

AULA 07

Análise de regressão múltipla: problemas adicionais

Ernesto F. L. Amaral

23 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 6 (pp.174-206).

EFEITOS DA DIMENSÃO DOS DADOS NAS ESTATÍSTICAS

- Mudanças das unidades de medida das variáveis não afeta o R^2 .
- A intenção agora é de examinar o efeito do redimensionamento das variáveis dependente ou independente sobre:
 - Erros-padrão.
 - Estatísticas t .
 - Estatísticas F .
 - Intervalos de confiança.
- Escolhendo as unidades de medida, a aparência da equação estimada pode melhorar, sem alterar a essência do modelo.
- É geralmente realizada com valores monetários, especialmente quando os montantes são muito grandes.

EXEMPLO

- *pesônas*: peso dos recém-nascidos, em onças.
- *cigs*: número médio de cigarros que a mãe fumou por dia durante a gravidez.
- *rendfam*: renda anual familiar, em milhares de dólares.
- Equação 1:

$$\widehat{pesonas} = \hat{\beta}_0 + \hat{\beta}_1 cigs + \hat{\beta}_2 rendfam$$

EFEITOS DA DIMENSÃO DOS DADOS

Variável Dependente	(1) pesonas	(2) pesonaslb = pesonas/16	(3) pesonas
Variáveis Independentes			
<i>cigs</i>	-0,4634 (0,0916)	-0,0289 (0,0057)	-----
<i>maços = cigs/20</i>	-----	-----	-9,268 (1,832)
<i>rendfam</i>	0,0927 (0,0292)	0,0058 (0,0018)	0,0927 (0,0292)
<i>intercepto</i>	116,974 (1,049)	7,3109 (0,0656)	116,974 (1,049)
Observações	1.388	1.388	1.388
R-quadrado	0,0298	0,0298	0,0298
SQR	557.485,51	2.177,6778	557.485,51
EPR	20,063	1,2539	20,063

MUDANÇA NA DEPENDENTE

– Não importa como a variável dependente seja medida, os efeitos da constante e coeficientes são transformados nas mesmas unidades.

– Equação 2:

$$\widehat{pessoas}/16 = \hat{\beta}_0/16 + (\hat{\beta}_1/16)cigs + (\hat{\beta}_2/16)rendfam$$

E A SIGNIFICÂNCIA ESTATÍSTICA?

- A alteração da variável dependente de onças para libras não tem efeito sobre o quanto são estatisticamente importantes as variáveis independentes.
- Os erros-padrão na coluna (2) são 16 vezes menores que os da coluna (1).
- As estatísticas t na coluna (2) são idênticas às da coluna (1).
- Os pontos extremos dos intervalos de confiança na coluna (2) são exatamente os pontos extremos na coluna (1) divididos por 16, já que ICs mudam pelos mesmos fatores dos erros-padrão.
- IC de 95% é beta estimado +/- 1,96 erro padrão estimado.

E O GRAU DE AJUSTE? E O SQR? E O EPR?

- Os R^2 das duas regressões são idênticos, como esperado.
- A soma dos resíduos quadrados (SQR) e o erro-padrão da regressão (EPR) possuem diferentes equações.
- Quando *pesonaslb* é a variável dependente, o resíduo da observação *i* na equação (2) é: $\hat{u}_i/16$
- O resíduo quadrado em (2) é: $(\hat{u}_i/16)^2 = \hat{u}_i^2/256$
- Por isso, **SQR(2) = SQR(1) / 256.**
- Como: $EPR = \hat{\sigma} = \sqrt{SQR/(n - k - 1)} = \sqrt{SQR/1.385}$
- Por isso, **EPR(2) = EPR(1) / 16.**

REDUZIMOS O ERRO?

- O erro na equação com *pesonaslb* como a variável dependente tem um desvio-padrão 16 vezes menor do que o desvio-padrão do erro original.
- Isso não significa reduzir o erro por mudar a medida da variável dependente.
- O EPR menor simplesmente reflete uma diferença nas unidades de medida.

EXEMPLO 1: PNAD DE MINAS GERAIS DE 2007

– Rendimento em reais como variável dependente:

```
. *Modelo com reais
. reg renpri mulher idpia anest negra [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS			
Model	4.7726e+09	4	1.1932e+09	Number of obs =	15620	
Residual	2.0236e+10	15615	1295928.74	F(4, 15615) =	920.70	
Total	2.5009e+10	15619	1601162.78	Prob > F =	0.0000	
				R-squared =	0.1908	
				Adj R-squared =	0.1906	
				Root MSE =	1138.4	

renpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-456.3604	18.81349	-24.26	0.000	-493.2371	-419.4838
idpia	26.5257	.7831009	33.87	0.000	24.99073	28.06067
anest	118.2471	2.375738	49.77	0.000	113.5904	122.9038
negra	-173.1548	18.80343	-9.21	0.000	-210.0117	-136.2979
_cons	-813.123	42.34102	-19.20	0.000	-896.1164	-730.1297

EXEMPLO 2: PNAD DE MINAS GERAIS DE 2007

- Rendimento em dólares (reais dividido por dois) como variável dependente:

```
. *Modelo com dólares
. reg rendo1 mulher idpia anest negra [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS			
Model	1.1932e+09	4	298289636	Number of obs =	15620	
Residual	5.0590e+09	15615	323982.185	F(4, 15615) =	920.70	
Total	6.2521e+09	15619	400290.695	Prob > F =	0.0000	
				R-squared =	0.1908	
				Adj R-squared =	0.1906	
				Root MSE =	569.19	

rendo1	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-228.1802	9.406745	-24.26	0.000	-246.6185	-209.7419
idpia	13.26285	.3915504	33.87	0.000	12.49536	14.03033
anest	59.12355	1.187869	49.77	0.000	56.79519	61.45191
negra	-86.57738	9.401716	-9.21	0.000	-105.0058	-68.14893
_cons	-406.5615	21.17051	-19.20	0.000	-448.0582	-365.0649

- Coeficientes, erros padrões, intervalo de confiança e erro padrão do resíduo são 2 vezes menores.
- R^2 é o mesmo.

MUDANÇA NA INDEPENDENTE

- *maços*: quantidade de maços de cigarros fumados por dia:

$$maços = cigs / 20$$

$$\begin{aligned} \widehat{pesonas} &= \hat{\beta}_0 + (20\hat{\beta}_1) \left(\frac{cigs}{20} \right) + \hat{\beta}_2 rendfam \\ &= \hat{\beta}_0 + (20\hat{\beta}_1) maços + \hat{\beta}_2 rendfam \end{aligned}$$

- O intercepto e o coeficiente de inclinação de *rendfam* não se alteraram.
- O coeficiente de *maços* é 20 vezes o de *cigs*.
- O erro-padrão de *maços* é 20 vezes o de *cigs*, o que significa que a estatística *t* é a mesma.
- Se *maços* e *cigs* fossem inseridos conjuntamente, teríamos multicolinearidade perfeita.

EXEMPLO 3: PNAD DE MINAS GERAIS DE 2007

– Idade original como variável independente:

```
. *Modelo com idpia
. reg renpri mulher idpia anest negra [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS			
Model	4.7726e+09	4	1.1932e+09	Number of obs =	15620	
Residual	2.0236e+10	15615	1295928.74	F(4, 15615) =	920.70	
Total	2.5009e+10	15619	1601162.78	Prob > F =	0.0000	
				R-squared =	0.1908	
				Adj R-squared =	0.1906	
				Root MSE =	1138.4	

renpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-456.3604	18.81349	-24.26	0.000	-493.2371	-419.4838
idpia	26.5257	.7831009	33.87	0.000	24.99073	28.06067
anest	118.2471	2.375738	49.77	0.000	113.5904	122.9038
negra	-173.1548	18.80343	-9.21	0.000	-210.0117	-136.2979
_cons	-813.123	42.34102	-19.20	0.000	-896.1164	-730.1297

EXEMPLO 4: PNAD DE MINAS GERAIS DE 2007

- Idade dividida por 5 como variável independente (impacto de 5 em 5 anos de idade):

```
. *Modelo com id5
. reg renpri mulher id5 anest negra [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS			
Model	4.7726e+09	4	1.1932e+09	Number of obs =	15620	
Residual	2.0236e+10	15615	1295928.74	F(4, 15615) =	920.70	
Total	2.5009e+10	15619	1601162.78	Prob > F =	0.0000	
				R-squared =	0.1908	
				Adj R-squared =	0.1906	
				Root MSE =	1138.4	

renpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-456.3604	18.81349	-24.26	0.000	-493.2371	-419.4838
id5	132.6285	3.915504	33.87	0.000	124.9536	140.3033
anest	118.2471	2.375738	49.77	0.000	113.5904	122.9038
negra	-173.1548	18.80343	-9.21	0.000	-210.0117	-136.2979
_cons	-813.1231	42.34102	-19.20	0.000	-896.1164	-730.1297

- Coeficiente e erro padrão de idade são 5 vezes maiores.
- As demais estimativas são as mesmas.

COEFICIENTES BETA

- Algumas vezes, uma variável-chave é medida em uma dimensão de difícil interpretação.
- Primeiro exemplo: ao invés de perguntar o efeito sobre o salário, proveniente do aumento em dez pontos em um teste, talvez faça mais sentido perguntar sobre efeito proveniente do aumento de um desvio-padrão.
- Segundo exemplo: é o caso de variáveis criadas com análise fatorial, já que não sabemos exatamente o que a unidade de medida significa.
- Como o desvio-padrão da variável “fatorial” é geralmente próximo de uma unidade, verificamos o efeito na unidade da variável dependente (beta), após a alteração de um desvio-padrão na variável independente.

COEFICIENTES PADRONIZADOS

- Algumas vezes é útil obter resultados de regressão quando todas as variáveis tenham sido padronizadas.
- Uma variável é padronizada pela subtração de sua média e dividindo o resultado por seu desvio-padrão.
- Ou seja, computamos a transformação z de cada variável e depois fazemos a regressão usando esses valores z.

- Portanto, partimos de:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik} + \hat{u}$$

- Novo beta = beta original * (dp de x / dp de y)
- Intercepto (beta zero) não existe mais:

$$z_y = \hat{b}_1 z_1 + \hat{b}_2 z_2 + \dots + \hat{b}_k z_k + erro$$

- Para $j = 1, \dots, k$, os coeficientes são: $\hat{b}_j = (\hat{\sigma}_j / \hat{\sigma}_y) \hat{\beta}_j$

INTERPRETANDO COEFICIENTES PADRONIZADOS

- Os coeficientes padronizados são também chamados de coeficientes beta.
- Se x_1 aumentar em um desvio-padrão, então o y predito será alterado em b_1 desvios-padrão.
- Os efeitos não estão sendo medidos em termos das unidades originais de y ou de x_j , mas em unidades de desvios-padrão.
- A dimensão das variáveis independentes passa a ser irrelevante, colocando-as em igualdade.
- Quando cada x_j é padronizado, a comparação das magnitudes dos coeficientes (significância econômica) é mais convincente. Ou seja, a variável com maior coeficiente (em módulo) é a “mais importante”.
- O Stata apresenta os beta padronizados com opção “, beta”.

EXEMPLO 5: PNAD DE MINAS GERAIS DE 2007

– Coeficiente padronizado:

```
. *Modelo com betas padronizados
. reg renpri mulher idpia anest negra [aweight=v4729], beta
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS		
Model	4.7726e+09	4	1.1932e+09	Number of obs =	15620
Residual	2.0236e+10	15615	1295928.74	F(4, 15615) =	920.70
Total	2.5009e+10	15619	1601162.78	Prob > F =	0.0000
				R-squared =	0.1908
				Adj R-squared =	0.1906
				Root MSE =	1138.4

renpri	Coef.	Std. Err.	t	P> t	Beta
mulher	-456.3604	18.81349	-24.26	0.000	-.1772221
idpia	26.5257	.7831009	33.87	0.000	.2537558
anest	118.2471	2.375738	49.77	0.000	.386066
negra	-173.1548	18.80343	-9.21	0.000	-.0682722
_cons	-813.123	42.34102	-19.20	0.000	.

USO DE FORMAS FUNCIONAIS LOGARÍTMICAS

- O uso de logaritmos das variáveis dependentes ou independentes é o artifício mais comum em econometria para permitir relações não lineares entre a variável explicada e as variáveis explicativas.

$$\widehat{\log}(y) = \hat{\beta}_0 + \hat{\beta}_1 \log(x_1) + \hat{\beta}_2 x_2$$

- β_1 é a elasticidade de y , em relação a x_1 :
 - Quando x_1 aumenta em 1%, y aumenta em $\beta_1\%$, mantendo x_2 fixo.
- $100*\beta_2$ é a semi-elasticidade de y , em relação a x_2 :
 - Quando x_2 aumenta em 1, y aumenta em $100*[\exp(\beta_2)-1]$, mantendo x_1 fixo.
 - No entanto, podemos utilizar $100*\beta_2$, quando temos pequenas mudanças percentuais.

PECULIARIDADES DO USO DE LOGARITMOS

- Com log, ignoramos unidades de medida das variáveis, pois coeficientes de inclinação não variam pelas unidades.
- Quando $y > 0$, os modelos que usam $\log(y)$ satisfazem MQO mais do que os modelos que usam o nível original de y .
- Log é útil para variáveis estritamente positivas com grandes valores e distribuição concentrada, tais como: renda, vendas de empresas, população, matrículas, empregados, votação.
- Log estreita amplitude dos valores, tornando estimativas menos sensíveis a observações extremas (*outliers*).
- Variáveis medidas em anos aparecem em forma original.
- Taxas geralmente aparecem em forma original.
- Log não é usado se variável tem valor zero ou negativo.
- Não é válido comparar R^2 entre modelos com y e $\log(y)$.

EXEMPLO 6: PNAD DE MINAS GERAIS DE 2007

– Logaritmo do rendimento como variável dependente:

```
. reg lnrenpri mulher idpia anest negra [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS	Number of obs = 15620		
Model	4047.56788	4	1011.89197	F(4, 15615) =	2227.96	
Residual	7092.0144	15615	.454179597	Prob > F =	0.0000	
Total	11139.5823	15619	.713207137	R-squared =	0.3634	
				Adj R-squared =	0.3632	
				Root MSE =	.67393	

lnrenpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-.5330765	.0111376	-47.86	0.000	-.5549075	-.5112455
idpia	.0215629	.0004636	46.51	0.000	.0206542	.0224716
anest	.1086479	.0014064	77.25	0.000	.1058911	.1114047
negra	-.1301593	.0111317	-11.69	0.000	-.1519786	-.1083399
_cons	4.921049	.025066	196.32	0.000	4.871917	4.970181

MODELOS COM FUNÇÕES QUADRÁTICAS

- Funções quadráticas são usadas para capturar efeitos marginais crescentes ou decrescentes.

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + u$$

- Sempre existe um valor positivo de x , no qual o efeito de x sobre y é zero, chamado de ponto crítico: $x^* = |\beta_1 / (2\beta_2)|$.
- Interpretações: (1) após ponto crítico, a relação se inverte; (2) após/antes ponto crítico, há poucos casos; (3) falta incluir variáveis; ou (4) falta transformar variáveis.
- Quando o coeficiente de x é positivo e o coeficiente de x^2 é negativo, a função quadrática tem um formato parabólico (\cap):
 - Antes desse ponto, x tem um efeito positivo sobre y .
 - Após esse ponto, x tem um efeito negativo sobre y .
- Se β_1 é negativo e β_2 é positivo, função tem formato U.

EXEMPLO 7: PNAD DE MINAS GERAIS DE 2007

– Transformação quadrática da idade:

```
. reg lnrenpri mulher idpia idquad anest negra [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS			
Model	4332.2922	5	866.458439	Number of obs =	15620	
Residual	6807.29008	15614	.43597349	F(5, 15614) =	1987.41	
Total	11139.5823	15619	.713207137	Prob > F =	0.0000	
				R-squared =	0.3889	
				Adj R-squared =	0.3887	
				Root MSE =	.66028	

lnrenpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-.5440937	.0109206	-49.82	0.000	-.5654994	-.522688
idpia	.088968	.0026764	33.24	0.000	.0837219	.0942141
idquad	-.0008933	.000035	-25.56	0.000	-.0009618	-.0008248
anest	.1067622	.0013799	77.37	0.000	.1040573	.109467
negra	-.1368042	.0109094	-12.54	0.000	-.1581878	-.1154205
_cons	3.805854	.0500742	76.00	0.000	3.707703	3.904005

– Se coeficiente de idade original é negativo e idade ao quadrado é positivo, função tem formato U.

– Se coeficiente de idade original é positivo e idade ao quadrado é negativo, função tem formato parabólico.

– Ponto crítico = $|\beta_1 / (2 \beta_2)| = |0.088968 / (2 * -0.0008933)| = 49,8$

MODELOS COM TERMOS DE INTERAÇÃO

- O efeito de uma variável independente, sobre a variável dependente, pode depender de outra variável explicativa:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2 + u$$

- O efeito parcial de x_2 sobre y é: $\Delta y / \Delta x_2 = \beta_2 + \beta_3 x_1$.
- β_2 é o efeito parcial de x_2 sobre y , quando $x_1 = 0$, o que pode não ser de interesse prático.
- Podemos então reparametrizar o modelo, tal como:

$$y = \alpha_0 + \delta_1 x_1 + \delta_2 x_2 + \beta_3 (x_1 - \mu_1)(x_2 - \mu_2) + u, \text{ sendo:}$$

μ_1 e μ_2 médias populacionais de x_1 e x_2 .

- δ_2 é o efeito parcial de x_2 sobre y no valor médio de x_1 :

$$\delta_2 = \beta_2 + \beta_3 \mu_1$$

- É complicado interpretar modelos com termos de interação.

EXEMPLO 8: PNAD DE MINAS GERAIS DE 2007

– Termo de interação entre idade e escolaridade (“idest”):

```
. reg lnrenpri mulher idpia anest negra idest [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS			
Model	4139.7391	5	827.94782	Number of obs =	15620	
Residual	6999.84317	15614	.44830557	F(5, 15614) =	1846.84	
Total	11139.5823	15619	.713207137	Prob > F =	0.0000	
				R-squared =	0.3716	
				Adj R-squared =	0.3714	
				Root MSE =	.66956	

lnrenpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-.5244468	.0110817	-47.33	0.000	-.5461683	-.5027253
idpia	.0090526	.0009866	9.18	0.000	.0071188	.0109865
anest	.0449341	.004658	9.65	0.000	.0358039	.0540643
negra	-.1319659	.0110602	-11.93	0.000	-.1536451	-.1102867
idest	.0016014	.0001117	14.34	0.000	.0013825	.0018203
_cons	5.437715	.0438012	124.15	0.000	5.35186	5.523571

– Efeito parcial de idade sobre renda em 2 anos de estudo:

$$\text{“idpia”} + (\text{“idest”} * \text{escolaridade}) = 0,01 + (0,002*2) = 1,2\%$$

– Efeito parcial de escolaridade sobre renda em 15 anos:

$$\text{“anest”} + (\text{“idest”} * \text{idade}) = 0,05 + (0,002*15) = 6,9\%$$

EXEMPLO 9: PNAD DE MINAS GERAIS DE 2007

– Interação de idade e escolaridade, centralizada na média:

```
. reg lnrenpri mulher idpia anest negra idestmed [aweight=v4729]
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS	Number of obs = 15620		
Model	4139.7391	5	827.94782	F(5, 15614) =	1846.84	
Residual	6999.84317	15614	.44830557	Prob > F =	0.0000	
Total	11139.5823	15619	.713207137	R-squared =	0.3716	
				Adj R-squared =	0.3714	
				Root MSE =	.66956	

lnrenpri	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
mulher	-.5244468	.0110817	-47.33	0.000	-.5461683	-.5027253
idpia	.0220666	.0004619	47.77	0.000	.0211611	.022972
anest	.1027652	.0014563	70.57	0.000	.0999107	.1056197
negra	-.1319659	.0110602	-11.93	0.000	-.1536451	-.1102867
idestmed	.0016014	.0001117	14.34	0.000	.0013825	.0018203
_cons	4.967743	.0251154	197.80	0.000	4.918514	5.016972

– Efeito parcial de anos de estudo sobre renda indica que o aumento de um ano de estudo aumenta a renda em 10,3%, considerando uma pessoa de idade média (36 anos).

“anest” + “idestmed” * (idade - idade média)

– Efeito parcial de idade sobre renda indica que o aumento de um ano de idade aumenta a renda em 2,2%, considerando uma pessoa de escolaridade média (8 anos de estudo).

VARIÁVEL CENTRALIZADA NA MÉDIA

- No exemplo abaixo, temos o efeito de idade (x_1) e escolaridade (x_2) sobre a renda (y), sendo que idade varia de 15 a 64 e escolaridade varia de 0 a 15:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u$$

- Não faz sentido interpretar β_0 , já que $\beta_1 x_1$ nunca será igual a zero (não temos idade igual a zero).
- Podemos reparametrizar o modelo, subtraindo a idade de cada unidade de análise pela média de idade na amostra.
- A equação abaixo ilustra o novo modelo populacional:

$$y = \beta_0 + \beta_1 (x_1 - \mu_1) + \beta_2 x_2 + u$$

- Neste caso, β_0 será o valor estimado de y quando a idade for igual à média e a escolaridade for igual a zero.

GRAU DE AJUSTE E SELEÇÃO DE REGRESSORES

- Seleção de variáveis explicativas com base no tamanho do R^2 pode levar a modelos absurdos.
- Nada nas hipóteses do modelo linear clássico exige que o R^2 esteja acima de qualquer valor em particular.
- O R^2 é simplesmente uma estimativa do quanto da variação em y é explicado por x_1, x_2, \dots, x_k na população.
- Modelos com R^2 pequenos significam que não incluímos fatores importantes, mas não necessariamente significam que fatores em u estão correlacionados com os x 's.
- O tamanho de R^2 não tem influência sobre a média dos resíduos ser igual a zero.
- R^2 pequeno sugere que variância do erro é grande em relação à variância de y , mas isso pode ser compensado por amostra grande.

R² AJUSTADO

- Sendo σ_y^2 a variância populacional de y e σ_u^2 a variância populacional do erro, R^2 da população é a proporção da variação em y na população, explicada pelas independentes:

$$R^2 = 1 - \sigma_u^2 / \sigma_y^2$$

- R^2 usual = $SQE/SQT = 1 - SQR/SQT = 1 - (SQR/n) / (SQT/n)$
- Podemos substituir o SQR/n e SQT/n , por termos não-viesados de σ_u^2 e σ_y^2 , e chegamos ao R^2 ajustado:

$$\begin{aligned} \bar{R}^2 &= 1 - [SQR/(n-k-1)] / [SQT/(n-1)] = 1 - \hat{\sigma}^2 / [SQT/(n-1)] \\ &= 1 - (1 - R^2)(n - 1)/(n - k - 1) \end{aligned}$$

- R^2 ajustado não corrige viés de R^2 na estimativa do R^2 da população, mas penaliza inclusão de independentes.
- R^2 ajustado negativo indica adaptação ruim do modelo, relativo ao número de graus de liberdade.

\bar{R}^2 NA ESCOLHA DE MODELOS NÃO-ANINHADOS

- O R^2 ajustado auxilia na escolha de modelo sem variáveis independentes redundantes (entre modelos não-aninhados).
- A estatística F (*test*) permite testar somente modelos aninhados.
- Por exemplo, podemos testar se modelo com informação de idade é melhor do que modelo com experiência no mercado de trabalho:

$$\text{renda} = \beta_0 + \beta_1 \text{escolaridade} + \beta_2 \text{idade} + u$$

$$\text{renda} = \beta_0 + \beta_1 \text{escolaridade} + \beta_2 \text{experiência} + u$$

- Neste caso, não queremos incluir as duas variáveis em conjunto, pois teoricamente medem a mesma dimensão.
- Estes são modelos não-aninhados, exigindo comparação do R^2 ajustado.

\bar{R}^2 E MODELOS COM DIFERENTES FORMAS FUNCIONAIS

- Comparação dos R^2 ajustados pode ser feita para optar entre modelos com formas funcionais diferentes das variáveis independentes:

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

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + u$$

- Não podemos usar nem o R^2 nem o R^2 ajustado para escolher entre modelos não-aninhados com diferentes formas funcionais da variável dependente.
- Os R^2 medem a proporção explicada do total da variação de qualquer variável dependente:
 - Portanto, diferentes funções da variável dependente terão diferentes montantes de variação a serem explicados.

Coeficientes estimados por modelos de mínimos quadrados ordinários para explicação do logaritmo do rendimento no trabalho principal (variável dependente), Minas Gerais, 2007.

Variáveis independentes	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 4 (beta padronizado)
Constante	4,5830*** (0,0590)	3,6660*** (0,0532)	3,7810*** (0,0539)	3,8060*** (0,0501)	
Idade	0,0858*** (0,0033)	0,0831*** (0,0029)	0,0832*** (0,0029)	0,0890*** (0,0027)	1,263
Idade ao quadrado	-0,0010*** (4,31e-05)	-0,0008*** (3,78e-05)	-0,0008*** (3,76e-05)	-0,0009*** (3,50e-05)	-0,973
Anos de escolaridade		0,0996*** (0,0014)	0,0956*** (0,0015)	0,1070*** (0,0014)	0,516
Cor/raça					
Branca			ref.	ref.	ref.
Negra (preta e parda)			-0,1360*** (0,0117)	-0,1370*** (0,0109)	-0,0801
Sexo					
Homem				ref.	ref.
Mulher				-0,5440*** (0,0109)	-0,315
R ²	0,0643	0,2860	0,2920	0,3890	0,3890
R ² ajustado	0,0640	0,2850	0,2920	0,3890	0,3890
Observações	15.620	15.620	15.620	15.620	15.620

Obs.: Erros padrão em parênteses.

* Significativo ao nível de confiança de 90%; ** Significativo ao nível de confiança de 95%; *** Significativo ao nível de confiança de 99%.

Fonte: Pesquisa Nacional por Amostra de Domicílios (PNAD) de 2007.

EXEMPLO 10: PNAD DE MINAS GERAIS DE 2007

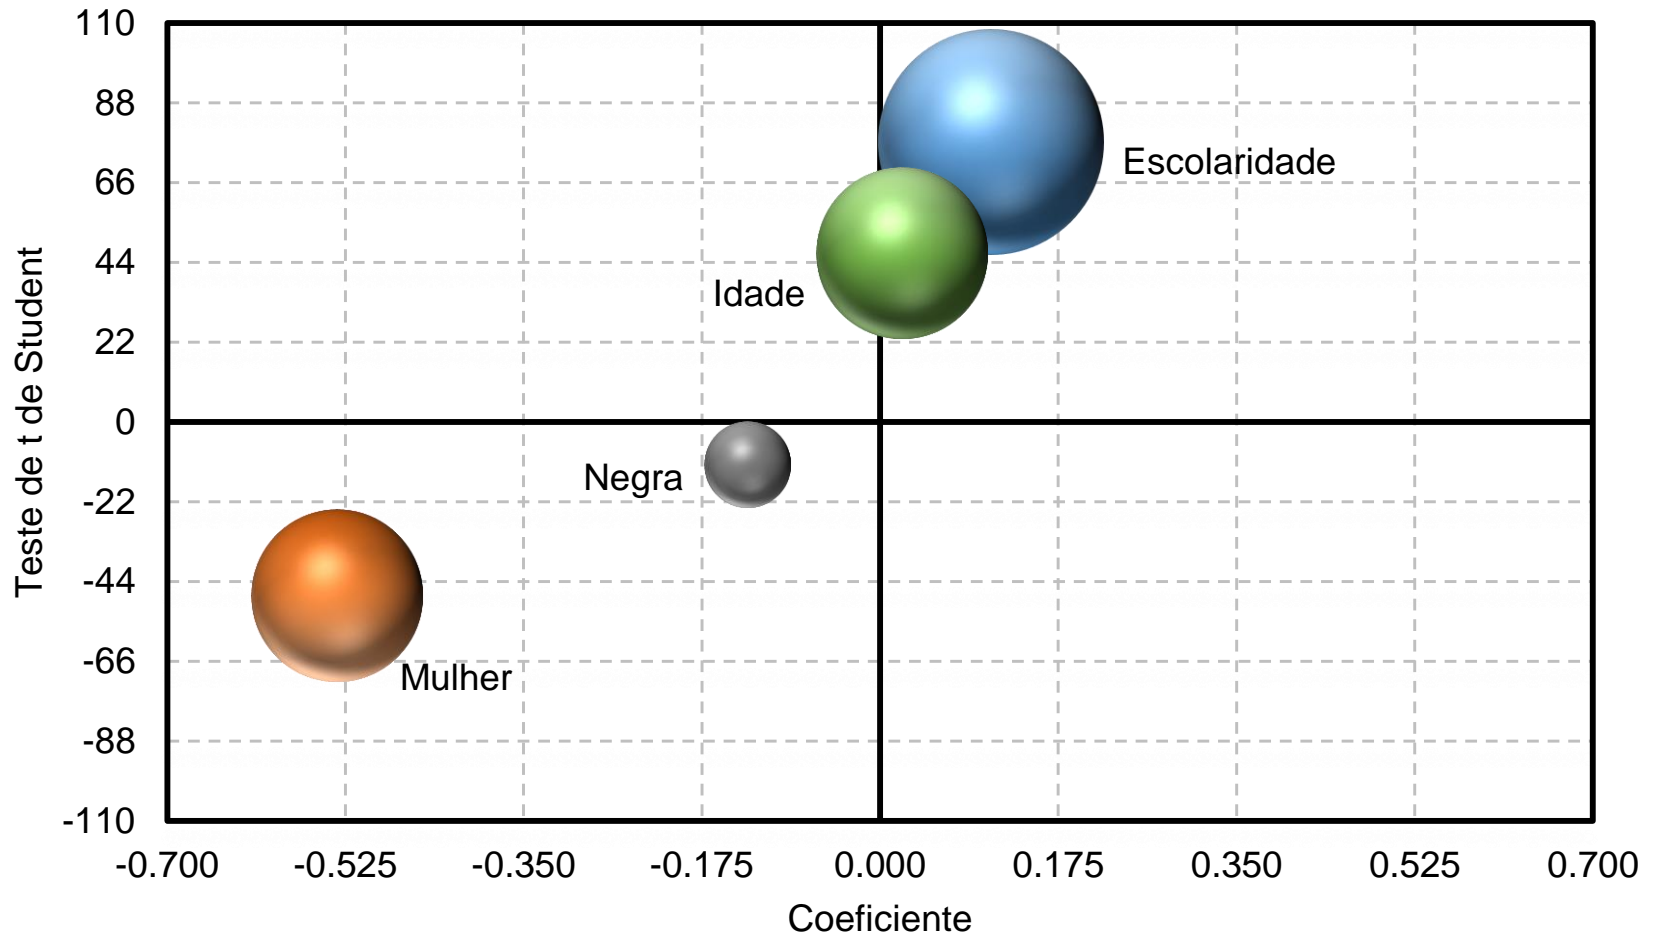
– Modelo para gerar gráfico de bolhas:

```
. reg lnrenpri mulher anest idpia negra [aweight=v4729], beta
(sum of wgt is 8.4198e+06)
```

Source	SS	df	MS	
Model	4047.56788	4	1011.89197	Number of obs = 15620
Residual	7092.0144	15615	.454179597	F(4, 15615) = 2227.96
Total	11139.5823	15619	.713207137	Prob > F = 0.0000
				R-squared = 0.3634
				Adj R-squared = 0.3632
				Root MSE = .67393

lnrenpri	Coef.	Std. Err.	t	P> t	Beta
mulher	-.5330765	.0111376	-47.86	0.000	-.3101769
anest	.1086479	.0014064	77.25	0.000	.5314987
idpia	.0215629	.0004636	46.51	0.000	.3090769
negra	-.1301593	.0111317	-11.69	0.000	-.0768943
_cons	4.921049	.025066	196.32	0.000	.

**Resultado de modelo de mínimos quadrados ordinários
para explicação do logaritmo de renda (variável dependente):
coeficiente (eixo horizontal), teste de *t* de *Student* (eixo vertical) e
beta padronizado (área da bolha) de variáveis independentes,
Minas Gerais, 2007**



CONTROLE DE MUITOS FATORES NA REGRESSÃO

- Estamos preocupados com omissão de fatores importantes que possam estar correlacionados com as variáveis independentes.
- Se enfatizarmos o R^2 , tenderemos a controlar fatores em um modelo que não deveriam ser controlados.
- Ao estudar o efeito da qualidade do ensino sobre a renda, talvez não faça sentido controlar os anos de escolaridade, pois subestimar o retorno da qualidade. Podemos estimar a equação com e sem anos de estudo.
- A questão de decidir se devemos ou não controlar certos fatores nem sempre é bem definida.
- Se nos concentrarmos na interpretação *ceteris paribus* da regressão, não incluiremos fatores no modelo, mesmo que estejam correlacionadas com a dependente.

ADIÇÃO DE FATORES: REDUZIR VARIÂNCIA DO ERRO

- A adição de uma nova variável independente pode aumentar o problema da multicolinearidade.
- Porém, ao adicionar uma variável, estamos reduzindo a variância do erro.
- Devemos incluir variáveis independentes que afetem y e que sejam não-correlacionadas com todas variáveis independentes, pois:
 - Não induzirá multicolinearidade.
 - Reduzirá variância do erro.
 - Diminuirá erros-padrão dos coeficientes beta, gerando estimativas mais precisas (estimador com menor variância do erro amostral).

INTERVALOS DE CONFIANÇA DE PREVISÕES

- Intenção é de mostrar como obter intervalos de confiança de previsões da linha de regressão MQO.

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \cdots + \hat{\beta}_k x_k$$

- O valor predito de cada observação leva em consideração os valores de todas variáveis independentes daquele caso.
- Porém, podemos querer estimar um intervalo de confiança de y com valores específicos das variáveis independentes.
- Para construir um intervalo de confiança de valores preditos, precisamos de um erro-padrão do parâmetro estimado.

INTERVALOS DE CONFIANÇA DA MÉDIA

- Podemos obter um intervalo de confiança de y , com base nos valores médios do conjunto de covariáveis:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1(x_{i1} - \mu_1) + \hat{\beta}_2(x_{i2} - \mu_2) + \dots + \hat{\beta}_k(x_{ik} - \mu_k)$$

- O β_0 previsto desta equação informa o valor estimado de y , quando todas covariáveis são iguais à media.
- Erro padrão do β_0 previsto é o erro padrão de y deste caso.
- O intervalo de confiança de 95% da média de y esperado será igual a:

$$\hat{\beta}_0 \pm 1,96[ep(\hat{\beta}_0)]$$

INTERVALOS DE CONFIANÇA INDIVIDUAL

- Intervalo de confiança de uma unidade particular da população deve levar em consideração a variância do erro não observado (fatores não observados que afetam y).
- **Intervalo de previsão** (y^0) é o valor para o qual gostaríamos de construir um intervalo de confiança.

– O **erro de previsão** é: $\hat{e}^0 = y^0 - \hat{y}^0$

– A **variância do erro de previsão** é:

$$Var(\hat{e}^0) = Var(\hat{y}^0) + Var(u^0) = Var(\hat{y}^0) + \sigma^2$$

– Em amostras grandes, variância de y pode ser pequena.

– **Erro padrão do erro de previsão**: $ep(\hat{e}^0) = \{[ep(\hat{y}^0)]^2 + \hat{\sigma}^2\}^{1/2}$

– **Intervalo de confiança** de 95% para y^0 :

$$\hat{y}^0 \pm t_{0,025} * ep(\hat{e}^0)$$

ANÁLISE DE RESÍDUOS

- É importante analisar os resíduos das observações individuais e examinar se valor efetivo da variável dependente está acima ou abaixo do valor previsto:

$$\hat{u}_i = y_i - \hat{y}_i$$

- Resíduo mais negativo indica valor observado mais baixo do que o previsto na regressão e vice-versa.

PREVISÃO DE y QUANDO A DEPENDENTE É $\log(y)$

- Temos um modelo de regressão:

$$\log(y) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$$

- A previsão de $\log(y)$ é dada por:

$$\widehat{\log(y)} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$$

- A previsão de y ocorre por:

$$\hat{y} = \exp(\hat{\sigma}^2 / 2) * \exp(\widehat{\log(y)})$$

... onde σ^2 é a variância de u estimado (*MS Residual*).

- Previsão de y que não depende da normalidade de u é:

$$\hat{y} = \hat{\alpha}_0 \exp(\widehat{\log(y)})$$

... onde α_0 é o valor esperado de $\exp(u)$.

OPERACIONALIZAÇÃO DA PREVISÃO QUANDO $\log(y_i)$

- Obtenha os valores estimados de $\log(y_i)$ da regressão:
 - *predict ypred*
- Para cada observação i , crie $\exp[\log(y_i)]$:
 - *gen ypredexp=exp(ypred)*
- Faça a regressão de y sobre a variável $ypredexp$ sem um intercepto (regressão simples passando pela origem):
 - *reg y ypredexp, nocons*
- O único coeficiente que existe na regressão acima é a estimativa de α_0 .
- Obtenha a previsão de y :
 - *gen yfinal = alfa * ypredexp*

R^2 QUANDO A DEPENDENTE É $\log(y)$

- Podemos usar o método anterior de obter previsões para determinar o quanto o modelo com $\log(y)$ como variável dependente explica bem a variável y .
- O objetivo é obter um indicador de grau de ajuste do modelo $\log(y)$ que possa ser comparado ao R^2 do modelo em que y é variável dependente.
- Após passos anteriores, encontramos a correlação amostral entre y estimado (y_{final}) e o verdadeiro y na amostra.
- O quadrado dessa correlação amostral pode ser comparado ao R^2 do modelo em que y é variável dependente.
- Na equação com y , o R^2 é a correlação quadrada entre y observado e y estimado.