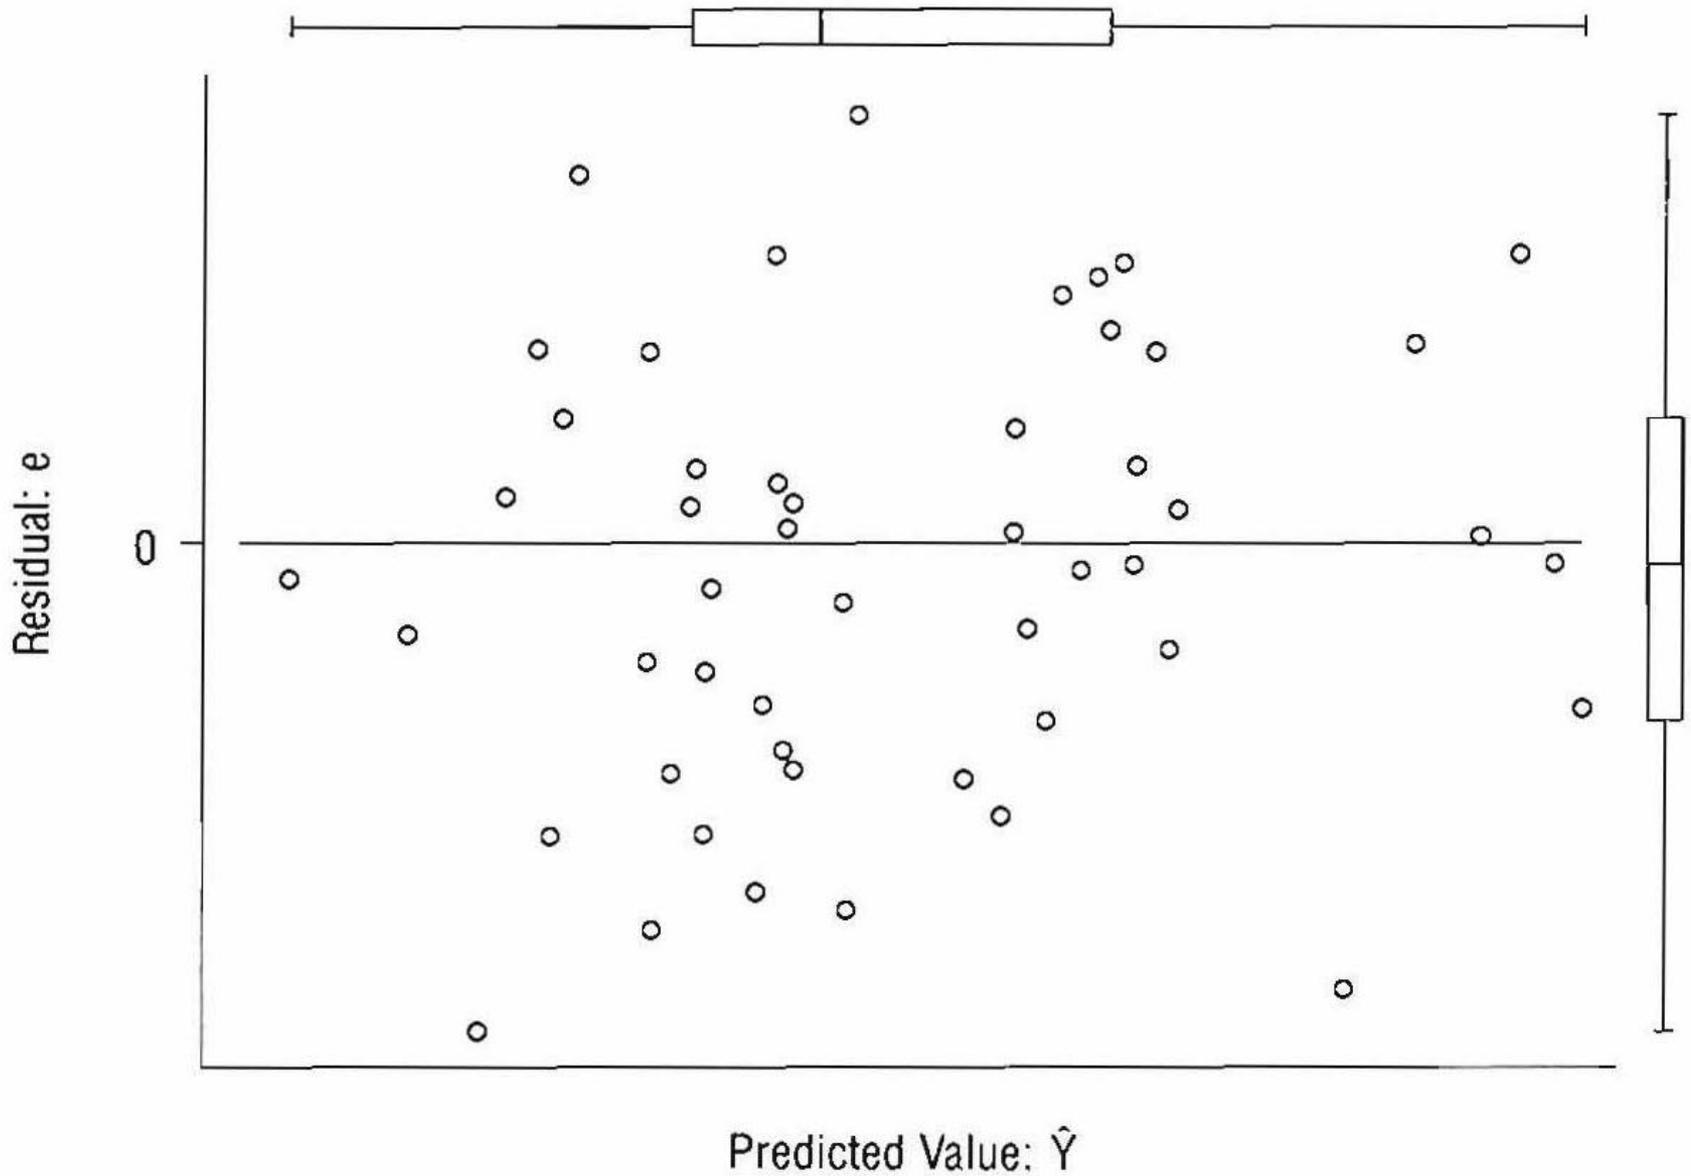
- Da mesma forma, dada qualquer variação em  $x$ , podemos calcular a variação prevista em  $y$ :

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

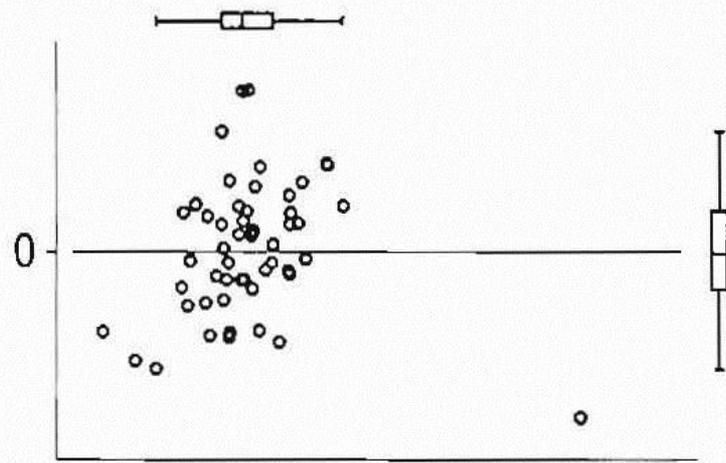
**Figura 2.5**

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

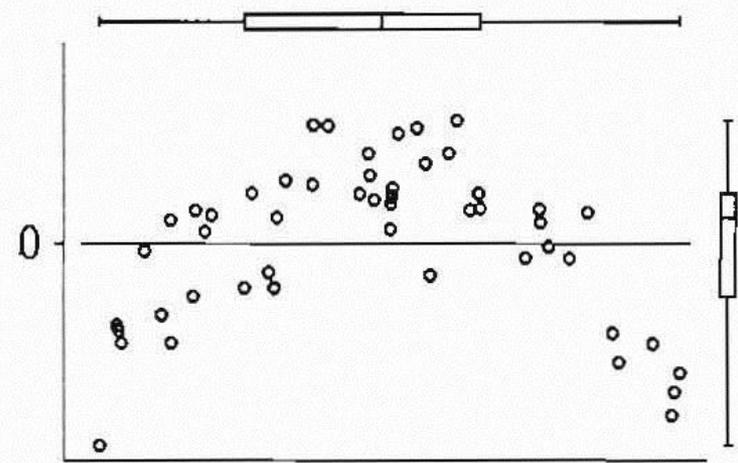




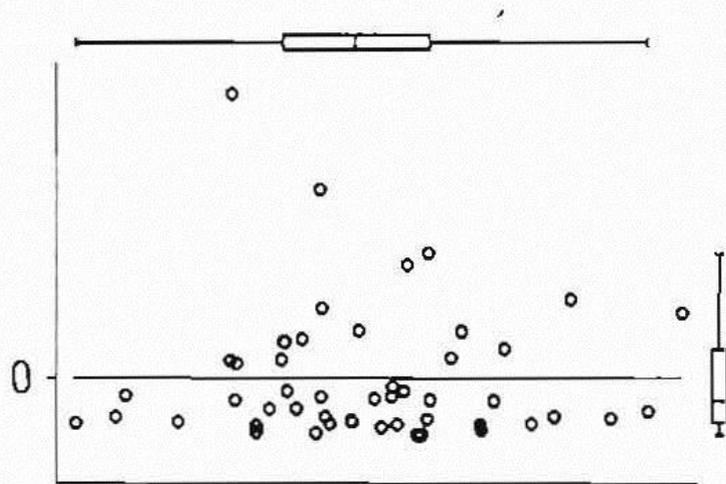
**Figure 2.10** “All clear”  $e$ -versus- $\hat{Y}$  plot (artificial data).



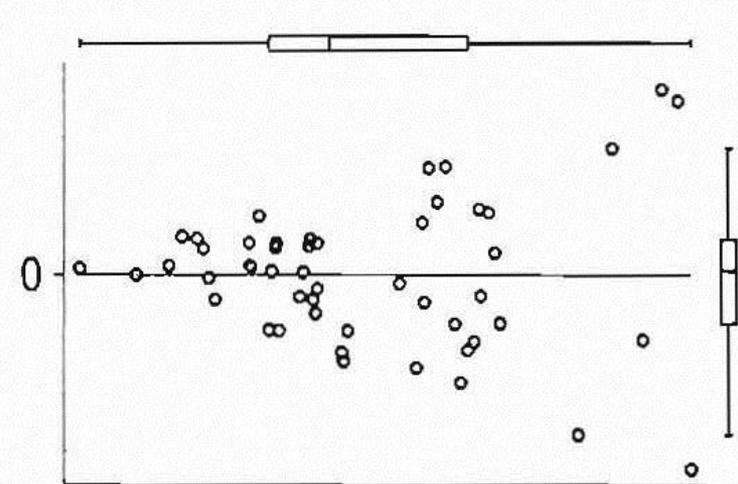
Influential Case



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:

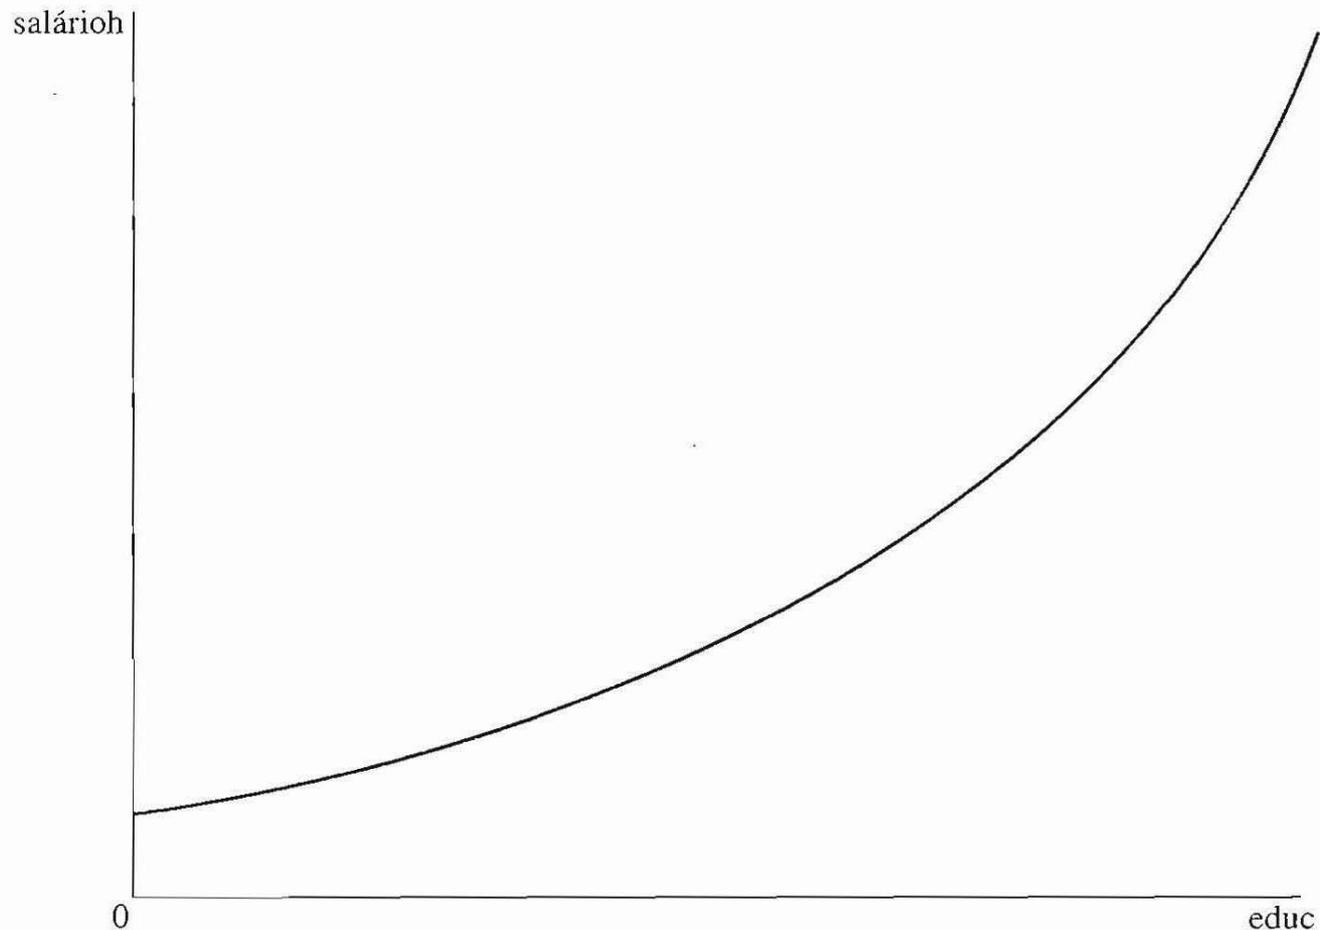
$$\% \Delta \textit{salário} = (100 * \beta_1) \Delta \textit{educ}$$

- 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  $\beta_1$  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 $\beta_1$               |
|-------------|---------------------|-----------------------|------------------------------------------|
| 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:  $\beta_0$  e  $\beta_1$ .
- 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

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

### 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

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

| <b>PESOS EM MODELOS DE REGRESSÃO devem manter o tamanho da amostra (n)</b> |                                              |
|----------------------------------------------------------------------------|----------------------------------------------|
| <b>Erro padrão robusto</b>                                                 | <b>R<sup>2</sup> ajustado, SQT, SQE, SQR</b> |
| <b>pweight</b>                                                             | <b>aweight</b>                               |
| <b>reg y x, robust</b>                                                     | <b>outreg2</b>                               |

## 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)
```

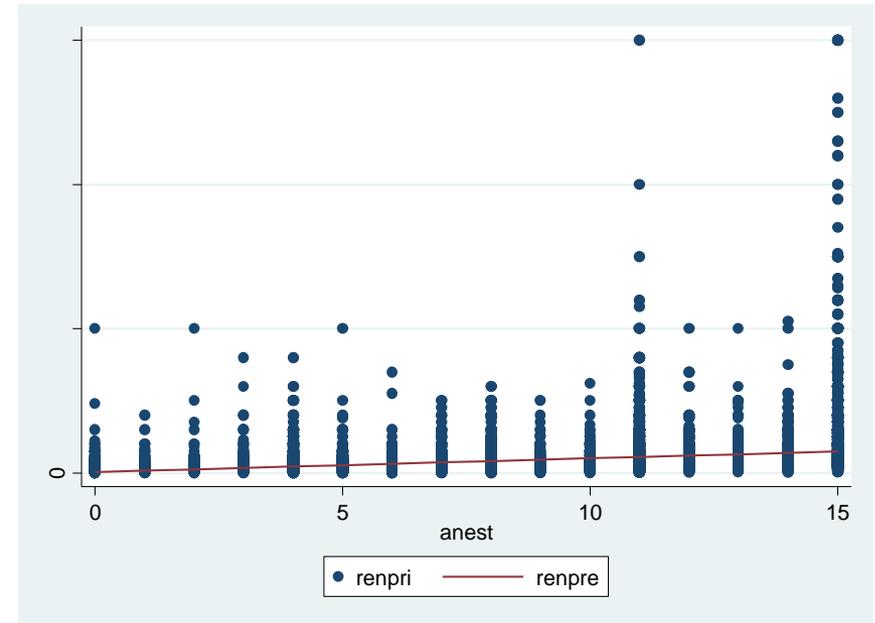
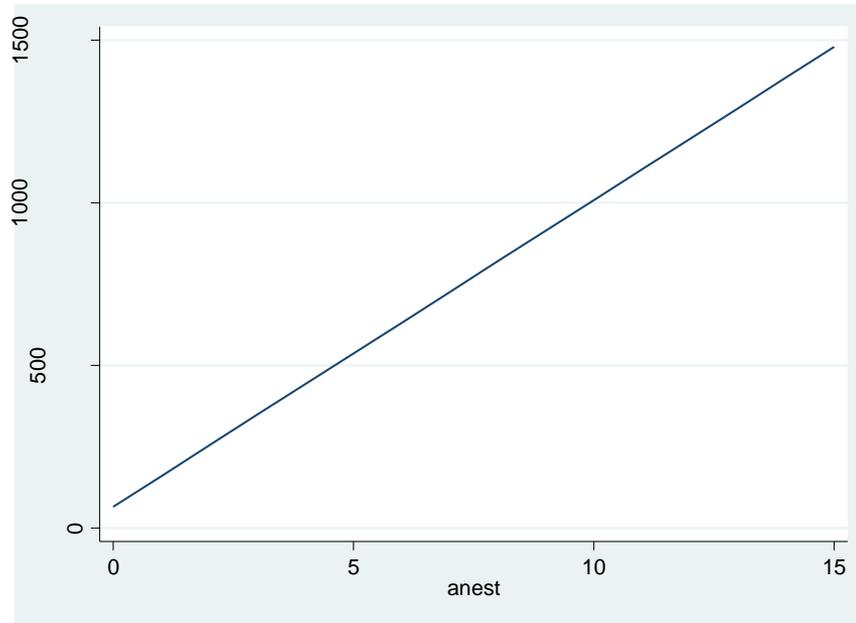
| Source   | SS         | df    | MS         |
|----------|------------|-------|------------|
| Model    | 2.5086e+09 | 1     | 2.5086e+09 |
| Residual | 2.3809e+10 | 16230 | 1466951.75 |
| Total    | 2.6317e+10 | 16231 | 1621416.61 |

```
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    |

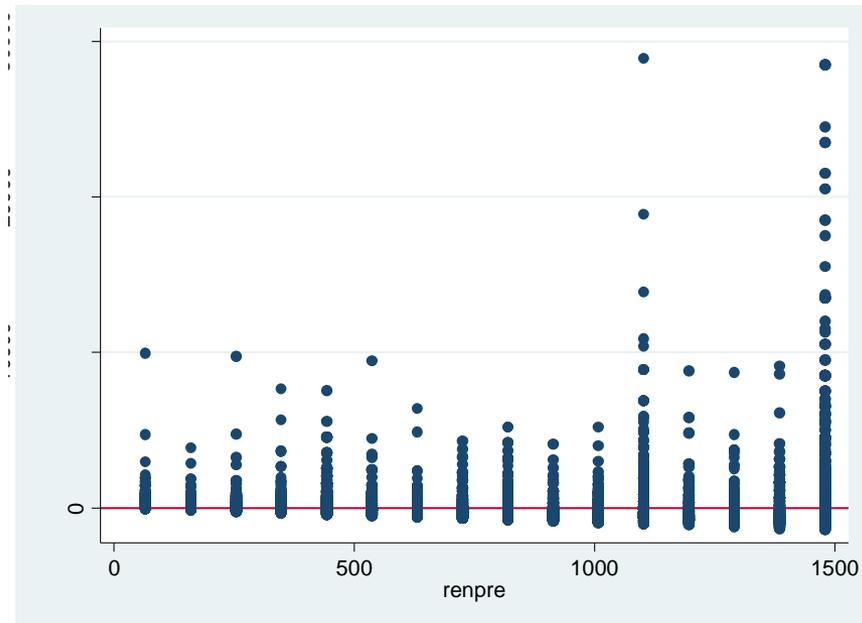
# EXEMPLO 1: PNAD DE MINAS GERAIS DE 2007

– 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)
```

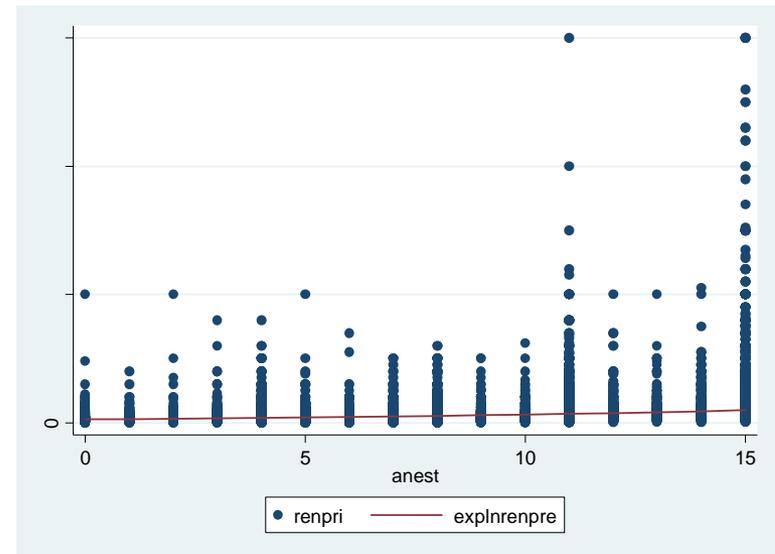
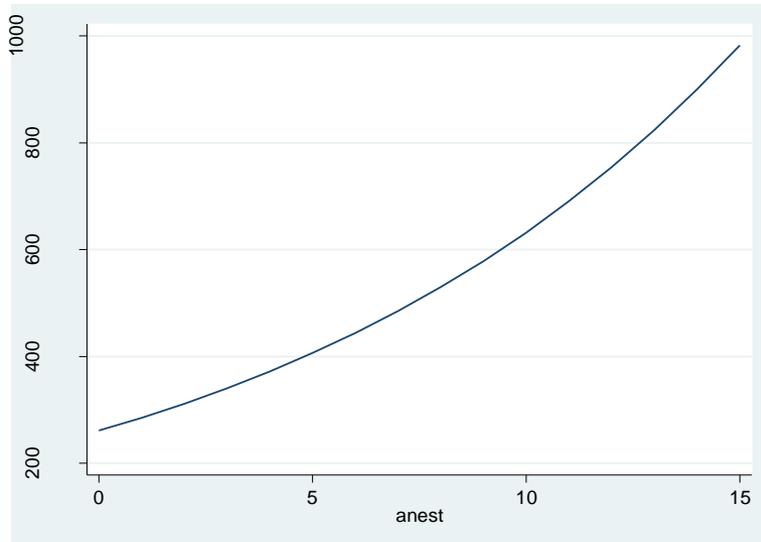
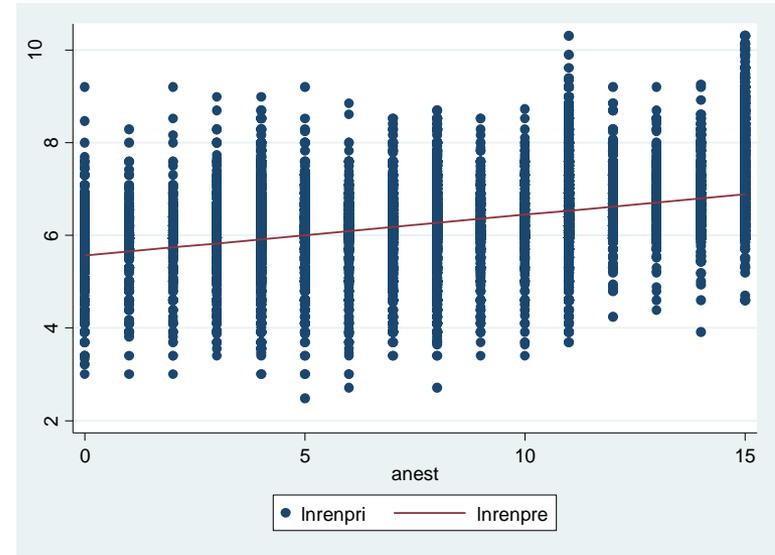
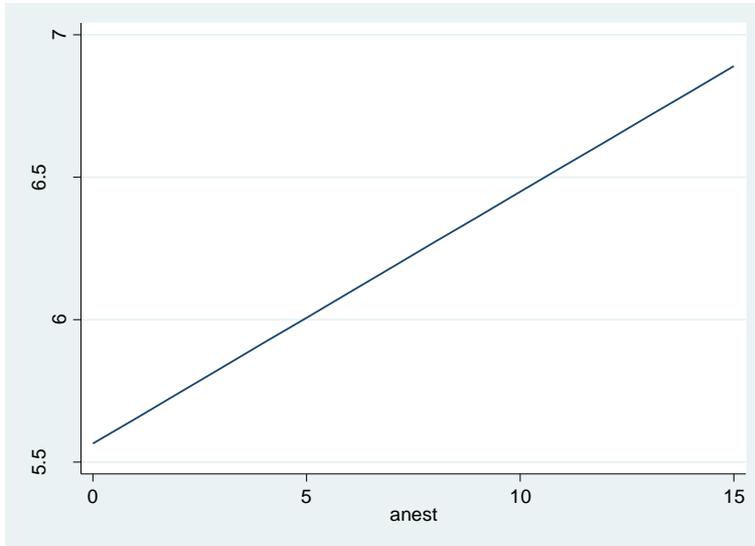
| Source   | SS         | df    | MS         |                 |         |  |
|----------|------------|-------|------------|-----------------|---------|--|
| Model    | 2204.86541 | 1     | 2204.86541 | Number of obs = | 16232   |  |
| Residual | 10035.5653 | 16230 | .618334278 | F( 1, 16230) =  | 3565.81 |  |
| 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 |

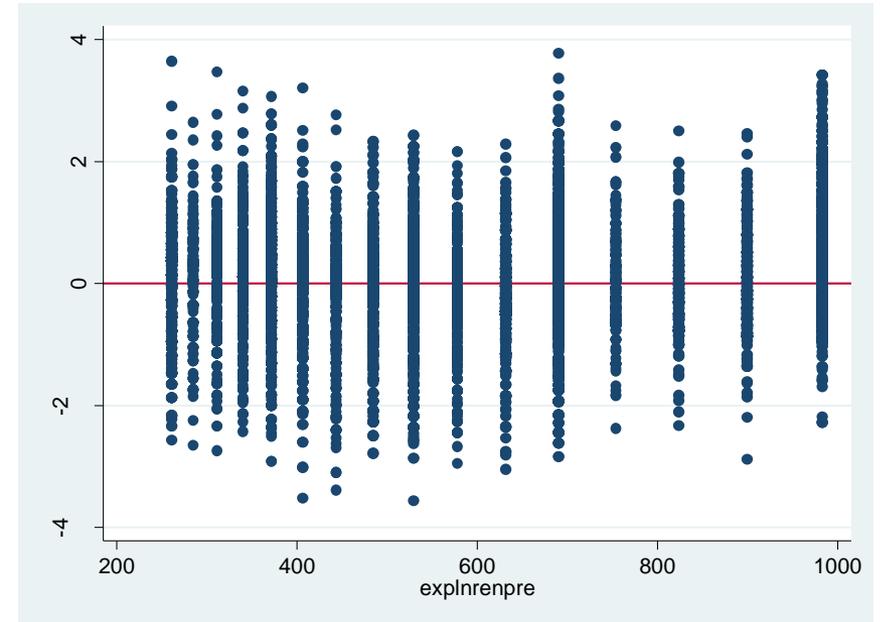
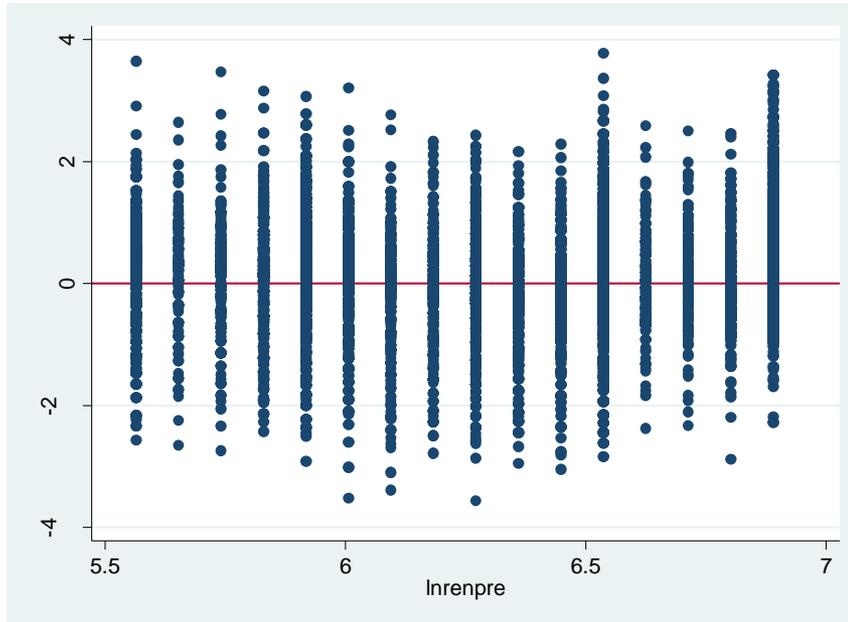
# EXEMPLO 2: PNAD DE MINAS GERAIS DE 2007

– 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   |