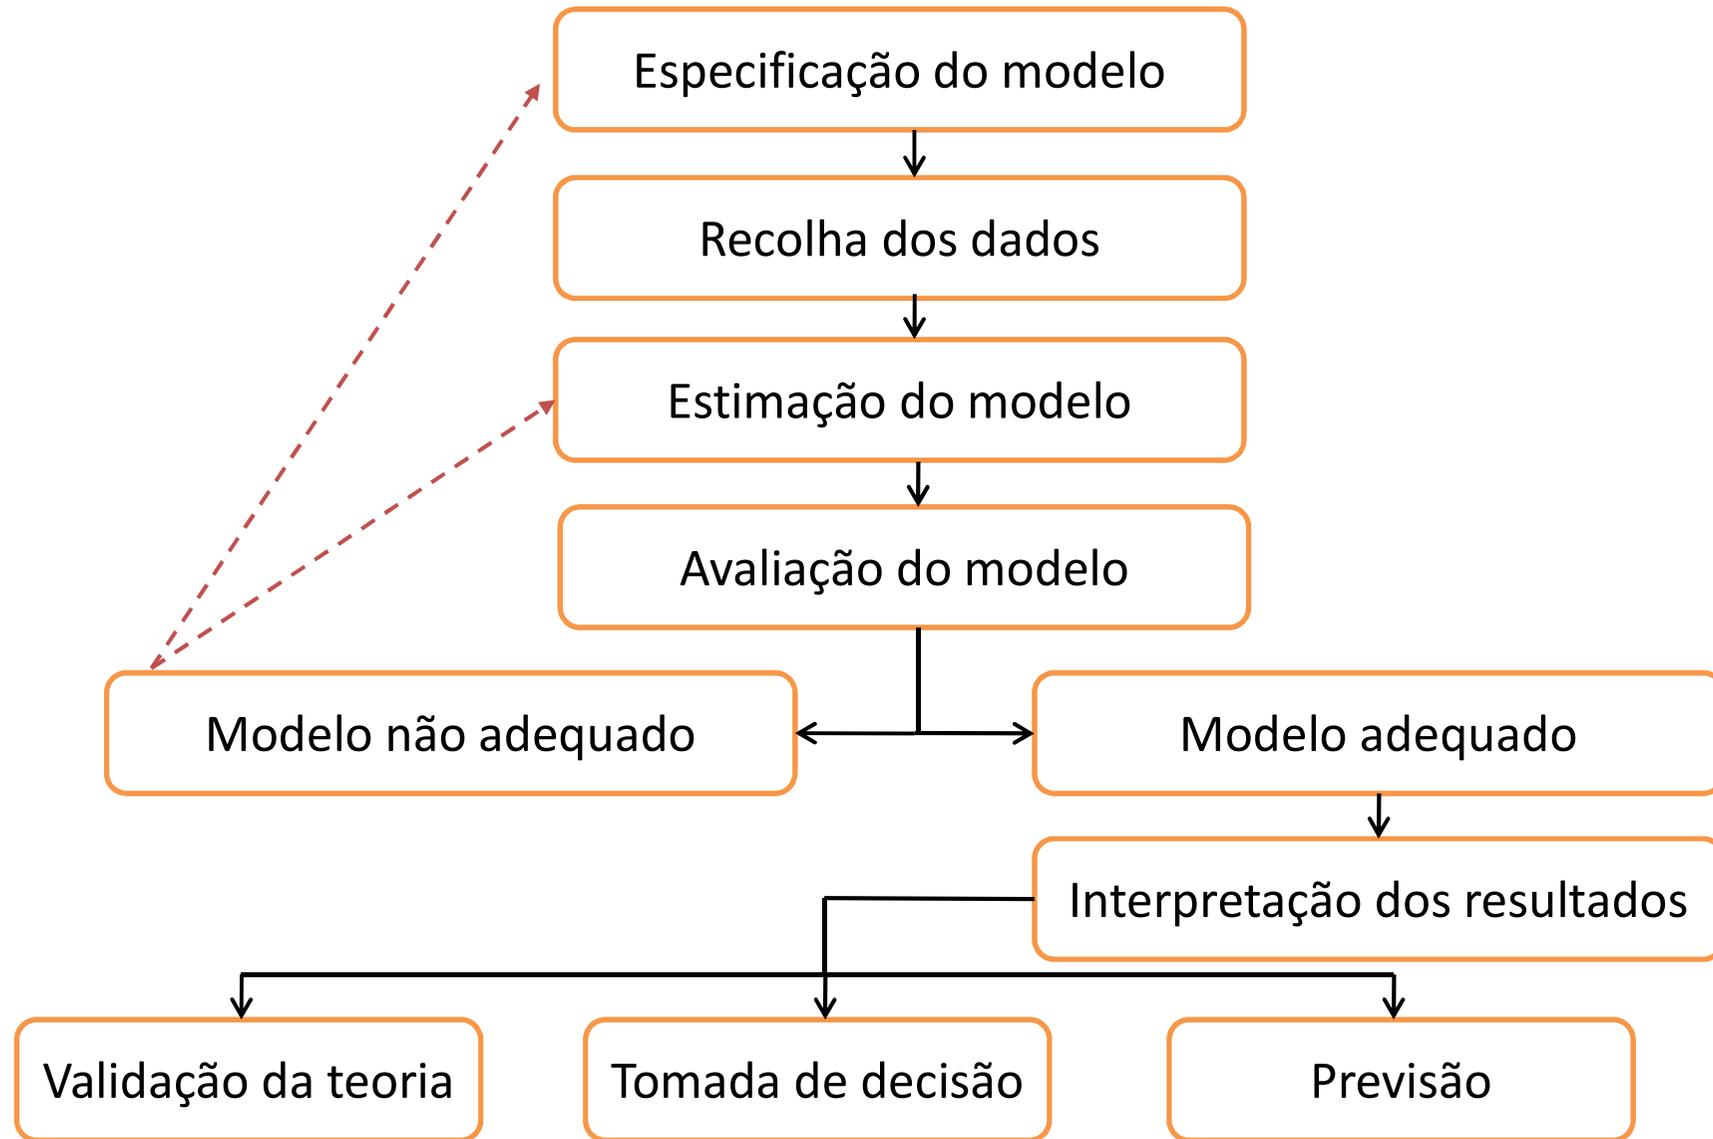


Econometria

- Noção:
 - Aplicação de técnicas estatísticas à análise de dados económicos, financeiros, sociais, etc. com o objectivo de estimar **relações** entre uma determinada **variável dependente** e um conjunto de **variáveis explicativas**
 - Exemplos:
 - Consumo = $f(\text{rendimento disponível})$
 - Salário = $f(\text{escolaridade, experiência, idade, género})$
- Finalidade:
 - Testar a validade de teorias
 - Efectuar previsões
 - Fundamentar quantitativamente políticas

Metodologia



Tipos de Dados

Dados seccionais:

- N indivíduos
- 1 observação por indivíduo

Dados temporais:

- 1 indivíduo
- T observações por indivíduo

Dados de painel

- N indivíduos
- T observações por indivíduo

Causalidade e análise ceteris paribus

Em econometria estudam-se frequentemente os **determinantes** de uma variável de interesse:

- verifica-se se as variáveis explicativas consideradas são **estatisticamente significativas** para explicar a variável de interesse, isto é, verifica-se se existe **relação de causalidade**
- Obtém-se o **efeito parcial / marginal** de cada variável explicativa sobre a variável de interesse, ceteris paribus, isto é, assumindo que tudo o resto se mantém constante. Pode interessar:
 - sinal do efeito (se positivo / negativo existe uma relação directa / inversa com a variável dependente)
 - magnitude

Objectivo / Motivação do Modelo de Regressão Linear Múltipla (MRLM)

Objectivo genérico: explicar $E(Y|X)$

Y : variável dependente / variável de interesse

X : variáveis explicativas / regressores

$E(Y|X)$: valor esperado para Y dado o valor de X

$E(Y|X)$ é função de um conjunto de parâmetros β que serão estimados

Especificação do MRLM

Especificação do Modelo:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i \quad (i = 1, \dots, N)$$
$$E(Y|X) = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k$$

u : termo erro – contém todos os factores explicativos de Y , para além dos incluídos em X

β : parâmetros – serão estimados

k : nº variáveis explicativas

$k + 1$: nº parâmetros (em modelos incluindo contante)

N : nº observações

Especificação do MRLM

Exemplo: factores incluídos em u_i

$$\text{salário_hora}_i = \beta_0 + \beta_1 \text{educ}_i + \beta_2 \text{exper}_i + u_i$$

u_i poderá incluir factores como género, região onde trabalha, motivação, ...

Valores ajustados, resíduos e estimação OLS

Valores ajustados: $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \dots + \hat{\beta}_k X_{ik}$

Resíduos: $\hat{u}_i = Y_i - \hat{Y}_i$

\hat{u} : resíduo

\hat{Y} : estimador de $E(Y|X)$

$\hat{\beta}$: estimador de β

Estimação do Modelo:

- Método dos Mínimos Quadrados (OLS): $\min \sum_{i=1}^N \hat{u}_i^2$

Interpretação dos coeficientes

Em geral, a interpretação de um coeficiente β_j consiste em avaliar a reacção do valor esperado condicional de Y dado X , $E(Y|X)$, a uma variação da variável explicativa X_j associada a β_j , mantendo tudo o resto constante

Modelo linear sem transformação das variáveis,

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i$$

Tem-se que

$$\Delta X_j = 1 \rightarrow \Delta E(Y|X) = \beta_j, \text{ ceteris paribus}$$

Interpretação dos coeficientes

Resumo:

Modelo linear nos parâmetros: $Y^* = X^* \beta + u$

Y^*	X^*	Interpretação
Y	X_j	$\Delta X_j = 1 \rightarrow \Delta E(Y X) = \beta_j$
$\ln(Y)$	X_j	$\Delta X_j = 1 \rightarrow \Delta E(Y X) = 100\beta_j\%$
Y	$\ln(X_j)$	$\Delta X_j = 1\% \rightarrow \Delta E(Y X) = \frac{\beta_j}{100}$
$\ln(Y)$	$\ln(X_j)$	$\Delta X_j = 1\% \rightarrow \Delta E(Y X) = \beta_j\%$
Y	X, X^2	$\Delta X_j = 1 \rightarrow \Delta E(Y X) = \beta_x + 2\beta_{x^2}X$

Interpretação dos coeficientes

Exemplo: considere o modelo

$$preço_i = \beta_0 + \beta_1 area_i + \beta_2 quartos_i + u_i$$

onde o preço de uma casa, em milhares de dólares, depende da área (m²) e do número de quartos. Estimou-se

$$\widehat{preço}_i = -19.286 + 1.384 area_i + 15.121 quartos_i$$

Admitindo tudo o resto constante:

- por cada variação unitária de área, isto é, por cada m² adicional, é de esperar que o preço médio das casas aumente 1.384 milhares de dólares
- por cada variação unitária de quartos, isto é, por cada quarto adicional, é de esperar que o preço médio das casas aumente 15.121 milhares de dólares

Interpretação dos coeficientes

Output em excel

SUMÁRIO DOS RESULTADOS						
Estatística de regressão						
R múltiplo	0,794906945					
Quadrado de R	0,63187705					
Quadrado de R ajustado	0,623215334					
Erro-padrão	63,04837628					
Observações	88					
ANOVA						
	gl	SQ	MQ	F	F de significância	
Regressão	2	579971,1994	289985,6	72,95056	3,58672E-19	
Residual	85	337883,3088	3975,098			
Total	87	917854,5083				
	Coefficientes	Erro-padrão	Stat t	valor P	95% inferior	95% superior
Interceptar	-19,28550028	31,0475285	-0,62116	0,536156	-81,0163048	42,44530424
quartos	15,12133684	9,488597692	1,593632	0,11473	-3,744537442	33,98721112
area	1,38360615	0,148943494	9,28947	1,4E-14	1,08746658	1,67974572

Interpretação dos coeficientes

Output em stata

```
. regress preco quartos area
```

Source	SS	df	MS			
Model	579971.198	2	289985.599	Number of obs	=	88
Residual	337883.308	85	3975.09774	F(2, 85)	=	72.95
Total	917854.506	87	10550.0518	Prob > F	=	0.0000
				R-squared	=	0.6319
				Adj R-squared	=	0.6232
				Root MSE	=	63.048

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
quartos	15.12134	9.488598	1.59	0.115	-3.744538	33.98721
area	1.383606	.1489435	9.29	0.000	1.087467	1.679746
_cons	-19.2855	31.04753	-0.62	0.536	-81.0163	42.4453

Interpretação dos coeficientes

Exemplo (continuação): retome o modelo

$$\widehat{preço}_i = -19.286 + 1.384area_i + 15.121quartos_i$$

Note-se que:

- o aumento estimado no preço médio pelo acrescento de um quarto (separação de um quarto em dois), mantendo tudo o resto contante (não alterando a área), é 15.121 milhares de dólares
- o aumento estimado no preço médio pelo acrescento de um quarto que aumenta a área da casa em 13m² é

$$\begin{aligned}\Delta\widehat{preço}_i &= 1.384\Delta area_i + 15.121\Delta quartos_i \\ &= 1.384 * 13 + 15.121 * 1 = 33.108 \text{ milhares de dólares}\end{aligned}$$

Interpretação dos coeficientes

Exemplo: considere outro modelo alternativo

$$\ln(\widehat{\text{preço}}_i) = 1.289 + 0.810\ln(\text{area}_i) + 0.038\text{quartos}_i$$

Admitindo tudo o resto constante:

- uma variação da área de 1% gera um aumento no preço médio das casas de 0.810%
- por cada quarto adicional, o preço médio das casas aumenta 3.8%

Note-se que $\ln(\cdot)$ apenas é definido para valores positivos das variáveis, por isso não se aplicou a *quartos* já que *quartos* pode assumir o valor 0

Interpretação dos coeficientes

Output em stata

```
. generate lpreco=ln(preco)
. generate larea=ln(area)
. regress lpreco quartos larea
```

Source	SS	df	MS	Number of obs	=	88
Model	4.50364223	2	2.25182112	F(2, 85)	=	54.47
Residual	3.51396129	85	.041340721	Prob > F	=	0.0000
-----+-----				R-squared	=	0.5617
Total	8.01760352	87	.092156362	Adj R-squared	=	0.5514
-----+-----				Root MSE	=	.20332

lpreco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
quartos	.0376464	.0303446	1.24	0.218	-.0226868	.0979795
larea	.8100637	.0987611	8.20	0.000	.6137002	1.006427
_cons	1.28929	.4666125	2.76	0.007	.3615395	2.217041

Decomposição da variação e coeficiente de determinação

- Quadro de análise de variância: decomposição da variação total de Y

	SS	DF	MS
Explicados	$\sum (\hat{y}_i - \bar{y})^2$	k	MSE
Residual	$\sum \hat{u}_i^2$	N-k-1	$MSR = \hat{\sigma}^2$
Total	$\sum (y_i - \bar{y})^2$	N-1	s_y^2

- Coeficiente de determinação:

$$R^2 = \frac{SSE}{SST}, 0 \leq R^2 \leq 1$$

Mede a proporção da variação de Y explicada pela regressão

Coeficiente de determinação

- Formas alternativas do coeficiente de determinação e comparação de modelos:

$R^2 = \frac{SSE}{SST}$	$\bar{R}^2 = 1 - (1 - R^2) \frac{N - 1}{N - k - 1}$
Mod. com constante	Mod. com constante
Mod. com a mesma variável dependente	Mod. com a mesma variável dependente
Mod. com k igual	

- Tipicamente, o software apresenta R^2 e a sua versão ajustada \bar{R}^2
- Aumentando o número de regressores, R^2 aumenta necessariamente – limitação na sua utilização
- Um R^2 elevado (baixo) não significa que o modelo descreva (não descreva) convenientemente os dados: será necessário testar a validade do modelo

Pressupostos do MRLM e propriedades do estimador OLS

Pressupostos:

1. Modelo linear nos parâmetros: $Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i$
2. Amostra aleatória
3. $E(u|X) = 0$
4. Ausência de colineariedade perfeita
5. Homoscedasticidade: $Var(u|X) = \sigma^2$
6. Normalidade do erro: $u \sim Normal(0, \sigma^2)$

Pequenas amostras	Propriedades assintóticas
1-4: estimadores centrados	1-4: estimadores consistentes
1-5: estimadores centrados e eficientes	1-5: estimadores consistentes, eficientes e normalmente distribuídos
1-6: estimadores centrados, eficientes e normalmente distribuídos	

Variáveis explicativas omitidas e variáveis explicativas irrelevantes

Aquando da escolha dos regressores a incluir no modelo, deve-se ter em conta que:

- Regressores em excesso geram redução de eficiência
- Omissão de regressores (tendo em conta que os regressores omitidos estão incluídos no erro u) gera:
 - Inconsistência se $E(U|X) \neq 0 \rightarrow$ endogeneidade
 - Consistência se $E(U|X) = 0 \rightarrow$ exogeneidade

Multicolinearidade

Problema: $\sigma_{\beta_j}, j = 1, \dots, k$ vem inflacionado, gerando-se estimadores com pouca precisão. Contudo, o estimador OLS de β continua consistente

Causa: decorre do facto de dois ou mais regressores estarem altamente correlacionados. Dado que se mostra que

$$\sigma_{\beta_j}^2 = \frac{\sigma^2}{(1 - R_j^2) \sum_{i=1}^N (X_{ij} - \bar{X}_j)^2}$$

onde R_j^2 é o coeficiente de determinação da regressão auxiliar de X_j sobre os restantes regressores, verifica-se que a variância de β_j aumenta quando :

- A variância condicional do erro, σ^2 , aumenta
- a variação total de X_j diminui
- R_j^2 , que mede o grau de associação entre X_j e os restantes

Distribuição por amostragem do estimador OLS, estatística t e intervalo de confiança para um parâmetro

Com $U \sim N(0, \sigma^2)$, $Y|X \sim N(X\beta, \sigma^2 I)$ e $\hat{\beta} \sim N(\beta, \sigma^2 (X'X)^{-1})$ sendo

$$\hat{\beta}_j \sim N(\beta_j, \sigma_{\beta_j}^2)$$

Estandarizando $\hat{\beta}_j$ tem-se

$$\frac{\hat{\beta}_j - \beta_j}{\sigma_{\beta_j}} \sim N(0, 1)$$

que não se usa directamente, pois σ_{β_j} é desconhecido. Utilizando $\hat{\sigma}_{\beta_j}^2$, tem-se

$$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\beta_j}} \sim t(N - k - 1)$$

Intervalo de confiança para um parâmetro

Tendo em conta o rácio t

$$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\beta_j}} \sim t(N - k - 1)$$

Obtém-se o intervalo de confiança para β_j

$$\left(\hat{\beta}_j - t_{N-k-1}^{\alpha/2} \hat{\sigma}_{\beta_j}; \hat{\beta}_j + t_{N-k-1}^{\alpha/2} \hat{\sigma}_{\beta_j} \right)$$

com $(1 - \alpha)100\%$ de confiança, β_j estará contido neste intervalo

Estatística t: principais variantes

Teste à significância (individual) estatística de um regressor:

Hipóteses	t_j	Nota
$H_0: \beta_j = 0$ $H_1: \beta_j \neq 0$	$\frac{\hat{\beta}_j}{\hat{\sigma}_{\beta_j}}$	Apresentando automaticamente nos output da regressão

Teste ao sinal de um coeficiente:

Hipóteses	t_j	Nota
$H_0: \beta_j = 0$ $H_1: \beta_j > 0$ ($H_1: \beta_j < 0$)	$\frac{\hat{\beta}_j}{\hat{\sigma}_{\beta_j}}$	Região de rejeição unilateral direita (esquerda)

Teste para um valor particular de um coeficiente (c):

Hipóteses	t_j	Nota
$H_0: \beta_j = c$ $H_1: \beta_j \neq c$ ($H_1: \beta_j > c$ ou $H_1: \beta_j < c$)	$\frac{\hat{\beta}_j - c}{\hat{\sigma}_{\beta_j}}$	Região de rejeição bilateral (unilateral à direita ou esquerda)

Testes sobre uma combinação linear de coeficientes

Pretende-se testar por exemplo

$$H_0: \beta_1 = \beta_2$$

A estatística de teste é então

$$t_{\hat{\delta}} = \frac{\hat{\beta}_1 - \hat{\beta}_2 - 0}{\hat{\sigma}_{\hat{\beta}_1 - \hat{\beta}_2}} \sim t(N - k - 1)$$

Testes sobre uma combinação linear de coeficientes

Exemplo: Testes de significância individual (retomar output Excel)

$$\widehat{preço}_i = -19.286 + 1.384 \text{ area}_i + 15.121 \text{ quartos}_i$$

(0.149) (9.489)

SUMÁRIO DOS RESULTADOS						
Estatística de regressão						
R múltiplo	0.794906945					
Quadrado de R	0.63187705					
Quadrado de R ajustado	0.623215334					
Erro-padrão	63.04837628					
Observações	88					
ANOVA						
	gl	SQ	MQ	F	F de significância	
Regressão	2	579971.1994	289985.6	72.95056	3.58672E-19	
Residual	85	337883.3088	3975.098			
Total	87	917854.5083				
	Coeficientes	Erro-padrão	Stat t	valor P	95% inferior	95% superior
Interceptar	-19.28550028	31.0475285	-0.62116	0.536156	-81.0163048	42.44530424
quartos	15.12133684	9.488597692	1.593632	0.11473	-3.744537442	33.98721112
area	1.38360615	0.148943494	9.28947	1.4E-14	1.08746658	1.67974572

A 5% de significância, apenas área é individualmente significativa

Testes sobre uma combinação linear de coeficientes

Exemplo (continuação): Retoma-se o output do STATA

```
. regress preco area quartos
```

Source	SS	df	MS	Number of obs = 88		
Model	579971.198	2	289985.599	F(2, 85)	=	72.95
Residual	337883.308	85	3975.09774	Prob > F	=	0.0000
-----+-----				R-squared	=	0.6319
Total	917854.506	87	10550.0518	Adj R-squared	=	0.6232
-----+-----				Root MSE	=	63.048

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
area	1.383606	.1489435	9.29	0.000	1.087467	1.679746
quartos	15.12134	9.488598	1.59	0.115	-3.744538	33.98721
_cons	-19.2855	31.04753	-0.62	0.536	-81.0163	42.4453

Testes sobre uma combinação linear de coeficientes

Exemplo: no âmbito do modelo anterior, testar se o efeito de área e quartos é igual

$$\widehat{preço}_i = -19.286 + \underset{(0.149)}{1.384} \textit{area}_i + \underset{(9.489)}{15.121} \textit{quartos}_i$$

$$H_0: \beta_1 = \beta_2$$

```
. test area==quartos
( 1)  area - quartos = 0
      F( 1, 85) = 2.06
      Prob > F = 0.1548
```

Não se rejeita a hipótese de igualdade dos dois efeitos

Testes sobre várias combinações lineares de coeficientes

Hipóteses em teste

1. Teste à significância conjunta de alguns regressores:

$$H_0: \beta_{p+1} = \dots = \beta_k = 0 \quad (Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip} + u_i) \rightarrow R_*^2$$

$$H_1: \exists \beta_j \neq 0, j = p+1, \dots, k \quad (Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip} + \beta_{p+1} X_{ip+1} + \dots + \beta_k X_{ik} + u_i) \rightarrow R^2$$

2. Teste de significância global:

$$H_0: \beta_1 = \dots = \beta_k = 0 \quad (Y_i = \beta_0) \rightarrow R_*^2 = 0$$

$$H_1: \exists \beta_j \neq 0, j = 1, \dots, k \quad (Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i) \rightarrow R^2$$

Notas:

- Pode-se considerar $H_0: R^2 = 0$ (ausência de ajustamento)
- A magnitude do R^2 não é interpretável: deve-se fazer o teste F de ajustamento global

Testes sobre várias combinações lineares de coeficientes

Estatística de teste:

1. Teste à significância conjunta de alguns regressores:

$$F = \frac{(R^2 - R_*^2)/m}{(1 - R^2)/(N - K - 1)} \sim F(m, N - k - 1)$$

onde m é o # restrições (# β 's em teste sob H_0)

2. Teste de significância global:

$$F = \frac{(R^2)/m}{(1 - R^2)/(N - K - 1)} \sim F(m = k, N - k - 1)$$

Região de rejeição: aba direita da distribuição F

Testes t e F

Exemplo: escolha entre os dois modelos seguintes

$$preço_i = \beta_0 + \beta_1 area_i + \beta_2 quartos_i + \beta_3 lote_i + u_i$$

$$preço_i = \beta_0 + \beta_2 quartos_i + e_i$$

$$H_0: \beta_1 = \beta_3 = 0 \text{ (mod. restrito)}$$

$$H_1: \text{não } H_0$$

$$\rightarrow R_*^2 = 0.258$$

$$\rightarrow R^2 = 0.672$$

$$F = \frac{(0.672 - 0.258)/2}{(1 - 0.672)/(88 - 3 - 1)} = 53.06$$

A 5% de significância, $F(2,84) \simeq 18$. Rejeita-se H_0 : escolhe-se o modelo alargado

Testes t e F

Exemplo (continuação):

Output STATA

```
. regress preco area lote quartos
```

Source	SS	df	MS	Number of obs =	88
Model	617018.847	3	205672.949	F(3, 84) =	57.43
Residual	300835.658	84	3581.37688	Prob > F =	0.0000
Total	917854.506	87	10550.0518	R-squared =	0.6722

Adj R-squared = 0.6605
Root MSE = 59.845

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
area	1.322524	.1426449	9.27	0.000	1.038859	1.606189
lote	.0222365	.0069137	3.22	0.002	.0084878	.0359852
quartos	13.7864	9.015998	1.53	0.130	-4.142903	31.7157
_cons	-21.72645	29.47964	-0.74	0.463	-80.34994	36.89704

```
. test área quartos
```

```
(...)
```

Testes t e F

Exemplo: teste ao ajustamento global / significância conjunta dos regressores

$$preço_i = \beta_0 + \beta_1 area_i + \beta_2 quartos_i + \beta_3 lote_i + u_i$$

$H_0: \beta_1 = \beta_2 = \beta_3 = 0$ (sem significância conjunta)

$H_1: \text{não } H_0$

$\rightarrow R^2 = 0.672$

$$F = \frac{0.672/3}{(1 - 0.672)/(88 - 3 - 1)} = 57.43$$

A 5% de significância, $F(3,84) \simeq 8,0$

Rejeita-se H_0 : evidência de ajustamento global / os regressores são conjuntamente significativos

A estatística de teste e respectivo p-value é dada no output de *regress* no STATA (ver resultados a verde)

Notas sobre testes assintóticos

Quando a amostra é grande, dispensa-se o pressuposto (6), relativo à normalidade de u

- Teste a coeficientes individuais:

$$t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\beta_j}} \sim N(0,1)$$

Embora também se possa utilizar $t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\beta_j}} \sim t(N - k - 1)$

- Teste a conjuntos de coeficientes:
 - Utiliza-se o teste F, apesar da distribuição ser apenas aproximada
 - Pode-se aplicar o **teste LM** (Lagrange multiplier), que se executa de forma muito fácil no caso do **teste de ajustamento global**:

$$LM = NR^2 \sim X_k^2$$

- **Região de rejeição:** aba direita da distribuição *Qui-quadrado*

Notas sobre testes assintóticos

Exemplo: testar a significância conjunta dos regressores pelo teste LM no âmbito do modelo

$$preço_i = \beta_0 + \beta_1 area_i + \beta_2 quartos_i + \beta_3 lote_i + u_i$$

$H_0: \beta_1 = \beta_2 = \beta_3 = 0$ (ausência de significância conjunta)

$H_1: \text{não } H_0$

$$LM = 88 * 0.6722 = 59.154$$

A 5% de significância, o valor crítico é $X_3^2 = 7.815$. Rejeita-se H_0

Introdução de determinantes qualitativos

Existem factores explicativos do valor esperado condicionado da variável dependente que são de natureza qualitativa:

- Preço de imóveis = $f(\text{área, nº quartos, qualidade da localização, tipo de imóvel})$
- Salário = $f(\text{idade, experiencia profissional, tipo de profissão, género, região local trabalho})$

A introdução dos factores qualitativos é feita por meio de variáveis artificiais, designadas de variáveis dummy, que têm a particularidade de apenas poderem assumir o valor 1 ou 0

$$d = \begin{cases} 1 & \text{se atributo observado} \\ 0 & \text{se atributo não observado} \end{cases}$$

Introdução de determinantes qualitativos

Representação de duas categorias: requer a inclusão de uma dummy

$$d = \begin{cases} 1 & \text{se atributo observado (ex: homem)} \\ 0 & \text{se atributo não observado (ex: mulher)} \end{cases}$$

Representação de M categorias: requer a introdução de M-1 dummies

$$d_1 = \begin{cases} 1 & \text{se atributo 1 observado (ex: região Sul)} \\ 0 & \text{se atributo não observado (ex: outras regiões)} \end{cases}$$
$$d_2 = \begin{cases} 1 & \text{se atributo 2 observado (ex: região Centro)} \\ 0 & \text{se atributo não observado (ex: outras regiões)} \end{cases}$$

Em ambos os casos a interpretação do efeito sobre o valor esperado é feita por referência ao atributo omitido: no primeiro exemplo o ser mulher e no segundo o pertencer à região Norte

Introdução de determinantes qualitativos

Exemplo:

$$Y_i = \beta_0 + \beta_1 \text{masc}_i + \beta_2 \text{sul}_i + \beta_3 \text{centro}_i + u_i$$

β_1 : diferença no valor de Y de um homem relativamente a uma mulher;

β_2 : diferença em Y de um indivíduo que vive no Sul, relativamente a um indivíduo que vive no Norte

β_3 : diferença em Y de um indivíduo que vive no Centro, relativamente a um indivíduo que vive no Norte

Ajustamento para a interpretação quando o modelo é log-lin:

$$(e^{\beta_j} - 1)100\%$$

Importante quando β_j é de grande magnitude. Por exemplo

- $(e^{0.457-0.063} - 1)100\% = 48.3\%$
- $(e^{-0.063} - 1)100\% = -6,1 \%$

Introdução de determinantes qualitativos

Variável de interação: resulta da multiplicação de uma dummy por outra variável

Exemplo:

$$\text{salario}_i = \beta_0 + \beta_1 \text{masc}_i + \beta_2 \text{educ}_i + \beta_3 \text{masc} * \text{educ}_i + u_i$$

Escrevendo o modelo para cada grupo:

- homens (masc=1): $\text{salario}_i = (\beta_0 + \beta_1) + (\beta_2 + \beta_3)\text{educ}_i + u_i$
- mulheres (masc=0): $\text{salario}_i = \beta_0 + \beta_2\text{educ}_i + u_i$

Logo:

- β_0 : termo independente relativo às mulheres
- β_1 : diferença no termo independente entre os homens e as mulheres
- β_2 : acréscimo que se verifica no salário das mulheres por cada ano de escolaridade adicional
- β_3 : diferença que se verifica no efeito anterior entre os homens e as mulheres.

Introdução de determinantes qualitativos

Teste de Chow para a Quebra de Estrutura:

- Contexto:

- Dois grupos de indivíduos / empresas: G_A, G_B
- Suspeita-se que o comportamento dos dois grupos no que diz respeito à variável dependente tenha diferentes determinantes

- Implementação:

- Gerar a variável binária $D = \begin{cases} 1 & \text{se a observação pertence a } G_A \\ 0 & \text{se a observação não pertence a } G_A \end{cases}$

- Estimar o modelo original de forma 'duplicada':

$$Y = \theta_0 + \theta_1 X_1 + \dots + \theta_k X_k + \gamma_0 D + \gamma_1 D X_1 + \dots + \gamma_k D X_k + v$$

- Aplicar um teste F para a significância das variáveis envolvendo D :

$$H_0: \gamma_0 = \gamma_1 = \dots = \gamma_k = 0 \text{ (sem quebra de estrutura)}$$

$$H_1: \text{Não } H_0 \text{ (com quebra de estrutura)}$$

Teste à forma funcional - RESET

Modelo em teste: $Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i$

Teste F para a significância de um sub-conjunto de parâmetros, onde o modelo sob H_1 é uma regressão auxiliar que acrescenta ao original potências de \hat{Y} (isto é, de $X\hat{\beta}$): $\hat{Y}^2 = (X\hat{\beta})^2$, $\hat{Y}^3 = (X\hat{\beta})^3 \dots$

$H_0: \gamma_1 = \dots = \gamma_k = 0$ ($Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i$) \rightarrow FF correcta $\rightarrow R_*^2$

$H_1: n H_0$ ($Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + \gamma_1 \hat{Y}_i^2 + \gamma_2 \hat{Y}_i^3 \dots + v$) \rightarrow FF incorrecta $\rightarrow R^2$

Nota: a rejeição de H_0 requer que se procure outra forma funcional alternativa - o modelo alternativo de H_1 é uma regressão auxiliar, não é candidato a modelo alternativo

Forma funcional - RESET

Exemplo: testar a forma funcional de

$$preço_i = \beta_0 + \beta_1 area_i + \beta_2 quartos_i + u_i$$

```
regress preco quartos area
```

Source	SS	df	MS			
Model	579971.198	2	289985.599	Number of obs =	88	
Residual	337883.308	85	3975.09774	F(2, 85) =	72.95	
Total	917854.506	87	10550.0518	Prob > F =	0.0000	
				R-squared =	0.6319	
				Adj R-squared =	0.6232	
				Root MSE =	63.048	

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
quartos	15.12134	9.488598	1.59	0.115	-3.744538	33.98721
area	1.383606	.1489435	9.29	0.000	1.087467	1.679746
_cons	-19.2855	31.04753	-0.62	0.536	-81.0163	42.4453

```
. predict precohat  
(option xb assumed; fitted values)  
  
. generate precohat2=precohat^2  
  
. generate precohat3=precohat^3
```

Forma funcional - RESET

Exemplo (continuação):

```
. regress preco quartos area precohat2 precohat3
```

Source	SS	df	MS	Number of obs =	88
Model	610249.039	4	152562.26	F(4, 83) =	41.17
Residual	307605.467	83	3706.08996	Prob > F =	0.0000
				R-squared =	0.6649
				Adj R-squared =	0.6487
				Root MSE =	60.878
Total	917854.506	87	10550.0518		

preco	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
quartos	-58.37904	38.71904	-1.51	0.135	-135.3897 18.63158
area	-5.680895	3.613211	-1.57	0.120	-12.86743 1.505637
precohat2	.0133394	.0076821	1.74	0.086	-.0019399 .0286187
precohat3	-.0000109	7.20e-06	-1.52	0.133	-.0000252 3.40e-06
_cons	675.0476	328.2222	2.06	0.043	22.22683 1327.868

$H_0: \gamma_1 = \gamma_2 = 0 \rightarrow$ FF correcta

$$F = \frac{(0.6649 - 0.631^*)/2}{(1 - 0.6649)/(88 - 5)} = 4.08$$

A 5% de significância, $F(2,83) =$

Rejeita-se H_0 : a FF não é válida

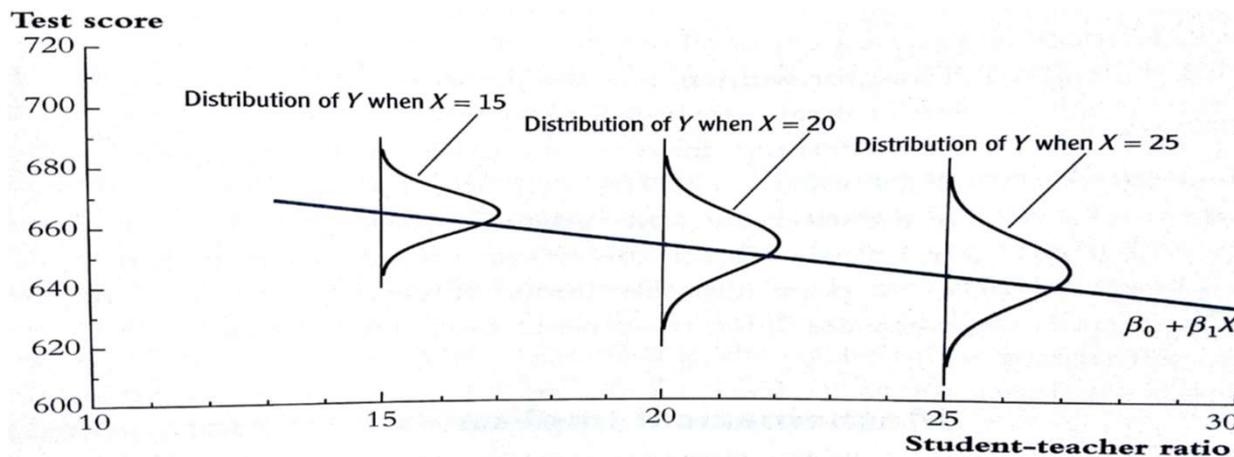
Heteroscedasticidade: motivação e definição

Variância condicional do erro (skedastic function): $Var(u|X)$

Pressuposto (5): $Var(u|X) = \sigma^2$ (homocedasticidade)

Falha do pressuposto (5): $Var(u|X) = \sigma^2 h(X)$ (heteroscedasticidade)

- Ilustração:



O pressuposto (5) garante a eficiência e a normalidade assintótica dos estimadores OLS, mas não coloca em causa o seu não enviesamento ou consistência. Assim, **os estimadores dos MQ continuam a ser centrados e consistentes mas perdem a eficiência e normalidade assintótica.**

Além disto, a fórmula da variância deixa de ser válida

Heteroscedasticidade: estimação robusta da matriz de covariâncias

Dado que os estimadores OLS continuam a ser centrados e consistentes, corrige-se apenas a sua variância

Variância standard (assume $Var(U|X) = \sigma^2 I$)

$$\begin{aligned} Var(\hat{\beta}) &= (X'X)^{-1}X'Var(U|X)X(X'X)^{-1} \\ &= \sigma^2(X'X)^{-1}X'X(X'X)^{-1} = \sigma^2(X'X)^{-1} \end{aligned}$$

Variância robusta (assume $Var(\dot{U}|X) = \Sigma$)

$$\begin{aligned} Var(\hat{\beta}) &= (X'X)^{-1}X'Var(U|X)X(X'X)^{-1} \\ &= (X'X)^{-1}X'\Sigma X(X'X)^{-1} \end{aligned}$$

onde $\Sigma = diag(\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2)$ para u_i independentes mas com variâncias σ_i^2

A implementação é simples mas o método é apenas válido assintoticamente e os estimadores não são eficientes.

Heteroscedasticidade: estimação robusta da matriz de covariâncias

Exemplo (continuação): estimação de variâncias robustas (os coeficientes serão iguais aos do OLS)

```
. regress preco quartos area, robust  
Linear regression
```

```
Number of obs =      88  
F( 2,      85) =    27.22  
Prob > F      =    0.0000  
R-squared     =    0.6319  
Root MSE     =    63.048
```

		Robust				
	Coef.	Std. Err.	t.	P> t	[95% Conf. Interval]	
preco						
quartos	15.12134	8.96599	1.69	0.095	-2.705452	32.94813
area	1.383606	.2111629	6.55	0.000	.9637578	1.803455
_cons	-19.2855	41.54017	-0.46	0.644	-101.8785	63.30749

$$\widehat{preço}_i = -19.286 + 1.384 \text{ area}_i + 15.121 \text{ quartos}_i$$

(0.149)(9.489)

[0.211][8.966]

Heteroscedasticidade: testes para detecção

Há vários testes, todos baseados em regressões auxiliares com variável dependente \hat{u}^2 , onde a significância global dos parâmetros é testada através dum teste F / LM.

Modelo base:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{ik} + u_i$$

H_0 : Homocedasticidade $\rightarrow Var(u|X) = \sigma^2$ (usar OLS)

H_1 : Heteroscedasticidade $\rightarrow Var(u|X) = \sigma^2 h(X)$ (usar variâncias robustas)

1. Procedimento comum: estimar o modelo base por OLS e obter \hat{u}^2

Heteroscedasticidade: testes para detecção

2. Estimar a regressão auxiliar:

- Breusch Pagan: $\hat{u}^2 = \gamma_0 + \gamma_1 X_1 + \dots + \gamma_k X_k + e$

e obter $R_{\hat{u}^2}^2$

3. Estatística de teste e distribuição:

$$F = \frac{R_{\hat{u}^2}^2/k}{(1 - R_{\hat{u}^2}^2)/(N - k - 1)} \sim F(k, N - k - 1)$$

ou

$$LM = NR_{\hat{u}^2}^2 \sim X_k^2$$

Heteroscedasticidade: testes para detecção

Exemplo: testar heteroscedasticidade no âmbito do modelo

$$\ln(\text{preço}_i) = \beta_0 + \beta_1 \ln(\text{area}_i) + \beta_2 \text{quartos}_i + u_i$$

```
gen larea=log(area)
gen lpreço=log(preço)
regress lpreço larea quartos
```

Source	SS	df	MS	Number of obs =	88
Model	4.50364223	2	2.25182112	F(2, 85) =	54.47
Residual	3.51396129	85	.041340721	Prob > F =	0.0000
Total	8.01760352	87	.092156362	R-squared =	0.5617
				Adj R-squared =	0.5514
				Root MSE =	.20332

lpreço	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
larea	.8100637	.0987611	8.20	0.000	.6137002	1.006427
quartos	.0376464	.0303446	1.24	0.218	-.0226868	.0979795
_cons	1.28929	.4666125	2.76	0.007	.3615395	2.217041

```
predict uhat, resid
gen uhat2=uhat^2
```

Heteroscedasticidade: testes para detecção

Exemplo (continuação):

Teste BP:

```
regress uhat2 larea quartos
```

Source	SS	df	MS	Number of obs = 88		
Model	.026033827	2	.013016913	F(2, 85) =	1.93	
Residual	.573679783	85	.006749174	Prob > F =	0.1516	
-----+-----				R-squared =	0.0434	
Total	.59971361	87	.00689326	Adj R-squared =	0.0209	
-----+-----				Root MSE =	.08215	
uhat2	Coef.	Std. Err.	t.	P> t	[95% Conf. Interval]	
larea	-.0607216	.0399045	-1.52	0.132	-.1400625	.0186193
quartos	.0227115	.0122608	1.85	0.067	-.0016662	.0470892
_cons	.2744371	.1885353	1.46	0.149	-.1004216	.6492957

* Teste LM

```
display 88*0.0434
```

```
3.8192
```

```
display chi2tail(2,3.8192)
```

```
.14813963
```

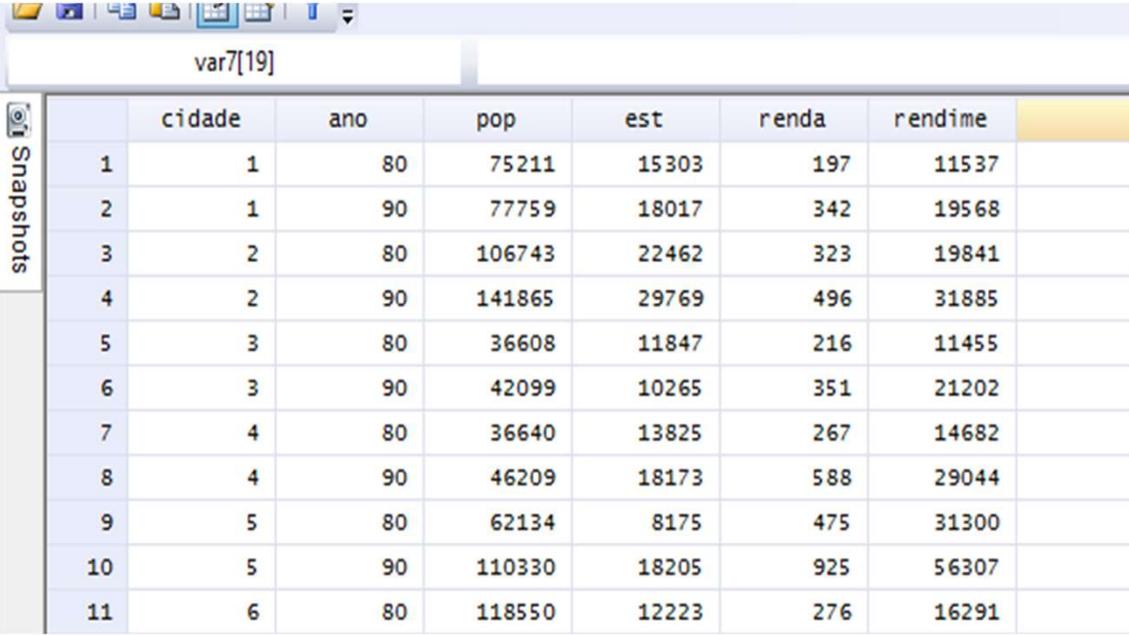
Não se rejeita H_0 : existe evidencia de homocedasticidade (tanto pelo teste F como pelo LM)

Introdução aos modelos para dados de painel

Estrutura dos dados

Dados de Painel:

- N empresas / indivíduos: $i = 1, \dots, N$
- T observações por empresa / indivíduo: $t = 1, \dots, T$



The screenshot shows a data table titled 'var7[19]' with 11 rows and 7 columns. The columns are labeled 'cidade', 'ano', 'pop', 'est', 'renda', and 'rendime'. The rows represent observations for different cities (1-6) over two years (80 and 90). The 'pop' column shows population values, 'est' shows estimated values, 'renda' shows income values, and 'rendime' shows return values.

	cidade	ano	pop	est	renda	rendime
1	1	80	75211	15303	197	11537
2	1	90	77759	18017	342	19568
3	2	80	106743	22462	323	19841
4	2	90	141865	29769	496	31885
5	3	80	36608	11847	216	11455
6	3	90	42099	10265	351	21202
7	4	80	36640	13825	267	14682
8	4	90	46209	18173	588	29044
9	5	80	62134	8175	475	31300
10	5	90	110330	18205	925	56307
11	6	80	118550	12223	276	16291

Introdução aos modelos para dados de painel

Vantagens

Dados seccionais / painel / agrupados:

- Dados seccionais: indivíduos diferentes \Rightarrow observações independentes
- Dados de painel: mesmos indivíduos \Rightarrow observações dependentes ao longo do tempo
- Dados agrupados: indivíduos diferentes observados em diferentes momentos \Rightarrow observações independentes

Algumas vantagens:

- Análise da dinâmica temporal dos comportamentos individuais
- Ganhos de eficiência, dado o aumento da amostra
- Lidar facilmente com endogeneidade resultante da omissão de variáveis que não se alteram no tempo

Introdução aos modelos para dados de painel

Tipos de dados

Painéis curtos:

- Amostra composta por muitos indivíduos ($N \rightarrow \infty$) mas com um horizonte temporal curto (T pequeno)
- Assume-se correlação temporal das observações para cada indivíduo, mas independência entre os indivíduos.

Painéis equilibrados:

- Todos os indivíduos são observados em todos os momentos ($T_i = T, \forall i$)

Painéis desequilibrados:

- Alguns indivíduos não são observados nalguns períodos de tempo ($T_i \neq T$)
- Principal causa: alguns indivíduos desistem de dar informação ao fim de alguns períodos \rightarrow problema conhecido como 'attrition'
- Muitos estimadores funcionam com painéis desequilibrados

Modelos para dados de painel

Introdução de time-dummies e interações

Objectivo: estudar o efeito do tempo

Para T anos , toma-se o primeiro ano como referência e incluem-se $(T - 1)$ dummies, uma para cada um dos restantes anos

- incluem-se essas dummies, sendo que os seus coeficientes informam sobre a alteração de Y relativamente à base, controlados os factores explicativos incluídos no modelo
 - exemplo, o coeficiente de D_{2017} informa quanto variou Y entre o ano base e 2017, devido a factores que não os regressores
- se os efeitos parciais dos regressores se alteram no tempo acrescentam-se também termos de interação
 - pode-se usar o teste Chow para quebra de estrutura

Modelos para dados de painel

Variabilidade no tempo e por indivíduos:

- Com dados de painel, pode-se decompor a variância de Y_{it} :

$$\begin{aligned} \sum_{i=1}^N \sum_{t=1}^T (Y_{it} - \bar{Y})^2 &= \sum_{i=1}^N \sum_{t=1}^T (Y_{it} - \bar{Y}_i + \bar{Y}_i - \bar{Y})^2 \\ &= \sum_{i=1}^N \sum_{t=1}^T (Y_{it} - \bar{Y}_i)^2 + \sum_{i=1}^N (\bar{Y}_i - \bar{Y})^2 \end{aligned}$$

Variabilidade dentro do grupo i Variabilidade entre os grupos

- Obtém-se a variância 'within', 'between' e total dividindo por, respectivamente, $NT - 1$, $N(T - 1)$ e $N - 1$

Modelos para dados de painel

Modelo Base - Modelo de Efeitos Individuais:

$$Y_{it} = \alpha_i + x'_{it}\beta + u_{it} \quad (i = 1, \dots, N; t = 1, \dots, T)$$

- α_i : efeitos individuais, não dependentes do tempo e não observáveis
- x_{it} - variáveis explicativas, incluindo:
 - x_{it} : varia de indivíduo para indivíduo e entre os vários períodos de tempo
 - x_i : invariante no tempo
 - d_t : *dummy* temporal para o momento t
 - $d_t \cdot x_{it}$: termos de interacção
- u_{it} : erro idiossincrático - difere de indivíduo para indivíduo e de período para período de forma aleatória

Modelos para dados de painel

O modelo de efeitos individuais pode ser reescrito como:

$$Y_{it} = x'_{it}\beta + (\alpha_i + u_{it})$$

- O termo erro passa a ter duas componentes, assumindo-se que α_i pode ou não estar relacionado com as variáveis explicativas

Efeitos Aleatórios:

- Pressuposto: α_i e x_{it} não estão correlacionados $\rightarrow x_{it}$ é exógeno
- Estimadores em análise: “Pooled” e Efeitos Aleatórios

Efeitos Fixos:

- Pressuposto: α_i e x_{it} podem estar correlacionados $\rightarrow x_{it}$ é endógeno (relativamente à parte do erro invariante no tempo)
- Estimadores em análise: Efeitos Fixos ou “Within” e Diferenças

Modelos para dados de painel

Estimador pooled

- Equação:

$$Y_{it} = \alpha + x'_{it}\beta + \underbrace{(\alpha_i - \alpha + u_{it})}_{v_{it}}$$

- Estimação:

- Método dos mínimos quadrados com opção cluster ou similar para a variância

Stata

```
regress  $Y$   $X_1$  ...  $X_k$ , vce(cluster clustvar)
```

Modelos para dados de painel

Estimador de efeitos aleatórios

Equação:

$$Y_{it} = \alpha + x'_{it}\beta + (\alpha_i - \alpha + u_{it})$$

com $Var(\alpha_i) = \sigma_\alpha^2$ e $Var(u_{it}) = \sigma_u^2$

Explorando $cor(u_{it}, u_{is}) = \sigma_\alpha^2 / (\sigma_\alpha^2 + \sigma_u^2)$, estes estimadores são mais eficientes. Os estimadores anteriores não exploravam a natureza de painel dos dados no cálculo dos estimadores (apenas na parte da inferência)

Estimação: método dos mínimos quadrados generalizados

$$Y_{it} - \hat{\theta}_i \bar{Y}_i = (1 - \hat{\theta}_i)\alpha + (x_{it} - \hat{\theta}_i \bar{x}_i)' \beta + v_{it}$$

onde $\hat{\theta}_i = 1 - \sqrt{\hat{\sigma}_u^2 / (T_i \hat{\sigma}_\alpha^2 + \hat{\sigma}_\alpha^2)}$ e $v_{it} = (1 - \hat{\theta}_i)\alpha_i + (u_{it} - \hat{\theta}_i \bar{u}_i)$

Stata

```
xtreg YX1 ... Xk, vce(cluster clustvar)
```

Modelos para dados de painel

Estimador de efeitos fixos

Equação:

$$Y_{it} - \bar{Y}_i = (x_{it} - \bar{x}_i)' \beta + (u_{it} - \bar{u}_i)$$

Estimação: método dos mínimos quadrados com opção cluster ou similar para a variância

Stata

```
xtreg  $Y X_1 \dots X_k$ , fe vce(cluster clustvar)
```

Apesar da robustez, dado o não requisito de efeitos aleatórios, tem a desvantagem de eliminar do modelo

- As variáveis explicativas que não se alteram no tempo
- As variáveis explicativas que se alteram de forma constante no tempo (ex.: idade), se o modelo incluir dummies temporais

Modelos para dados de painel

Estimador das diferenças

Equação:

$$y_{it} - y_{i,t-1} = (x_{it} - x_{i,t-1})' \beta + (u_{it} - u_{i,t-1}) \Leftrightarrow$$
$$\Delta y_{it} = \Delta x_{it}' \beta + \Delta u_{it}$$

Stata
`regress D.Y D.X1 ... D.Xk, vce(cluster clustvar)`

Tem as mesmas desvantagens do estimador de EF
Igual ao estimador de EF para T=2

Modelos para dados de painel

Escolha efeitos fixos / efeitos aleatórios

Teste de Hausman:

$H_0: E(\alpha_i x_{it}) = 0$ (EA e EF consistentes, EA eficiente)

$H_1: E(\alpha_i x_{it}) \neq 0$ (EF consistentes, EA inconsistente)

$$H = (\hat{\beta}_{EF} - \hat{\beta}_{EA})' [V(\hat{\beta}_{EF}) - V(\hat{\beta}_{EA})]^{-1} (\hat{\beta}_{EF} - \hat{\beta}_{EA}) \sim \chi_k^2$$

Stata

(modelos têm de ser estimados sem opções robust ou cluster)

```
xtreg YX1 ... Xk, fe  
estimates store ModeloEF  
xtreg YX1 ... Xk  
estimates store ModeloEA  
hausman ModeloEF ModeloEA
```

Análise de política com dados de painel de dois períodos de tempo

Considera-se uma amostra em condições similares da “quasi experiment”: os indivíduos são observados duas vezes, uma antes do programa de intervenção e outra depois, e devem ser de dois tipos, afectados pela experiencia (tratados) e não afectados (controls)

Modelo geral:

$$y_{it} = \alpha + \delta d_{it} + \beta prog_{it} + \alpha_i + u_{it}$$

onde $prog = 1$ se recebeu formação

Modelo às diferenças:

$$\Delta y_{it} = \delta + \beta prog_{it} + \Delta u_{it}$$

Efeito de interesse: $\beta = \overline{\Delta y}_{trat} - \overline{\Delta y}_{cont}$

Análise de política com dados de painel de dois períodos de tempo

Exemplo: Wooldridge

Pretende-se apurar se a taxa de produtos defeituosos (% de produtos defeituosos inutilizados na produção total da empresa), *scrap*, se altera em função da participação num programa de formação, (*Grant*=1 se participa), ocorrido em 1988. Os dados são de painel, para 1987 e 1988 e contêm indivíduos que receberam e indivíduos que não receberam formação profissional

Modelo estimado

$$\Delta \ln(\widehat{scrap}) = -0.057 - 0.317 \Delta grant, n = 54, R^2 = 0.067$$

(0.097) (0.164)

- A formação reduziu a taxa de rejeição em $(e^{0.317} - 1)100\% = 27.2\%$
- A taxa de rejeição reduziu-se em $(e^{0.057} - 1)100\% = 5.9\%$ por factores que não a formação profissional

Modelos para dados de painel dinâmicos: introdução

Modelos com a variável dependente desfasada, $Y_{i,t-1}$, $Y_{i,t-2}$, entre as variáveis explicativas

- Exemplo – $AR(1)$ model:

$$Y_{it} = \gamma_1 Y_{i,t-1} + \alpha_i + u_{it}$$

- Todos os estimadores do modelo estático apresentados anteriormente são inconsistentes

Modelos para dados de painel dinâmicos: introdução

Modelo básico para painéis dinâmicos:

$$\Delta Y_{it} = \gamma_1 \Delta Y_{i,t-1} + \Delta x'_{it} \beta + \Delta u_{it}, t = 3, \dots, T$$

Pressuposto: u_{it} não tem autocorrelação $\Rightarrow \Delta u_{it}$ autocorrelação de ordem 1:

$$Cov(\Delta u_{it}, \Delta u_{i,t-1}) = -Cov(u_{i,t-1}, u_{i,t-1}) \neq 0$$

Principais estimadores (estimadores de variáveis instrumentais):

- Anderson-Hsiao (1981)
- Arellano-Bond (1991) – ‘Difference GMM’
- Blundell-Bond (1998) – ‘System GMM’

Modelos para dados de painel dinâmicos: introdução

Anderson-Hsiao (1981):

2 tipos de VI:

- $Y_{i,t-2}$

Stata

```
ivregress gmm D.Y(DL.Y = L2.Y) D.X1 ... D.Xk
```

- $\Delta Y_{i,t-2}$ (perde-se 1 observação mas em geral gera estimadores mais eficientes)

Stata

```
xtivreg D.Y(DL.Y = DL2.Y) D.X1 ... D.Xk
```

or

```
xtivreg Y(L.Y = L2.Y) X1 ... Xk, fd
```

Modelos para dados de painel dinâmicos: introdução

Arellano-Bond (1991):

- Sugere o uso de todos os lags de $Y_{i,t}$ como VI:
 - $t = 3: Y_{i,1}$
 - $t = 4: Y_{i,2}, Y_{i,1}$
 - ...
 - $t = T: Y_{i,T-2}, \dots, Y_{i,2}, Y_{i,1}$
- # VI = $(T - 1)(T - 2)/2$
- Pode-se usar apenas um subconjunto das VI disponíveis
- Mais eficiente do que os estimadores Anderson-Hsiao's (1981)

```
Stata  
xtabond  $YX_1 \dots X_k$ , maxldep(#) twostep vce(robust)
```

Modelos para dados de painel dinâmicos: introdução

Blundell-Bond (1998):

- Sugere o uso das VI: $\Delta Y_{i,2}, \dots, \Delta Y_{i,T-1}$
- # VI = $\frac{(T-1)(T-2)}{2} + (T - 2)$
- Pode-se usar apenas um subconjunto das VI disponíveis
- Mais eficiente do que o estimador Arellano-Bond's (1991), mas requer mais pressupostos

Stata
xtdpdsys $Y X_1 \dots X_k$, maxldep(#) twostep vce(robust)

Modelos para dados de painel dinâmicos: introdução

Testes principais a aplicar:

- Teste J de Hansen para sobreidentificação

Stata

(after xtabond or xtdpdsys, with variance estimated in a standard way)
estat sargan

- Teste de autocorrelação

Stata

(after xtabond or xtdpdsys, with variance estimated in a standard way)
estat abond, artests(3)