

# ECONOMETRIA

## Análise de Regressão com Séries Temporais

Teoria e Exemplos

# Análise de Regressão Básica

Dados temporais: registo de uma ou mais variáveis ao longo do tempo para um individuo, empresa, região ou país, ...

Exemplo: para um país, tem-se a taxa de desemprego e a taxa de inflação ao longo de n anos

Wooldridge (2016)

**TABLE 10.1 Partial Listing of Data on U.S. Inflation and Unemployment Rates, 1948–2003**

Year	Inflation	Unemployment
1948	8.1	3.8
1949	-1.2	5.9
1950	1.3	5.3
1951	7.9	3.3
.	.	.
.	.	.
.	.	.
1998	1.6	4.5
1999	2.2	4.2

# Análise de Regressão Básica

Características dos dados:

- Os valores passados da variável influenciam o presente e futuro, pelo que não há independência ao longo do tempo
- Apenas há uma amostra possível de recolher, num dado horizonte temporal

A sequência de variáveis aleatórias indexadas pelo tempo  $t$ ,  $t = 1, \dots, n$ , designa-se de processo estocástico,  $\{x_t\}$ , sendo a sua realização designada de série temporal  $x_t$

# Modelos estáticos e modelos de defasamentos distribuídos

## Modelo estático

$y$ , num dado período, é influenciado apenas por variáveis explicativas desse período:

$$y_t = \beta_0 + \beta_1 x_t + u_t$$

- Modelo adequado para casos em que uma variação de  $x$  provoca apenas um efeito imediato sobre  $y$
- Efeito parcial:

$$\Delta x_t = 1 \rightarrow \Delta y_t = \beta_1$$

# Modelos estáticos e modelos de defasamentos distribuídos

## Modelo FDL(q)

$y_t$ , num dado período, é influenciado por variáveis explicativas desse período e de períodos passados:

$$y_t = \alpha_0 + \alpha_1 x_t + \alpha_2 x_{t-1} + \dots + \alpha_{q+1} x_{t-q} + u_t$$

onde  $q$  define o número de lags ou defasamentos a incluir

- Reduz-se ao modelo estático para  $\alpha_2 = \dots = \alpha_{q+1} = 0$
- Efeitos parciais
  - Multiplicador/propensão de impacto:  $\alpha_1$ , impacto imediato em  $y$  de uma variação unitária em  $x$  no momento  $t$
  - Multiplicador/propensão de longo prazo:  $\alpha_1 + \alpha_2 + \dots + \alpha_{q+1}$ , impacto de longo prazo em  $y$  de uma variação permanente em  $x$

# Modelos estáticos e modelos de defasamentos distribuídos

Considere-se o modelo FDL(2)

$$y_t = \alpha_0 + \delta_0 z_t + \delta_1 z_{t-1} + \delta_2 z_{t-2} + u_t$$

1. Assume-se que  $z$  tem o nível  $c$ , exceto em  $t$ , onde aumentou 1 unidade, tendo depois voltado ao nível  $c$ :  $z_t = c + 1$  e ...  $z_{t+2} = z_{t+1} = z_{t-1} = z_{t-2} = \dots = c$

$$y_{t-1} = \alpha_0 + \delta_0 c + \delta_1 c + \delta_2 c$$

$$y_t = \alpha_0 + \delta_0 (c + 1) + \delta_1 c + \delta_2 c$$

$$y_{t+1} = \alpha_0 + \delta_0 c + \delta_1 (c + 1) + \delta_2 c$$

$$y_{t+2} = \alpha_0 + \delta_0 c + \delta_1 c + \delta_2 (c + 1)$$

$$y_{t+3} = \alpha_0 + \delta_0 c + \delta_1 c + \delta_2 c$$

O aumento em  $t$  de  $z$  afectou  $y$  por 3 períodos

- $y_t - y_{t-1} = \delta_0$  (impacto imediato)
- $y_{t+1} - y_{t-1} = \delta_1$
- $y_{t+2} - y_{t-1} = \delta_2$
- $y_{t+3} - y_{t-1} = 0$  (o impacto já não se faz sentir)

# Modelos estáticos e modelos de defasamentos distribuídos

2. Assume-se que  $z$  tem o nível  $c$  antes de  $t$  e  $c+1$  em  $t$  e após:

$$z_t = z_{t+1} = z_{t+2} \dots = c + 1 \text{ e } z_{t-1} = z_{t-2} = \dots = c$$

$$y_{t-1} = \alpha_0 + \delta_0 c + \delta_1 c + \delta_2 c$$

$$y_t = \alpha_0 + \delta_0 (c + 1) + \delta_1 c + \delta_2 c$$

$$y_{t+1} = \alpha_0 + \delta_0 (c + 1) + \delta_1 (c + 1) + \delta_2 c$$

$$y_{t+2} = \alpha_0 + \delta_0 (c + 1) + \delta_1 (c + 1) + \delta_2 (c + 1)$$

O aumento em  $t$  de  $z$  afecta todos os períodos

- Para um horizonte  $h$ , a alteração no valor esperado de  $y$  decorrente de um aumento permanente em  $x$  de 1 unidade é  $\delta_1 + \delta_2 + \dots + \delta_h$
- No longo prazo, a alteração no valor esperado de  $y$  decorrente de um aumento permanente em  $x$  de 1 unidade é  $\delta_1 + \delta_2 + \dots + \delta_q$ : o multiplicador de longo prazo

# Modelos estáticos e modelos de defasamentos distribuídos

## Outros aspectos

- Modelo com vários regressores:

$$y_t = \alpha_0 + \alpha_1 x_{t1} + \alpha_2 x_{t-1,1} + \alpha_3 x_{t2} + \alpha_4 x_{t-1,2} + u_t$$

	$x_1$	$x_2$
P. impacto	$\alpha_1$	$\alpha_3$
P. longo prazo	$\alpha_1 + \alpha_2$	$\alpha_3 + \alpha_4$

- Intervalo de confiança para  $\alpha_{PLP} = \alpha_1 + \alpha_2 + \dots + \alpha_{q+1}$  no modelo

$$y_t = \alpha_0 + \alpha_1 x_t + \alpha_2 x_{t-1} + \dots + \alpha_{q+1} x_{t-q} + u_t$$

- Fazendo  $\alpha_1 = \alpha_{PLP} - \alpha_2 - \dots - \alpha_{q+1}$  e substituindo

$$y_t = \alpha_0 + (\alpha_{PLP} - \alpha_2 - \dots - \alpha_{q+1})x_t + \alpha_2 x_{t-1} + \dots + \alpha_{q+1} x_{t-q} + u_t$$

$$y_t = \alpha_0 + \alpha_{PLP} x_t + \alpha_2 (x_{t-1} - x_t) + \dots + \alpha_{q+1} (x_{t-q} - x_t) + u_t$$



# Modelos estáticos e modelos de defasamentos distribuídos

Exemplo: considere um conjunto de dados contendo observações anuais entre 1948 e 1996 relativas às variáveis *jbt* (taxa de juro dos bilhetes do tesouro a 3 meses), *inf* (taxa de inflação anual baseada no índice de preços no consumidor (IPC)), e *def* (défice governamental como percentagem do PIB). Pretende-se modelar *jbt* em função das outras duas variáveis

## Modelo estático

```
. regress jbt inf def
```

Source	SS	df	MS	Number of obs	=	49
-----+-----				F(2, 46)	=	52.78
Model	294.032897	2	147.016449	Prob > F	=	0.0000
Residual	128.133943	46	2.78552049	R-squared	=	0.6965
-----+-----				Adj R-squared	=	0.6833
Total	422.16684	48	8.7951425	Root MSE	=	1.669
-----						
jbt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
inf	.6131825	.0757753	8.09	0.000	.4606547	.7657104
def	.7004054	.11807	5.93	0.000	.4627427	.938068
_cons	1.252032	.4416346	2.83	0.007	.3630674	2.140996
-----						

# Modelos estáticos e modelos de defasamentos distribuídos

## Modelo FDL

```
. gen inf1=inf[_n-1]
(1 missing value generated)
. gen def1=def[_n-1]
(1 missing value generated)
```

```
. reg jbt inf inf1 def def1
```

Source	SS	df	MS	Number of obs	=	48
-----+-----				F(4, 43)	=	28.23
Model	293.744219	4	73.4360548	Prob > F	=	0.0000
Residual	111.851763	43	2.60120379	R-squared	=	0.7242
-----+-----				Adj R-squared	=	0.6986
Total	405.595982	47	8.62970175	Root MSE	=	1.6128

jbt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
inf	.4251947	.1288993	3.30	0.002	.1652445	.6851449
inf1	.2732321	.1412654	1.93	0.060	-.0116568	.558121
def	.1630251	.2569521	0.63	0.529	-.3551682	.6812185
def1	.4047177	.217547	1.86	0.070	-.0340078	.8434431
_cons	1.234579	.4410125	2.80	0.008	.3451928	2.123966

# Modelos estáticos e modelos de defasamentos distribuídos

OU

```
. tsset ano
      time variable:  ano, 1948 to 1996
              delta:  1 unit

. reg jbt inf L.inf def L.def
```

Source	SS	df	MS	Number of obs	=	
Model	293.744219	4	73.4360548	F(4, 43)	=	28.23
Residual	111.851763	43	2.60120379	Prob > F	=	0.0000
Total	405.595982	47	8.62970175	R-squared	=	0.7242
				Adj R-squared	=	0.6986
				Root MSE	=	1.6128

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
inf						
--.	.4251947	.1288993	3.30	0.002	.1652445	.6851449
L1.	.2732321	.1412654	1.93	0.060	-.0116568	.558121
def						
--.	.1630251	.2569521	0.63	0.529	-.3551682	.6812185
L1.	.4047177	.217547	1.86	0.070	-.0340078	.8434431
_cons	1.234579	.4410125	2.80	0.008	.3451928	2.123966

# Modelos estáticos e modelos de defasamentos distribuídos

Modelos estimados

$$\widehat{juro}_t = 1.252 + 0.613inf_t + 0.700def_t$$

$$\widehat{juro}_t = 1.235 + 0.425inf_t + 0.273inf_t + 0.163def_t + 0.405def_{t-1}$$

Propensão de impacto para a inflação:

- Modelo estático: 0.613
- Modelo FDL: 0.425

Propensão de longo prazo para a inflação:

- Modelo estático: 0.613
- Modelo FDL:  $0.425 + 0.272 = 0.698$

# Modelos estáticos e modelos de defasamentos distribuídos

Escolha entre o modelo estático e o modelo FDL

O modelo estático é re-estimado sem a primeira observação

```
. regress jbt inf def if ano>1948
```

Source	SS	df	MS	Number of obs	=	48
-----+-----				F(2, 45)	=	51.57
Model	282.381685	2	141.190843	Prob > F	=	0.0000
Residual	123.214297	45	2.73809548	R-squared	=	0.6962
-----+-----				Adj R-squared	=	0.6827
Total	405.595982	47	8.62970175	Root MSE	=	1.6547

jbt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
inf	.637288	.0772499	8.25	0.000	.4816987	.7928773
def	.6132833	.1338942	4.58	0.000	.3436065	.88296
_cons	1.367655	.4462745	3.06	0.004	.4688115	2.266498

```
. display ((0.7242-0.6962)/2)/((1-0.7242)/(48-5))  
. 2.1827411
```

Não se rejeita  $H_0$ : os lags introduzidos não são estatisticamente relevantes

# Modelos estáticos e modelos de defasamentos distribuídos

Intervalo de confiança para a propensão de longo prazo,  $\theta$ , a 95%

Modelo auxiliar

$$juro_t = \alpha_0 + \theta inf_t + \alpha_2(inf_{t-1} - inf_t) + \alpha_3 def_t + \alpha_4 def_{t-1} + u_t$$

```
. gen Dinf= inf1-inf
. (2 missing values generated)
. reg jbt inf Dinf def def1
```

Source	SS	df	MS	Number of obs	=	
-----+-----				F(4, 43)	=	28.23
Model	293.74422	4	73.4360549	Prob > F	=	0.0000
Residual	111.851763	43	2.60120378	R-squared	=	0.7242
-----+-----				Adj R-squared	=	0.6986
Total	405.595982	47	8.62970175	Root MSE	=	1.6128

jbt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
inf	<b>.6984268</b>	.0855166	8.17	0.000	<b>.5259662</b>	<b>.8708874</b>
Dinf	.2732321	.1412654	1.93	0.060	-.0116568	.558121
def	.1630251	.2569521	0.63	0.529	-.3551682	.6812185
def1	.4047177	.217547	1.86	0.070	-.0340078	.8434431
_cons	1.234579	.4410125	2.80	0.008	.3451928	2.123966
-----+-----						

# Hipóteses Clássicas e propriedades do OLS em pequenas amostras

1. Linearidade nos parâmetros:  $y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t$  (pode incluir regressores desfasados, logaritmizados, quadráticos,...)
2. Ausência de colineariedade perfeita
3. Exogeneidade estrita:  $E(u_t|X) = 0, \forall t \rightarrow Cov(x_{sj}, u_t) = 0 \forall t, s, j$  (ausência de correlação de  $u_t$  com qualquer uma das  $k$  variáveis explicativas, em  $t$ , no passado e no futuro)
  - envolve exogeneidade contemporânea:  $E(u_t|x_t) = 0, \forall t \rightarrow Cov(x_{tj}, u_t) = 0, \forall t, j$  (por exemplo,  $y_{t-1}$  não é estritamente exógeno mas é contemporaneamente exógeno)
  - falha em presença de variáveis omitidas (mesmo num FDL incluindo os lags adequados, pode ocorrer correlação com o futuro), erro de medida, ...
4. Homoscedasticidade:  $Var(u_t|X) = Var(u_t) = \sigma^2$
5. Ausência de autocorrelação:  $Corr(u_t, u_s|X) = 0, \forall t \neq s$
6. Normalidade do erro:  $u_t \sim N(0, \sigma^2)$

## Propriedades

1-3: estimadores centrados

1-5 (pressupostos de Gauss-Markov): estimadores BLUE

1-6: estimadores normalmente distribuídos  $\hat{\beta}|X \sim N(\beta, \sigma^2(X'X)^{-1})$  e testes  $t$  e  $F$  e IC na forma standard

# Exemplos de formas funcionais

As formas funcionais habituais com variáveis logaritmizadas, termos quadráticos, interações e dummies aplicam-se, com adaptações óbvias de interpretação

## Exemplos

- $\ln(y_t) = \alpha_0 + \alpha_1 x_t + \alpha_2 x_{t-1} + \dots + \alpha_{q+1} x_{t-q} + u_t$
- $\ln(y_t) = \alpha_0 + \alpha_1 x_{1t} + \alpha_2 x_{1t-1} + \alpha_3 x_{2t} + \alpha_4 x_{2t-1}$
- $\ln(y_t) = \alpha_0 + \alpha_1 \ln(x_t) + \alpha_2 \ln(x_{t-1}) + \dots + \alpha_{q+1} \ln(x_{t-q}) + u_t$ 
  - Propensão de impacto  $\alpha_1$  designada de elasticidade de curto prazo
  - Propensão de longo prazo  $\alpha_1 + \alpha_2 + \dots + \alpha_q$  designada de elasticidade de longo prazo



# Dummies e interacções

Time dummies:

- Step dummies – captam o efeito de um evento que potencialmente muda permanentemente a trajetória da série:

$$D_t = \begin{cases} 1 & \text{a partir do momento de ocorrência do evento} \\ 0 & \text{antes do evento} \end{cases}$$

- Impulse dummies – captam o efeito de um evento que potencialmente muda apenas temporariamente a trajetória da série:

$$D_t = \begin{cases} 1 & \text{no momento de ocorrência do evento} \\ 0 & \text{nos restantes períodos} \end{cases}$$

- Exemplo com interações:


$$y_t = \alpha_0 + \alpha_1 D_t + \alpha_2 x_t + \alpha_3 (D_t x_t) + u_t$$

onde  $D_t$  é uma step dummy

- Modelo antes do acontecimento:  $y_t = \alpha_0 + \alpha_2 x_t + u_t$
- Modelo após o acontecimento:  $y_t = (\alpha_0 + \alpha_1) + (\alpha_2 + \alpha_3) x_t + u_t$

# Dummies e interacções

**Exemplo:** pretende-se modelar o índice de confiança do consumidor para Portugal (cc1) como função da taxa de desemprego (unemp), usado dados trimestrais para o período 1990-2009. A representação gráfica da série sugere uma possível quebra de estrutura.



Definiu-se uma variável dummy,  $d97$  que é 1 a partir de Janeiro de 1997 (momento é que parece haver alteração de comportamento)

# Dummies e interacções

Modelo:  $cc1_t = \alpha_0 + \alpha_1 unemp_t + \alpha_2 d97_t + \alpha_3 (unemp_t * d97_t) + u_t$

```
. gen unempd97= unemp*d97  
(2 missing values generated)
```

```
. reg cc1 unemp d97 unempd97
```

Source	SS	df	MS	Number of obs	=	80
-----+-----				F(3, 76)	=	74.21
Model	4572.37487	3	1524.12496	Prob > F	=	0.0000
Residual	1560.90507	76	20.5382246	R-squared	=	0.7455
-----+-----				Adj R-squared	=	0.7355
Total	6133.27994	79	77.6364549	Root MSE	=	4.5319
-----						
cc1	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unemp	-.486134	.654488	-0.74	0.460	-1.78966	.8173918
d97	28.11922	4.520358	6.22	0.000	19.11614	37.12229
unempd97	-4.815761	.7484779	-6.43	0.000	-6.306484	-3.325038
_cons	-65.86282	3.820795	-17.24	0.000	-73.47259	-58.25304
-----						

- Antes da quebra:  $\widehat{cc1}_t = -65.863 - 0.486unemp_t$
- Após a quebra:  $\widehat{cc1}_t = (-65.863 + 28.119) + (-0.486 - 4.816)unemp_t$

# Tendência determinística

Variável tendência: representa a ordem de uma observação na amostra:  
 $t = 1, 2, \dots, n$

Permite incorporar no modelo a tendência de crescimento / decréscimo de uma série que se deve a factores que não os incluídos no modelo: informa da variação de  $y$  que ocorre devida à simples passagem do tempo

A omissão da tendência causará a inconsistência dos coeficientes dos restantes regressores, caso a série de interesse  $Y$

- tenha tendência
- não tenha tendência mas algum dos regressores tenha (o regressor está correlacionado com  $t$ , que está omitida do modelo)

# Tendência determinística

A omissão de  $t$  pode gerar resultados onde

- se indica erradamente que o andamento da serie se deve a factores explicativos: **relação espúria** (parece haver significância estatística quando na verdade não há). Quando se inclui a tendência no modelo, torna-se evidente que a relação não existe.
- Se indica que  $Y$  e  $X$  não se relacionam (em casos onde  $Y$  o  $X$  têm tendência de sentido oposto). Aqui a inclusão da tendência pode tornar a sua relação mais significativa

# Tendência determinística

Ilustração de Relação Espúria (Wooldridge, 2016. pp. 332-333)

The data in HSEINV are annual observations on housing investment and a housing price index in the United States for 1947 through 1988. Let  $invpc$  denote real per capita housing investment (in thousands of dollars) and let  $price$  denote a housing price index (equal to 1 in 1982). A simple regression in constant elasticity form, which can be thought of as a supply equation for housing stock, gives

$$\widehat{\log(invpc)} = -.550 + 1.241 \log(price) \\ (.043) \quad (.382) \quad [10.32] \\ n = 42, R^2 = .208, \bar{R}^2 = .189.$$

To account for the trending behavior of the variables, we add a time trend:

$$\widehat{\log(invpc)} = -.913 - .381 \log(price) + .0098 t \\ (1.36) \quad (.679) \quad (.0035) \quad [10.33] \\ n = 42, R^2 = .341, \bar{R}^2 = .307.$$

# Tendência determinística

Ilustração de variável Y e X com tendência oposta (Wooldridge, 2016, pp. 334)

Annual data on the Puerto Rican employment rate, minimum wage, and other variables are used by Castillo-Freeman and Freeman (1992) to study the effects of the U.S. minimum wage on employment in Puerto Rico. A simplified version of their model is

$$\log(\text{prepop}_t) = \beta_0 + \beta_1 \log(\text{mincov}_t) + \beta_2 \log(\text{usgnp}_t) + u_t \quad [10.16]$$

where  $\text{prepop}_t$  is the employment rate in Puerto Rico during year  $t$  (ratio of those working to total population),  $\text{usgnp}_t$  is real U.S. gross national product (in billions of dollars), and  $\text{mincov}$  measures the importance of the minimum wage relative to average wages. In particular,  $\text{mincov} =$

$$\widehat{\log(\text{prepop}_t)} = -1.05 - .154 \log(\text{mincov}_t) - .012 \log(\text{usgnp}_t) \quad [10.17]$$

(0.77) (.065) (.089)

$$n = 38, R^2 = .661, \bar{R}^2 = .641.$$

When we add a linear trend to equation (10.17), the estimates are

$$\widehat{\log(\text{prepop}_t)} = -8.70 - .169 \log(\text{mincov}_t) + 1.06 \log(\text{usgnp}_t) - .032 t \quad [10.38]$$

(1.30) (.044) (0.18)  
(.005)

$$n = 38, R^2 = .847, \bar{R}^2 = .834.$$

# Tendência determinística

Exemplos de modelos com tendência:

- Modelo de tendência linear:

$$y_t = \beta_0 + \beta_1 t + \beta_2 x_{t1} + \beta_3 x_{t2} \dots + u_t$$
$$\Delta t = 1 \Rightarrow \Delta y_t = \beta_1$$

- Modelo de tendência exponencial:

$$\ln(y_t) = \beta_0 + \beta_1 t + \beta_2 x_{t1} + \beta_3 x_{t2} \dots + u_t$$

$\Delta t = 1 \Rightarrow \% \Delta y_t = 100 * \beta_1 \%$ : obtendo-se a taxa de crescimento de y por unidade de tempo

- Modelo de tendência quadrática:

$$y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 x_{t1} + \beta_4 x_{t4} \dots + u_t$$

$\Delta t = 1 \Rightarrow \Delta y_t = \beta_1 + 2\beta_2 t$  (caso  $\beta_1 > 0$  e  $\beta_2 < 0$ : curva em U invertido)



# Tendência determinística

Interpretação “detrending”/remoção de tendência do modelo

Considere-se o modelo de tendência linear

$$\hat{y}_t = \hat{\beta}_0 + \hat{\beta}_1 t + \hat{\beta}_2 x_{t1} + \hat{\beta}_3 x_{t2} \dots$$

Caso se promova a remoção da tendência de cada uma das variáveis do modelo, obtendo-se de  $\ddot{y}_t, \ddot{x}_{t1}, \ddot{x}_{t2}, \dots$ , fazendo a regressão de  $\ddot{y}_t$  em  $\ddot{x}_{t1}, \ddot{x}_{t2}, \dots$  obtêm-se os mesmos coeficientes associados

$x_{t1}, x_{t2}, \dots : \hat{\beta}_2, \hat{\beta}_3, \dots$

- Ao incluir a variável tendência numa regressão faz-se a remoção da tendência
- Os coeficientes de regressão informam sobre variações, após a remoção da tendência

# Tendência determinística

Processo de detrending: aplica-se a cada variável. Por exemplo, para  $y_t$

1. Estimar o modelo  $y_t = \alpha_0 + \alpha_1 t + e_t$
2. Obter o resíduo, que é a versão “detrended” da variável:  $\hat{y}_t = y_t - (\hat{\alpha}_0 + \hat{\alpha}_1 t)$

**Exemplo:** pretende-se modelar o índice de confiança do consumidor para Portugal (cc1) como função da taxa de desemprego (unemp) e de uma tendência linear:

$$cc1_t = \alpha_0 + \alpha_1 t + \alpha_2 unemp_t + e_t$$

Mostra-se de seguida que esta abordagem corresponde a uma remoção da tendência

# Tendência determinística

```
. reg ccl t unemp
```

Source	SS	df	MS	Number of obs	=	80
-----+-----						
Model	3915.95775	2	1957.97887	F(2, 77)	=	67.99
Residual	2217.32219	77	28.7963921	Prob > F	=	0.0000
-----+-----						
Total	6133.27994	79	77.6364549	R-squared	=	0.6385
-----+-----						
				Adj R-squared	=	0.6291
				Root MSE	=	5.3662

ccl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
t	-.0855887	.0329731	-2.60	0.011	-.1512465	-.0199309
unemp	<b>-3.430343</b>	.4660924	-7.36	0.000	-4.358452	-2.502235
_cons	-46.07005	2.382637	-19.34	0.000	-50.81449	-41.32562
-----+-----						

# Tendência determinística

```
. quietly reg ccl t  
. predict ccldot, resid
```

```
. quietly reg unemp t  
. predict unempdot, resid
```

```
. reg ccldot unempdot
```

Source	SS	df	MS	Number of obs	=	80
-----+-----				F(1, 78)	=	54.87
Model	1559.80074	1	1559.80074	Prob > F	=	0.0000
Residual	2217.32218	78	28.4272074	R-squared	=	0.4130
-----+-----				Adj R-squared	=	0.4054
Total	3777.12292	79	47.8116825	Root MSE	=	5.3317
-----						
ccldot	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unempdot	<b>-3.430343</b>	.463095	-7.41	0.000	-4.352294	-2.508392
_cons	1.23e-09	.5961041	0.00	1.000	-1.186752	1.186752

# Sazonalidade

A sazonalidade gera oscilações de subida/queda nas séries, que se repetem-se por trimestre, mês, dia ou horário. Decorrem de causas naturais (clima: estações do ano no consumo de água, turismo), medidas administrativas (início do ano escolar), ou tradições (vendas no período natalício)

Incorpora-se no modelo através de, por exemplo, 3, 11, e 6 dummies que identificam estações do ano, meses, e dias

Exemplo: estações do ano

$$y_t = \alpha_0 + \rho_1 \text{primavera}_t + \rho_2 \text{verão}_t + \rho_3 \text{outono}_t \\ + \alpha_1 x_{1t} + \alpha_2 x_{1t-1} + \alpha_3 x_{2t} + \alpha_4 x_{2t-1} + u_t$$

# Sazonalidade

## Interpretação “seasonally adjusted”/remoção da sazonalidade

Considere-se o modelo do exemplo anterior. Caso se promova a desazonalização de cada uma das variáveis do modelo, obtendo-se de  $\ddot{y}_t$ ,  $\ddot{x}_{t1}$ ,  $\ddot{x}_{t2}$ , ..., fazendo a regressão de  $\ddot{y}_t$  em  $\ddot{x}_{t1}$ ,  $\ddot{x}_{t2}$ , ... obtêm-se os mesmos coeficientes associados  $x_{t1}$ ,  $x_{t2}$ , ... :  $\hat{\alpha}_1$ ,  $\hat{\alpha}_2$ , ...

- Ao incluir as dummies de sazonalidade numa regressão promove-se a dessazonalização
- Os coeficientes de regressão informam sobre variações, após a remoção da sazonalidade

Processo de dessazonalização: aplica-se a cada variável, por exemplo,  $y_t$

1. Estimar o modelo  $y_t = \delta_0 + \delta_1 primavera_t + \delta_2 verão_t + \delta_3 outono_t + e_t$
2. Obter o resíduo, que é a versão desazonalizada da variável:

$$\ddot{y}_t = y_t - (\hat{\delta}_0 + \hat{\delta}_1 primavera_t + \hat{\delta}_2 verão_t + \hat{\delta}_3 outono_t)$$

# Sazonalidade

## Exemplo: índice de confiança do consumidor (retoma)

```
. reg ccl unemp t Q1 Q2 Q3
```

Source	SS	df	MS	Number of obs	=	80
-----+-----				F(5, 74)	=	26.34
Model	3926.97184	5	785.394368	Prob > F	=	0.0000
Residual	2206.3081	74	29.8149743	R-squared	=	0.6403
-----+-----				Adj R-squared	=	0.6160
Total	6133.27994	79	77.6364549	Root MSE	=	5.4603

ccl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unemp	-3.438173	.4744801	-7.25	0.000	-4.383595	-2.492751
t	-.0860184	.0335616	-2.56	0.012	-.1528913	-.0191455
Q1	-.9428817	1.728888	-0.55	0.587	-4.387766	2.502002
Q2	-.7502904	1.728204	-0.43	0.665	-4.193812	2.693231
Q3	-.2910729	1.726991	-0.17	0.867	-3.732178	3.150032
_cons	-45.50831	2.683547	-16.96	0.000	-50.85539	-40.16123
-----+-----						

# Sazonalidade

```
. reg ccl t unemp
```

Source	SS	df	MS	Number of obs	=	80
Model	3915.95775	2	1957.97887	F(2, 77)	=	67.99
Residual	2217.32219	77	28.7963921	Prob > F	=	0.0000
				R-squared	=	0.6385
				Adj R-squared	=	0.6291
Total	6133.27994	79	77.6364549	Root MSE	=	5.3662

ccl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
t	-.0855887	.0329731	-2.60	0.011	-.1512465	-.0199309
unemp	<b>-3.430343</b>	.4660924	-7.36	0.000	-4.358452	-2.502235
_cons	-46.07005	2.382637	-19.34	0.000	-50.81449	-41.32562

```
. display ((0.6403-0.6385)/3)/((1-0.6403)/(80-6))  
.1234362  
. display Ftail(3,74,.1234362)  
.94599099
```

Não se rejeita  $H_0$  de ausência de sazonalidade na série



# Séries temporais estacionárias e fracamente dependentes

**Processo estocástico estacionário:** processo cuja distribuição é sempre a mesma qualquer que seja o período analisado: a distribuição conjunta de  $y_{t_1}, y_{t_2}, \dots, y_{t_m}$ , ( $1 \leq t_1 \leq t_2 \dots$ ) iguala a distribuição conjunta de  $y_{t_1+h}, y_{t_2+h}, \dots, y_{t_m+h}$ , para um número inteiro  $h \geq 1$  que define um intervalo de tempo

- retirando um conjunto de observações num intervalo de tempo e retirando outro  $h$  periodos mais tarde, a distribuição é igual
- Não significa ausencia de correlação entre observações adjacentes, significa que a correlação existente é estável ao longo do tempo

# Séries temporais estacionárias e fracamente dependentes

**Processo estocástico estacionário em covariância:** definição menos exigente do que a anterior, requerendo apenas que a média e variância do processo (requer-se que o segundo momento seja finito:  $E(y_t^2) < \infty$ ) sejam constantes e a covariância e correlação entre  $y_t$  e  $y_{t+h}$  dependam apenas do intervalo de tempo  $h$ :

- $E(y_t) = \mu$
- $V(y_t) = E(y_t - \mu)^2 = \sigma^2$
- $Cov(y_t, y_{t+h})$  pode depender de  $h$  mas não de  $t$

# Séries temporais estacionárias e fracamente dependentes

**Processo fracamente dependente:** requer que  $y_t$  e  $y_{t+h}$  sejam “quase” independentes quando  $h \rightarrow \infty$

- definição aplica-se a séries estacionárias ou não
- Quando se verifica estacionaridade em covariância, a sequência é designada
  - fracamente dependente se  $Cor(y_t, y_{t+h})$  vai para zero com a rapidez suficiente quando  $h \rightarrow \infty$
  - assintoticamente não correlacionada se  $Cor(y_t, y_{t+h}) \rightarrow 0$  quando  $h \rightarrow \infty$
- A estacionaridade com dependência fraca substitui o requisito de amostra aleatória requerido na aplicação da Lei dos Grandes Números e do Teorema do Limite Central

# Ruido branco

“White noise” é um processo cujas observações não são correlacionadas:

$$y_t = \varepsilon_t$$


onde

- $E(\varepsilon_t) = \mu_\varepsilon$
- $V(\varepsilon_t) = \sigma_\varepsilon^2$
- $Cov(\varepsilon_t, \varepsilon_{t-h}) = 0$  para  $h \neq 0$


# Ruido branco

## Simulações para diferentes “white noises”


a) distribuição normal, variância = 1




b) distribuição normal, variância = 4



c) distribuição de qui-quadrado, variância = 1



d) distribuição de qui-quadrado, variância = 4



# Modelos autorregressivos

## Modelo AR(1):

$$y_t = \rho y_{t-1} + \varepsilon_t$$

onde o comportamento de  $y_t$  resulta do seu passado e de um termo erro  $\varepsilon_t$ , ruído branco ( $\varepsilon_t \sim \text{iid}(0, \sigma^2)$ ), que inclui todos os outros determinantes de  $y_t$  para além de  $y_{t-1}$ . Assume-se  $|\rho| < 1$ , o que permite dizer que este AR(1) é um processo estável.


Verifica-se

- $E(y_t) = E(\varepsilon_t) + \rho E(\varepsilon_{t-1}) + \rho^2 E(\varepsilon_{t-2}) + \dots = 0$
- $V(y_t) = E(y_t^2) = E(\varepsilon_t^2) + \rho E(\varepsilon_{t-1}^2) + \rho^2 E(\varepsilon_{t-2}^2) + \dots = \frac{\sigma^2}{1-\rho^2}$
- $\text{Cov}(y_t, y_{t-h}) = \gamma_h = \rho^h \sigma^2$
- $\text{Cor}(y_t, y_{t-h}) = \frac{\gamma_h}{\gamma_0} = \rho^h$
- Estacionário e fracamente dependente se  $|\rho| < 1$


# Modelos autorregressivos

## Exemplos de processos AR(1)


a)  $y_t = 0.25y_{t-1} + \varepsilon_t$




b)  $y_t = 0.5y_{t-1} + \varepsilon_t$



c)  $y_t = 0.75y_{t-1} + \varepsilon_t$



d)  $y_t = 0.95y_{t-1} + \varepsilon_t$



# Modelos de médias móveis

## Modelo MA(1)

$$y_t = \varepsilon_t + \theta\varepsilon_{t-1}, |\theta| < 1$$

onde  $\varepsilon_t$  é um ruído branco,  $\varepsilon_t \sim \text{iid}(0, \sigma^2)$

Verifica-se


- $E(y_t) = E(\varepsilon_t) + \theta E(\varepsilon_{t-1}) = 0$
- $V(y_t) = V(\varepsilon_t + \theta\varepsilon_{t-1}) = V(\varepsilon_t) + \theta^2 V(\varepsilon_{t-1}) + 2\theta \text{Cov}(\varepsilon_t \varepsilon_{t-1}) = \sigma^2(1 + \theta^2)$
- $\text{Cov}(y_t, y_{t-h}) = \begin{cases} \theta\sigma^2 & \text{se } h = 1 \\ 0 & \text{se } h > 1 \end{cases}$
- $\text{Cor}(y_t, y_{t-h}) = \begin{cases} \frac{\theta\sigma^2}{\sigma^2(1+\theta^2)} = \frac{\theta}{(1+\theta^2)} & \text{se } h = 1 \\ 0 & \text{se } h > 1 \end{cases}$
- Estacionário e fracamente dependente




# Modelos de médias móveis

## Exemplos de modelo MA(1)

a)  $y_t = \varepsilon_t + 0.5\varepsilon_{t-1}$



b)  $y_t = \varepsilon_t + 0.95\varepsilon_{t-1}$



# Processos estacionários em tendência

$$y_t = \beta_0 + \beta_1 t + u_t$$

Verifica-se

- $E(y_t) = \beta_0 + \beta_1 t$

sendo um processo não estacionário, já que apenas é estacionário em tendência, pode ser estimado por OLS, desde que seja fracamente dependente em torno à tendência

# Exemplo

Seja  $e_t, t = -1, 0, 1, \dots$  uma sucessão de variáveis aleatórias independentes e identicamente distribuídas com média zero e variância unitária,  $e_t \sim i. i. d. (0, 1)$ . Defina o processo estocástico

$$x_t = e_t - 0.5e_{t-1} + 0.5e_{t-2}, t = 1, 2, \dots$$

- Determine  $E(x_t)$  e  $V(x_t)$  e verifique se dependem de  $t$ .
- Mostre que  $\text{Cor}(x_t, x_{t+1}) = -0.5$  e  $\text{Cor}(x_t, x_{t+2}) = 1/3$
- Qual é a  $\text{Cor}(x_t, x_{t+h})$  para  $h > 2$

Tem-se

- $E(e_t) = 0$
- $V(e_t) = 1$
- $\text{Cov}(e_t, e_s) = 0$  para  $t \neq s$  devido à independência

# Exemplo

a)

- $E(x_t) = E(e_t) - 0.5E(e_{t-1}) + 0.5E(e_{t-2}) = 0$
- $V(x_t) = V(e_t) - 0.5^2V(e_{t-1}) + 0.5^2V(e_{t-2}) = 1 + 0.25 + 0.25 = 1.5$

Não dependem de t

b)

- $$\text{Cor}(x_t, x_{t+1}) = \frac{\text{Cov}(x_t, x_{t+1})}{\sqrt{V(x_t)}\sqrt{V(x_{t+1})}} = \frac{\text{Cov}(x_t, x_{t+1})}{\sqrt{1.5}\sqrt{1.5}} = \frac{-0.75}{1.5} = -0.25$$

$$\text{Cov}(x_t, x_{t+1}) = E(x_t x_{t+1})$$

$$\begin{aligned} &= E((e_t - 0.5e_{t-1} + 0.5e_{t-2})(e_{t+1} - 0.5e_t + 0.5e_{t-1})) = \\ &= -0.5E(e_t^2) - 0.25E(e_{t-1}^2) = -0.5 - 0.25 = -0.75 \end{aligned}$$

- $$\text{Cor}(x_t, x_{t+2}) = \frac{\text{Cov}(x_t, x_{t+2})}{\sqrt{V(x_t)}\sqrt{V(x_{t+2})}} = \frac{\text{Cov}(x_t, x_{t+2})}{\sqrt{1.5}\sqrt{1.5}} = \frac{0.5}{1.5} = 1/3$$

$$\begin{aligned} \text{Cov}(x_t, x_{t+2}) &= E((e_t - 0.5e_{t-1} + 0.5e_{t-2})(e_{t+2} - 0.5e_{t+1} + 0.5e_t)) \\ &= 0.5E(e_t^2) = 0.5 \end{aligned}$$

# Exemplo

c)

$$\text{Cor}(x_t, x_{t+h}) = \frac{\text{Cov}(x_t, x_{t+h})}{\sqrt{V(x_t)}\sqrt{V(x_{t+h})}} = \frac{\text{Cov}(x_t, x_{t+h})}{\sqrt{1.5}\sqrt{1.5}} = \frac{0}{1.5} = 0$$

$$\begin{aligned}\text{Cov}(x_t, x_{t+3}) &= E((e_t - 0.5e_{t-1} + 0.5e_{t-2})(e_{t+3} - 0.5e_{t+2} + 0.5e_{t+1})) \\ &= 0\end{aligned}$$

Para  $h=4, 5, \dots$  também se terá 0

- $\text{Cor}(x_t, x_{t+h}) = 0$  para  $h > 2$

# Propriedades assintóticas do estimador OLS

1'. Linearidade nos parâmetros, **juntamente com estacionaridade e dependência fraca**

2'. Ausência de colineariedade perfeita

3'.  $E(u_t | \mathbf{x}_t) = 0$  exogeneidade contemporânea

4'. Homoscedasticidade:  $Var(u_t | \mathbf{x}_t) = Var(u_t) = \sigma^2$

5'. Ausência de autocorrelação:  $E(u_t, u_s | \mathbf{x}_t, \mathbf{x}_s) = 0, \forall t \neq s$

- No AR(1)  $y_t = \alpha_0 + \alpha_1 y_{t-1} + u_t$  tem-se  $E(u_t, u_s | y_{t-1}, y_{s-1})$ 
  - como  $t \neq s$ ,  $E(u_t, u_s | y_{t-1}, y_{s-1}) = u_s E(u_t | y_{t-1}, y_{s-1})$
  - Como em presença de exogeneidade contemporânea  $E(u_t | y_{t-1}) = E(u_t | y_{t-1}, y_{t-2}, y_{t-3} \dots) = 0$ , então não há autocorrelação:  
 $E(u_t, u_s | y_{t-1}, y_{s-1}) = 0$

## Propriedades

1'-3': estimadores consistentes

1'-5': estimadores normalmente distribuídos, sendo que os testes t, F e LM são assintoticamente válidos.

# Propriedades assintóticas do estimador OLS

## Análise de 3': exogeneidade contemporânea

Exemplo 1: modelo estático

$$y_t = \beta_0 + \beta_1 x_t + u_t$$

Requer que  $E(u_t | x_t) = 0$ ,

o que não se verificará com variáveis omitidas em  $u_t$  correlacionadas com  $x_t$ , mas permite, por exemplo, que  $x_t$  seja uma função de  $y_{t-1}$  ( $y_{t-1} = f(u_{t-1})$ ), pois não se requer  $E(u_{t-1} | x_t) = 0$ . Por exemplo, permite feedback de  $y$  para (valores futuros de)  $x$ : se  $x$  for uma variável de política, pode depender de  $y$  no momento anterior, causando a correlação entre  $u_{t-1}$  e  $x_{t1}$

Exemplo 2: modelo FDL

$$y_t = \alpha_0 + \delta_0 z_t + \delta_1 z_{t-1} + \delta_2 z_{t-2} + u_t$$

Com  $E(u_t | z_t, z_{t-1}, z_{t-2}, z_{t-3} + \dots) = 0$ ,

o que significa que  $E(y_t | z_t, z_{t-1}, z_{t-2}) = E(y_t | z_t, z_{t-1}, z_{t-2}, z_{t-3} + \dots)$ : depois de controlado para  $z_t, z_{t-1}, z_{t-2}$ , a informação de  $z_{t-3} + \dots$  é irrelevante. Definindo  $\mathbf{x}_t = (z_t, z_{t-1}, z_{t-2})$ , satisfaz-se 3'.

# Propriedades assintóticas do estimador OLS

Exemplo 3: modelo AR(1)

$$y_t = \rho y_{t-1} + u_t$$

com

$$E(u_t | y_{t-1}, y_{t-2}, y_{t-3} + \dots) = 0,$$

o que significa que  $E(y_t | y_{t-1}) = E(y_t | y_{t-1}, y_{t-2}, y_{t-3} + \dots)$ : depois de controlado para  $y_{t-1}$ , a informação de  $y_{t-2}, y_{t-3} + \dots$  é irrelevante

Definindo  $x_t = (y_{t-1})$ , satisfaz-se 3'. O que não se satisfaz é a versão correspondente 3, que garantiria também que  $\rho$  fosse centrado. Na verdade  $Cov(u_t, y_t) = Cov(u_t, (\rho y_{t-1} + u_t)) = Var(u_t) = \sigma^2$



# Séries temporais altamente persistentes

Caso o processo não seja fracamente dependente, então a aplicação do OLS requer que os pressupostos mais fortes expostos anteriormente se verifiquem (entre os quais a exogeneidade estrita)

Neste tópico estudam-se processos altamente persistentes / fortemente dependentes. O objectivo é conhecer estes processos e motivar a aplicação de transformações que permitem o uso do OLS

Processos estudados:

- Passeio aleatório
- Passeio aleatório com deslocação/drift

Ambos são processos de raiz unitária

# Séries temporais altamente persistentes

## 1) Passeio Aleatório

$$y_t = y_{t-1} + \varepsilon_t$$

Processo AR(1) com  $\rho = 1$  (de raiz unitária). Substituindo:

$$y_t = y_{t-2} + \varepsilon_{t-1} + \varepsilon_t = y_{t-3} + \varepsilon_{t-2} + \varepsilon_{t-1} + \varepsilon_t$$


$$y_t = y_0 + \varepsilon_1 + \dots + \varepsilon_{t-2} + \varepsilon_{t-1} + \varepsilon_t$$

Obtendo-se

- $E(y_t) = y_0$ , sendo comum assumir  $E(y_t) = y_0 = 0$
- $V(y_t) = \sigma_\varepsilon^2 t$  (série não estacionária: variância depende de t)
- $\text{Cor}(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$ 
  - ao contrário do que acontece com  $|\rho| < 1$ , a corr depende de t
  - para t fixo, quando  $h \rightarrow \infty$ ,  $\text{Cor}(y_t, y_{t+h}) \rightarrow 0$ , mas lentamente, especialmente se t for grande: a série não é assintoticamente não correlacionada
  - Para t grande  $\text{Cor}(y_t, y_{t+h}) \rightarrow 1$

# Séries temporais altamente persistentes

Exemplo de um passeio aleatório



# Séries temporais altamente persistentes

Em Economia/Finanças, em variáveis deste tipo, o efeito de intervenções prolonga-se, ao contrario do que acontece com variáveis assintoticamente não correlacionadas. O valor de  $y$  no momento  $t$  correlaciona-se com o valor de  $y$  num futuro distante.

De facto

$$y_{t+h} = y_{t+h-1} + \varepsilon_{t+h} = y_t + \varepsilon_{t+1} + \dots + \varepsilon_{t+h-1} + \varepsilon_{t+h}$$

Obtendo-se

- $E(y_{t+h}|y_t) = y_t$  (significa que no futuro a melhor previsão é sempre o ultimo valor da série observado, mesmo num futuro distante)
- $V(y_{t+h}|y_t) = \sigma_\varepsilon^2(t+h)$
- $\text{Cor}(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$

\* No caso de um AR(1) estável,  $E(y_{t+h}|y_t) = \rho^h y_t$ , indo para zero quando  $h \rightarrow \infty$ , por isso a dependência do ultimo valor da série esvai-se

# Séries temporais altamente persistentes

## 2) Passeio aleatório com drift

$$y_t = \alpha + y_{t-1} + \varepsilon_t$$

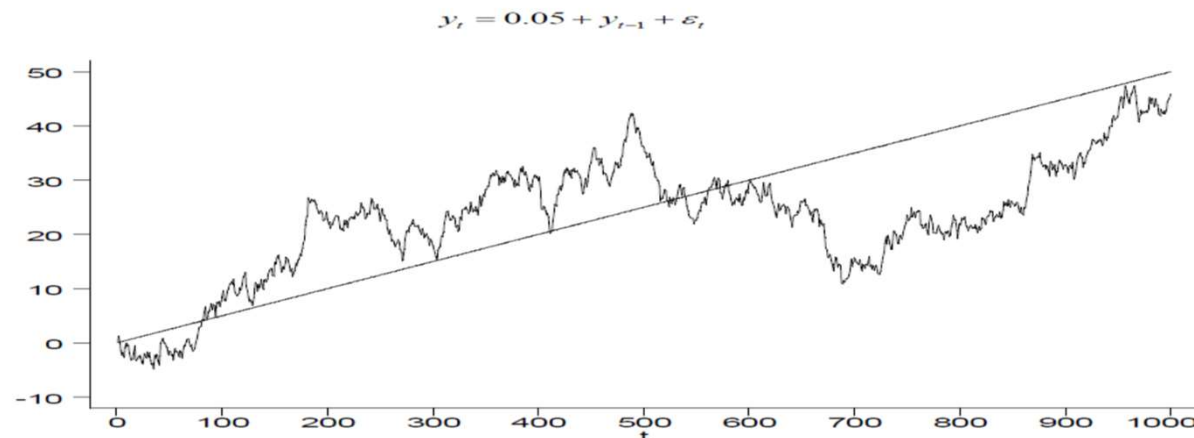
Substituindo sucessivamente:

$$y_t = \alpha + \alpha + y_{t-2} + \varepsilon_{t-1} + \varepsilon_t = \alpha + \alpha + \alpha + y_{t-3} + \varepsilon_{t-2} + \varepsilon_{t-1} + \varepsilon_t$$

$$y_t = \alpha t + y_0 + \varepsilon_1 + \dots + \varepsilon_{t-2} + \varepsilon_{t-1} + \varepsilon_t$$

Obtendo-se

- $E(y_t) = \alpha t + y_0$
- $V(y_t) = \sigma_\varepsilon^2 t$  (série não estacionária: tanto a média como a variância dependem de t)



# Séries temporais altamente persistentes

Para este caso

$$y_{t+h} = \alpha + y_{t+h-1} + \varepsilon_{t+h} = \alpha h + y_t + \varepsilon_{t+1} + \dots + \varepsilon_{t+h-1} + \varepsilon_{t+h}$$

Obtendo-se

- $E(y_{t+h}) = \alpha h + y_t$  (significa que no futuro a melhor previsão é sempre o ultimo valor da série observado, mais o drift multiplicado por h)
- $V(y_{t+h}) = \sigma_\varepsilon^2(t + h)$
- $\text{Cor}(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$

# Transformações de séries fortemente dependentes

Ideia: transformar uma série altamente persistente numa fracamente dependente

Ordem de integração

- $I(0)$ : série fracamente dependente – OLS pode ser directamente usado
- $I(1)$ : processo de raiz unitária cuja primeira diferença

$$\Delta y_t = y_t - y_{t-1}$$

é  $I(0)$ . Um processo  $I(1)$  é designado de processo estacionário às diferenças

Exemplo 1: passeio aleatório

$$y_t = y_{t-1} + \varepsilon_t \rightarrow I(1)$$
$$\Delta y_t = y_t - y_{t-1} = \varepsilon_t \rightarrow I(0)$$

# Transformações de séries fortemente dependentes

Exemplo 2: modelo de tendência determinística

$$y_t = \beta_0 + \beta_1 t + \dots + u_t \rightarrow \text{estac. em tendência}$$

$$\begin{aligned} \Delta y_t &= \beta_0 + \beta_1 t + \dots + u_t - (\beta_0 + \beta_1(t-1) + \dots + u_{t-1}) \\ &= \beta_1 + \Delta u_t \rightarrow \text{estac. em tendência} \end{aligned}$$

Assim, pode-se incluir a trend ou fazer a diferença

Exemplo 3: diferenças de logs

$$\begin{aligned} \ln(y_t) &= \dots \rightarrow I(1) \\ \Delta \ln(y_t) &= \ln(y_t) - \ln(y_{t-1}) \rightarrow I(0) \end{aligned}$$

Note-se que  $\Delta \ln(y_t) \approx \frac{y_t - y_{t-1}}{y_{t-1}}$

é a alteração proporcional, sendo

$$\Delta \ln(y_t) 100 \approx \frac{y_t - y_{t-1}}{y_{t-1}} 100 \%$$


a alteração percentual



# Transformações de séries fortemente dependentes

Exemplo e ilustração 4: passeio aleatório com drift

$$Y_t = 0.05 + Y_{t-1} + u_t \text{ vs. } \Delta Y_t = Y_t - Y_{t-1}$$



# Transformações de séries fortemente dependentes

Como saber se a série é  $I(1)$ , caso onde é necessário usar a primeira diferença com o OLS, ou  $I(0)$ , caso onde a série se usa em níveis?

Procedimento informal

Supondo  $y_t$  AR(1),  $y_t = \rho y_{t-1} + u_t$ . O ordem de integração de  $y_t$  depende da autocorrelação de primeira ordem: será  $I(0)$  para  $|\rho| < 1$  e  $I(1)$  para  $|\rho| = 1$ .

Assim, se  $\text{cor}(y_t, y_{t-1}) > 0.9$ ,  $y_t$  considera-se  $I(1)$  e trabalha-se com a série às diferenças. Para  $\text{cor}(y_t, y_{t-1}) > 0.8$ , por vezes já é recomendável diferenciar; Wooldridge (2016), p. 359

Testes de raízes unitárias (não são lecionados no âmbito da uc de Econometria): teste de Dickey-Fuller e Dickey-Fuller aumentado (ADF)

# Modelos dinamicamente completos

Um modelo dinamicamente completo satisfaz o pressuposto 5 de ausência de autocorrelação, isto é, satisfaz o pressuposto 5'

$$E(u_t, u_s | x_t, x_s) = 0, \forall t \neq s$$

Caso 1 – Modelo AR(1): foi antes dito que verifica 5'

Caso 2 - Modelo estático:  $y_t = \beta_0 + \beta_1 x_t + u_t$

- Tem-se que  $E(y_t | x_t) = \beta_0 + \beta_1 x_t$  e o requisito para a consistência do OLS:  $E(u_t | x_t) = 0$  (exog. contemporânea), podendo ocorrer  $E(u_t, u_s | x_t, x_s) = 0 \neq 0$  (exemplo:  $u_t = y_{t-1}, \dots$ , dado que  $y_{t-1} = f(u_{t-1}, \dots)$ )
- Só assumindo adicionalmente que  $E(y_t | x_t, y_{t-1}, x_{t-1}, \dots) = E(y_t | x_t)$ , o que equivale a assumir  $E(u_t | x_t, y_{t-1}, x_{t-1}, \dots) = E(u_t | x_t) = 0$ , se tem  $Corr(u_t, u_s | X) = 0$  (um modelo estático dinamicamente completo)
  - Intuição de  $E(y_t | x_t, y_{t-1}, x_{t-1}, \dots) = E(y_t | x_t)$ : tendo-se controlado para  $x_t$ ,  $(y_{t-1}, x_{t-1}, \dots)$  não influencia  $y_t$

# Modelos dinamicamente completos

Caso 3 - Modelo  $y_t = \beta_0 + \beta_1 x_t + \beta_2 y_{t-1} + \beta_3 x_{t-1} + u_t$

- $E(y_t | x_t, y_{t-1}, x_{t-1}) = \beta_0 + \beta_1 x_t + \beta_2 y_{t-1} + \beta_3 x_{t-1}$  e o requisito para a consistência do OLS é:  $E(u_t | x_t, y_{t-1}, x_{t-1}) = 0$ , podendo ocorrer  $E(u_t, u_s | x_t, x_s) \neq 0$  (exemplo,  $u_t = y_{t-2}, \dots$ , dado que  $y_{t-2} = f(u_{t-2}, \dots)$ )
- Só assumindo adicionalmente que  $E(y_t | x_t, y_{t-1}, x_{t-1}, \dots) = E(y_t | x_t, y_{t-1}, x_{t-1})$ , equivalendo a  $E(u_t | x_t, y_{t-1}, x_{t-1}, \dots) = E(u_t | x_t, y_{t-1}, x_{t-1}) = 0$ , se tem  $E(u_t, u_s | x_t, x_s) \neq 0$  (um modelo dinamicamente completo)
  - Intuição: tendo-se controlado para  $(x_t, y_{t-1}, x_{t-1}), (y_{t-2}, x_{t-2}, \dots)$  não influencia  $y_t$

**Em geral, um modelo contendo as variáveis e os lags relevantes para explicar  $y_t$  é dinamicamente completo (não tem autocorrelação)**

# Autocorrelação: definição e consequências

Decorre da falha do pressuposto 5':

$$E(u_t, u_s | x_t, x_s) \neq 0, \forall t \neq s,$$

O que ocorrerá se o modelo não for dinamicamente completo

Autocorrelação AR(1):

$$u_t = \rho u_{t-1} + \varepsilon_t,$$
$$|\rho| < 1, \varepsilon_t \sim \text{ruído branco}$$

Autocorrelação AR(p):

$$u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} \dots \rho_p u_{t-p} + \varepsilon_t$$
$$\varepsilon_t \sim \text{ruído branco}$$

Consequências sobre o estimador e inferência OLS:

- estimador centrado (ex. estrita) ou consistente (dependência fraca)
- estimador não BLUE com variância e inferência standard inválida

# Autocorrelação: testes

## Autocorrelação AR(1)

$H_0: \rho = 0$  (ausência de autocorrelação) e  $H_1: \rho \neq 0$  ou  $H_1: \rho > 0$

Testes

- $t_\rho$  (sob exogeneidade estrita)
- **Durbin-Watson** (sob exogeneidade estrita e normalidade do erro)
- H-alt de Durbin (sem exogeneidade estrita)

## Autocorrelação AR(p)

$H_0: \rho_1 = \rho_2 \dots = \rho_p = 0$  (ausência de autocorrelação)

Testes (sem exogeneidade estrita)

- H-alt de Durbin
- Breusch-Godfrey
- Válidos com homoscedasticidade. Todos podem ser feitos robustos, except o DW

# Autocorrelação: testes

## AR(1) : testes $t_\rho$ e H-alt de Durbin

1. Estimar o modelo de interesse:  $y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t$
2. Obter os resíduos  $\hat{u}_t$
3. Estimar o modelo auxiliar:
  - $t_\rho$ :  $\hat{u}_t = \rho \hat{u}_{t-1} + \varepsilon_t$
  - H-alt de Durbin:  $\hat{u}_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + \rho \hat{u}_{t-1} + e_t$
4. Aplicar o teste:  $t_\rho = \frac{\hat{\rho}}{\hat{\sigma}_{\hat{\rho}}}$

# Autocorrelação: testes

## AR(1) : testes de Durbin-Watson

1. Estimar o modelo de interesse:  $y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t$

2. Obter os resíduos  $\hat{u}_t$

3. Obter a estatística de teste  $DW = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2} \approx 2(1 - \hat{\rho})$

4. A distribuição DW tem uma zona inconclusiva, possuindo dois valores críticos, dL e dU:

- $DW < dL$ : rejeita-se  $H_0$
- $dL < DW < dU$  : inconclusão
- $DW > dU$  : não se rejeita  $H_0$ .



# Autocorrelação: testes

AR(p) : testes  $t_\rho$  e H-alt de Durbin

Teste BG

1. Estimar o modelo de interesse:  $y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t$

2. Obter os resíduos  $\hat{u}_t$

3. Estimar o modelo auxiliar:

$$\hat{u}_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + \rho_1 \hat{u}_{t-1} + \rho_2 \hat{u}_{t-2} + \dots + \rho_p \hat{u}_{t-p} + e_t$$

4. Aplicar o teste:

– Versão BG:  $LM = (N - p)R_{\hat{u}}^2 \sim X_p^2$

– Versão F (p restrições). Neste caso, colocando  $y_t$  em lugar de  $\hat{u}_t$  dá o mesmo resultado

# Autocorrelação: testes

## Exemplo: confiança do consumidor em Portugal

```
. tsset t
```

```
    time variable:  t, 1 to 80
```

```
        delta: 1 unit
```

```
. reg ccl1 unemp
```

Source	SS	df	MS	Number of obs	=	80
-----+-----				F(1, 78)	=	120.39
Model	3721.93515	1	3721.93515	Prob > F	=	0.0000
Residual	2411.34478	78	30.9146767	R-squared	=	0.6068
-----+-----				Adj R-squared	=	0.6018
Total	6133.27994	79	77.6364549	Root MSE	=	5.5601

ccl1	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unemp	-4.17529	.3805262	-10.97	0.000	-4.932859	-3.41772
_cons	-44.94287	2.427369	-18.52	0.000	-49.77539	-40.11035

```
. predict uhat, resid
```

```
(2 missing values generated)
```

# Autocorrelação: testes

```
. reg uhat L.uhat
```

```
...
```

uhat	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
uhat					
L1.	.8831601	.0516228	<b>17.11</b>	0.000	.780366 .9859543
_cons	.1151422	.2847252	0.40	0.687	-.4518181 .6821026

```
. reg uhat unemp L.uhat
```

```
...
```

uhat	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
unemp	.2097498	.1738344	1.21	0.231	-.1364714 .5559709
uhat					
L1.	.8882955	.0516463	<b>17.20</b>	0.000	.7854329 .9911581
_cons	-1.181139	1.111194	-1.06	0.291	-3.394274 1.031997

Em ambos os testes se rejeita a hipótese nula de ausência de autocorrelação

# Diferenciação e autocorrelação

Considere-se um modelo linear simples

$$y_t = \beta_0 + \beta_1 x_t + u_t$$

onde  $u_t$  segue um passeio aleatório:  $u_t = u_{t-1} + \varepsilon_t$

A versão com as variáveis às diferenças

$$\Delta y_t = \beta_0 + \beta_1 \Delta x_t + \Delta u_t$$

terá  $\Delta u_t$  com média 0, variância constante e autocorrelação de 0

Para outros tipos de autocorrelação, aplicar diferenças atenua ou elimina o problema

# Soluções para a autocorrelação

## 1. Método dos mínimos quadrados generalizados admissíveis (FGLS)

Assume exogeneidade estrita e  $u_t$  AR(1)

- Modelo:

$$Y_t = \beta_0 + \beta_1 X_t + u_t$$

$$u_t = \rho u_{t-1} + \epsilon_t, \epsilon_t \sim IID(0, \sigma_\epsilon^2), |\rho| < 1$$

- Escrever o modelo em função de  $\epsilon_t$ :

$$Y_{t-1} = \beta_0 + \beta_1 X_{t-1} + u_{t-1} \Leftrightarrow u_{t-1} = Y_{t-1} - \beta_0 - \beta_1 X_{t-1}$$

$$u_t = \rho u_{t-1} + \epsilon_t = \rho Y_{t-1} - \rho \beta_0 - \beta_1 \rho X_{t-1} + \epsilon_t$$

$$Y_t = \beta_0 + \beta_1 X_t + u_t$$

$$Y_t = \beta_0 + \beta_1 X_t + \rho Y_{t-1} - \rho \beta_0 - \beta_1 \rho X_{t-1} + \epsilon_t$$

$$\underbrace{Y_t - \rho Y_{t-1}}_{Y_t^*} = \beta_0 (1 - \rho) + \beta_1 \underbrace{(X_t - \rho X_{t-1})}_{X_t^*} + \epsilon_t$$

# Soluções para a autocorrelação

- Nesta nova formulação do modelo:
  - ▶ Não existe autocorrelação pois  $\epsilon_t \sim IID(0, \sigma_\epsilon^2)$
  - ▶ Ao incluir-se um desfasamento de algumas variáveis, o modelo passa a estar definido apenas para  $t \geq 2$
  - ▶ A observação perdida pode ser recuperada como:

$$\underbrace{\sqrt{1 - \rho^2} Y_1}_{Y_1^*} = \beta_0 \sqrt{1 - \rho^2} + \beta_1 \underbrace{\sqrt{1 - \rho^2} X_1}_{X_1^*} + \underbrace{\sqrt{1 - \rho^2} u_1}_{\epsilon_1}$$

- ▶ Para construir as variáveis transformadas é necessário obter previamente uma estimativa de  $\rho \rightarrow$  Mínimos Quadrados Generalizados Admissíveis

# Soluções para a autocorrelação

- Válido apenas assintoticamente
- Duas versões:
  - ▶ Cochrane-Orcutt: omite a primeira observação
  - ▶ Prais-Winsten: considera todas as observações
- Processo iterativo para estimar  $\rho$ :
  - 1 Estimar o modelo original  $Y_t = \beta_0 + \beta_1 X_{t1} + \dots + \beta_k X_{tk} + u_t$
  - 2 Calcular os resíduos  $\hat{u}_t = Y_t - \hat{Y}_t = Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_{t1} - \dots - \hat{\beta}_k X_{tk}$
  - 3 Estimar  $\hat{u}_t = \rho \hat{u}_{t-1} + \epsilon_t$
  - 4 Estimar o modelo transformado usando o  $\hat{\rho}$  obtido no 3º passo;
  - 5 Com os  $\hat{\beta}$ 's estimados no 4º passo, reiniciar o processo a partir do 2º passo até que os  $\rho$ 's estimados em duas iterações sucessivas forem, de acordo com o critério definido, idênticos

# Soluções para a autocorrelação

2. Aumento de lags no modelo para obter um modelo dinamicamente completo

Efeito do aumento de lags: exemplos

## Modelo dinâmico AR(1) com autocorrelação AR(1)

- Modelo:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + u_t,$$

$$u_t = \rho u_{t-1} + \epsilon_t, \epsilon_t \sim IID(0, \sigma_\epsilon^2), |\rho| < 1.$$

- Escrever o modelo em função de  $\epsilon_t$ :

$$Y_{t-1} = \beta_0 + \beta_1 Y_{t-2} + u_{t-1} \Leftrightarrow u_{t-1} = Y_{t-1} - \beta_0 - \beta_1 Y_{t-2}$$

$$u_t = \rho u_{t-1} + \epsilon_t = \rho Y_{t-1} - \rho \beta_0 - \rho \beta_1 Y_{t-2} + \epsilon_t$$

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \rho Y_{t-1} - \rho \beta_0 - \rho \beta_1 Y_{t-2} + \epsilon_t$$

$$Y_t = \underbrace{\beta_0(1-\rho)} + (\rho + \beta_1) Y_{t-1} - \underbrace{\rho \beta_1}_{\rho \beta_1} Y_{t-2} + \epsilon_t$$

- Nesta nova formulação, *em que se acrescentou um desfasamento de  $Y$* , não existe autocorrelação, pois  $\epsilon_t \sim IID(0, \sigma_\epsilon^2)$



# Soluções para a autocorrelação

## Modelo dinâmico AR(1) com autocorrelação AR(2)

- Modelo:

$$\dots, u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \epsilon_t, \epsilon_t \sim IID(0, \sigma_\epsilon^2)$$

- Escrever o modelo em função de  $\epsilon_t$ :

$$Y_{t-1} = \beta_0 + \beta_1 Y_{t-2} + u_{t-1} \Leftrightarrow u_{t-1} = Y_{t-1} - \beta_0 - \beta_1 Y_{t-2}$$

$$Y_{t-2} = \beta_0 + \beta_1 Y_{t-3} + u_{t-2} \Leftrightarrow u_{t-2} = Y_{t-2} - \beta_0 - \beta_1 Y_{t-3}$$

...

$$Y_t = \underbrace{\beta_0(1 - \rho_1 - \rho_2)} + (\rho_1 + \beta_1) Y_{t-1} + (\rho_2 - \rho_1 \beta_1) Y_{t-2} - \underbrace{\rho_2 \beta_1} Y_{t-3} + \epsilon_t$$

- Nesta nova formulação, *em que se acrescentaram dois desfasamentos de  $Y$* , não existe autocorrelação, pois  $\epsilon_t \sim IID(0, \sigma_\epsilon^2)$

# Soluções para a autocorrelação

O exemplo mostra que o problema de autocorrelação desaparece se:

- Forem acrescentados defasamentos a todas as variáveis do modelo, incluindo a variável dependente
- O número de defasamentos acrescentados a cada variável corresponder à ordem do processo de autocorrelação que caracteriza o modelo original

Em termos práticos:

- Não se conhece com certeza se existe autocorrelação e, existindo, qual a sua ordem
- A solução passa por ir acrescentado defasamentos ao modelo e, após a sua estimação, testar se existe autocorrelação. Quando deixar de existir autocorrelação, então já foi acrescentado o número de defasamentos suficiente para resolver o problema de autocorrelação e o modelo já se tornou dinamicamente completo

# Soluções para a autocorrelação

## Exemplo: confiança do consumidor em Portugal

```
. reg cc1 unemp L.cc1 L.unemp
```

Source	SS	df	MS	Number of obs	=	79
-----+-----				F(3, 75)	=	313.31
Model	5677.30236	3	1892.43412	Prob > F	=	0.0000
Residual	453.012125	75	6.04016167	R-squared	=	0.9261
-----+-----				Adj R-squared	=	0.9231
Total	6130.31449	78	78.5937755	Root MSE	=	2.4577

cc1	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unemp	-1.619056	1.052206	-1.54	0.128	-3.715157 .4770449	
cc1						
L1.	.9335196	.054141	17.24	0.000	.8256653 1.041374	
unemp						
L1.	1.433666	1.028628	1.39	0.168	-.6154668 3.482798	
_cons	-3.605968	2.687144	-1.34	0.184	-8.959033 1.747098	

```
. predict uhat1, resid
```

# Soluções para a autocorrelação

```
. reg uhat1 L.uhat1
```

Source	SS	df	MS	Number of obs	=	78
-----+-----						
				F(1, 76)	=	0.59
Model	3.44192247	1	3.44192247	Prob > F	=	0.4464
Residual	446.524834	76	5.87532676	R-squared	=	0.0076
-----+-----						
				Adj R-squared	=	-0.0054
Total	449.966756	77	5.84372411	Root MSE	=	2.4239

uhat1	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
uhat1						
L1.	-.0878209	.1147396	<b>-0.77</b>	0.446	-.3163446	.1407028
_cons	-.0251342	.2744797	-0.09	0.927	-.5718079	.5215394

-----+-----						
-------------	--	--	--	--	--	--

Não se rejeita  $H_0$  de ausência de autocorrelação. O modelo incluindo os lags é dinamicamente completo.

De seguida apresentam-se os estimadores de Prais-Winsten e Cochane-Orcutt com o modelo estático, para ilustrar os comandos

# Soluções para a autocorrelação

```
. prais ccl unemp
```

```
...
```

```
Prais-Winsten AR(1) regression -- iterated estimates
```

Source	SS	df	MS	Number of obs	=	80
-----+-----				F(1, 78)	=	66.44
Model	386.992482	1	386.992482	Prob > F	=	0.0000
Residual	454.293874	78	5.82428043	R-squared	=	0.4600
-----+-----				Adj R-squared	=	0.4531
Total	841.286356	79	10.6491944	Root MSE	=	2.4134

ccl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unemp	-1.558921	.8579676	-1.82	0.073	-3.267004	.1491607
_cons	-62.86105	7.104822	-8.85	0.000	-77.00566	-48.71644

```
-----+-----
```

rho	.947412
-----	---------

```
-----+-----
```

```
Durbin-Watson statistic (original) 0.218571
```

```
Durbin-Watson statistic (transformed) 2.187046
```

# Soluções para a autocorrelação

```
. prais ccl unemp, corc
```

```
...
```

```
Cochrane-Orcutt AR(1) regression -- iterated estimates
```

Source	SS	df	MS	Number of obs	=	79
-----+-----				F(1, 77)	=	3.65
Model	21.4916817	1	21.4916817	Prob > F	=	0.0599
Residual	453.756859	77	5.89294623	R-squared	=	0.0452
-----+-----				Adj R-squared	=	0.0328
Total	475.248541	78	6.09293002	Root MSE	=	2.4275

ccl	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
unemp	-1.675038	.8771134	-1.91	0.060	-3.421594	.0715177
_cons	-61.10983	7.972274	-7.67	0.000	-76.98465	-45.235
-----+-----						
rho	.9427111					

```
Durbin-Watson statistic (original) 0.218571
```

```
Durbin-Watson statistic (transformed) 2.169623
```

# Heteroscedasticidade

Considere-se o modelo

$$y_t = \beta_0 + \beta_1 z_t + \beta_2 y_{t-1} + \beta_3 z_{t-1} + u_t$$

Com a falha do pressuposto 4':

$$\text{Var}(u_t | \mathbf{x}_t) = \text{Var}(u_t | z_t, y_{t-1}, z_{t-1}) = \text{Var}(y_t | z_t, y_{t-1}, z_{t-1}) = \sigma^2 h(\mathbf{x}_t)$$

Consequências sobre o estimador e inferência OLS:

- Estimadores centrados (ex. estrita) ou consistentes (dependência fraca)
- Variância e inferência standard incorrectas

Teste BP -  $H_0: \text{Var}(u_t | z_t, y_{t-1}, z_{t-1}) = \sigma^2$  (válido sem autocorrelação)

- Regressão auxiliar:  $\hat{u}^2 = \gamma_0 + \gamma_1 z_t + \gamma_2 y_{t-1} + \gamma_3 z_{t-1} + e$ ,  $R_{\hat{u}^2}^2$
- Estatística de teste e distribuição:

$$F = \frac{R_{\hat{u}^2}^2 / 3}{(1 - R_{\hat{u}^2}^2) / (N - 3 - 1)} \sim F(3, N - 3 - 1)$$

ou

$$LM = NR_{\hat{u}^2}^2 \sim \chi_3^2$$

# Heteroscedasticidade

Considere-se o AR(1)

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + u_t.$$

Com homoscedasticidade  $Var(u_t|y_{t-1}) = Var(y_t|y_{t-1}) = \sigma^2$

Assim, ainda que  $E(y_t|y_{t-1})$  dependa de  $y_{t-1}$ , a  $Var(y_t|y_{t-1})$  não depende.

Considere-se o modelo estático

$$y_t = \beta_0 + \beta_1 z_t + u_t.$$

Com homoscedasticidade  $Var(u_t|z_t) = Var(y_t|z_t) = \sigma^2$





# Heteroscedasticidade

## **Procedimento com potencial de autocorrelação e de heteroscedasticidade:**

- Testar autocorrelação usando versões robustas à heteroscedasticidade
- Corrigir a autocorrelação, caso exista
- Testar heteroscedasticidade