

Métodos y técnicas del análisis del cambio climático

José Eduardo Alatorre Bremont

Orlando Reyes Martínez

División de Desarrollo Sostenible y Asentamientos Humanos
CEPAL

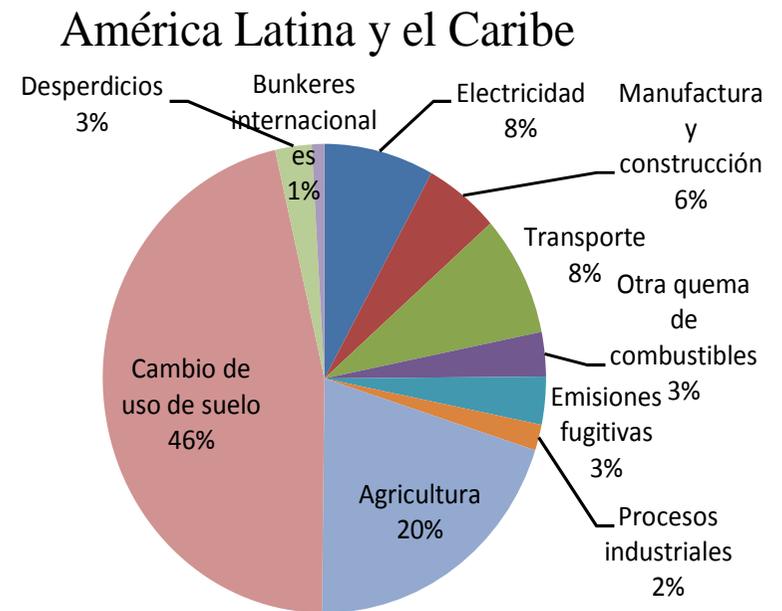
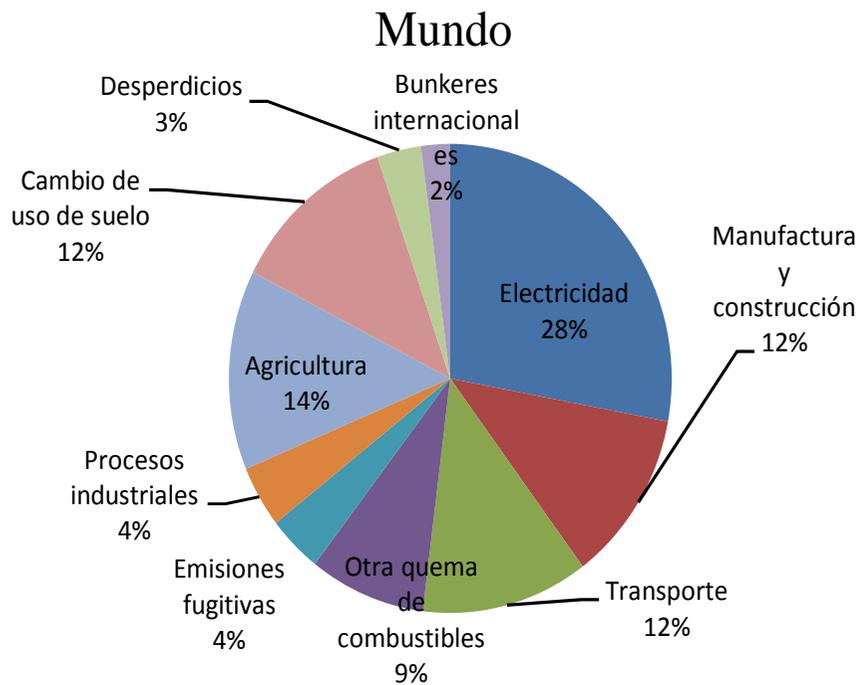
Febrero 2011

Introducción

Econometría: Es la aplicación de métodos matemáticos y estadísticos al análisis de los datos económicos, con la finalidad de dotar de contenido empírico a las teorías económicas y verificarlas o refutarlas.

Métodos econométricos aplicados al análisis de la economía del cambio climático

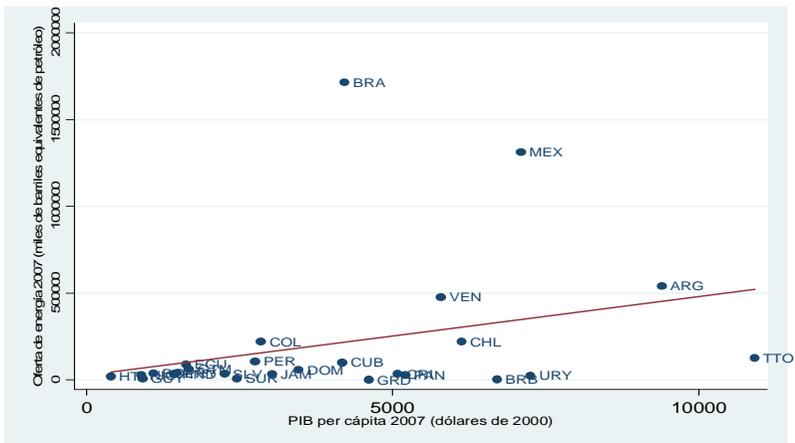
Emisiones de GEI por sector, 2005



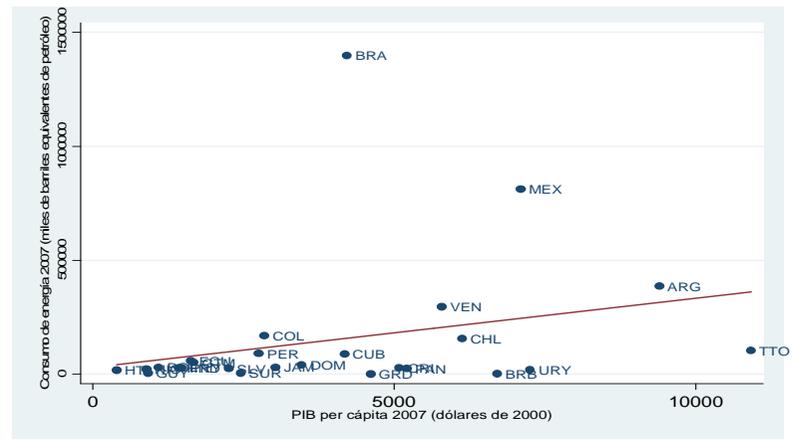
Fuente: World Resources Institute, 2010

Métodos econométricos aplicados al análisis de la economía del cambio climático

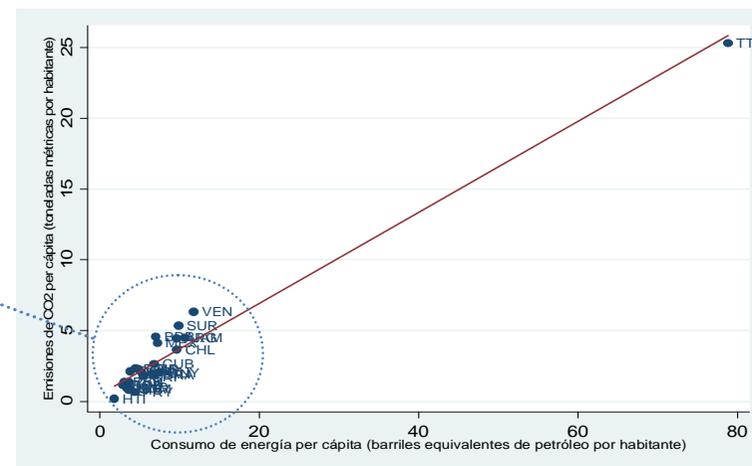
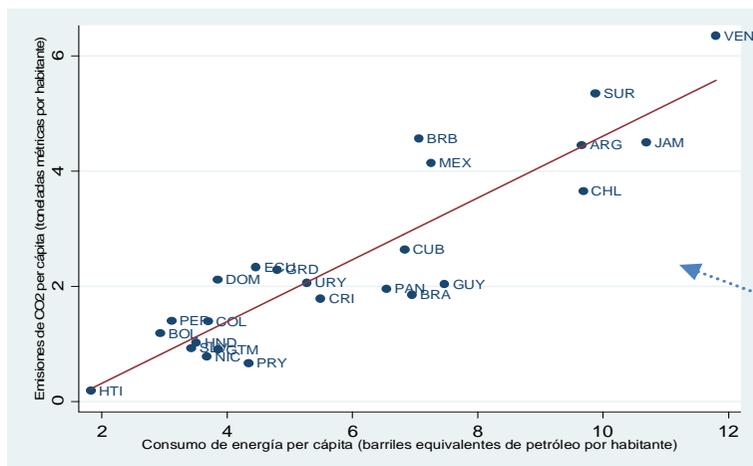
Oferta total de energía y PIB *per cápita* 2007



Consumo de energía y PIB *per cápita* 2007



Emisiones de CO₂ per cápita y consumo de energía *per cápita* 2006



Fuente: Elaborado por CEPAL con estadísticas de oferta total de energía del Sistema de Información Económica Energética (SIEE), de la Organización Latinoamericana de Energía (OLADE). Los datos de PIB *per cápita* a precios constantes del 2000, fueron obtenidos de la base de datos CEPAL (BADECON). Las estadísticas de CO₂ fueron obtenidas del sitio oficial ODM de la ONU en base a datos compilados por CDIAC.

Métodos econométricos aplicados al análisis de la economía del cambio climático

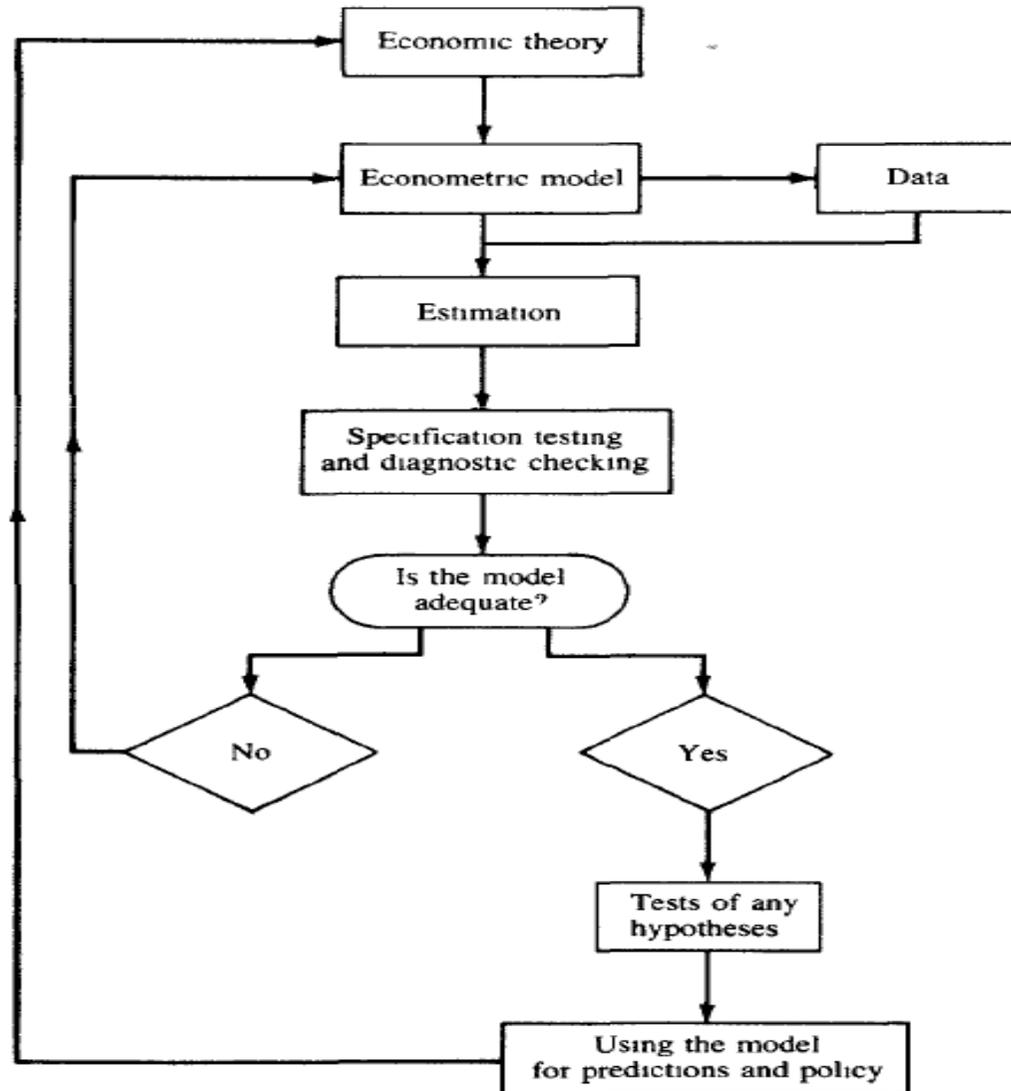
- ¿Qué efecto ejerce la actividad económica sobre la demanda de energía (gasolina, electricidad y otros tipos de energías)?
- ¿Cuál es el potencial de mitigación de las políticas de precios sobre los energéticos?
- ¿Cuál es el impacto del aumento de temperatura y/o la reducción/aumento de recursos hídricos sobre los rendimientos agrícolas?

Métodos econométricos aplicados al análisis de la economía del cambio climático

- Objetivos

1. Conocer las relaciones básicas entre variables de interés (ingreso y energía, precios y cantidad demandada, rendimientos y temperatura, etc.)
2. Realizar pronósticos y simular políticas.

Proceso de elaboración de un modelo



Proceso de elaboración de un modelo: Especificación

Por ejemplo, un modelo de demanda de gasolina:

$$(1) \quad \text{Ln } CG_t = \beta_1 + \beta_2 * \text{Ln } PR_t + \beta_3 * \text{Ln } Y^d_t + u_t$$

$$\beta_2 < 0 \text{ y } \beta_3 > 0$$

Donde,

CG: consumo de gasolina

PR: precios relativos de la gasolina

Y^d : Ingreso personal disponible

Ln: Indica logaritmo natural

u: término de error

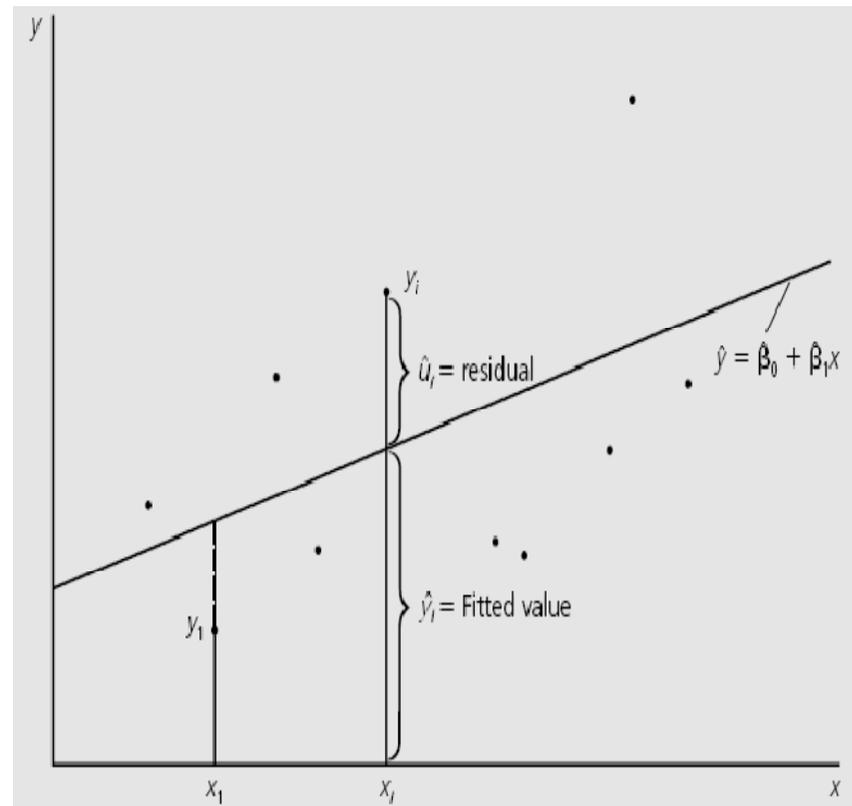
Proceso de elaboración de un modelo: Estimación

¿Cómo obtenemos la mejor predicción posible?

Un **estimador** es una fórmula, un método o receta para estimar un parámetro poblacional desconocido; y un **estimado** es el valor numérico obtenido cuando los datos muestrales son sustituidos en la fórmula.

El estimador de Mínimos Cuadrados Ordinarios (MCO) es el principio de estimación dominante.

Método de MCO



Proceso de elaboración de un modelo: Estimación

Inferencia

- ¿Cuáles son las propiedades de los parámetros estimados?
- ¿Cómo hacer inferencia sobre dichos parámetros?

Se puede probar que bajo ciertos supuestos el estimador de MCO es el mejor estimador lineal insesgado (BLUE por sus siglas en inglés).

Los supuestos necesarios para que el estimador sea insesgado y de varianza mínima son (teorema de Gauss – Markov):

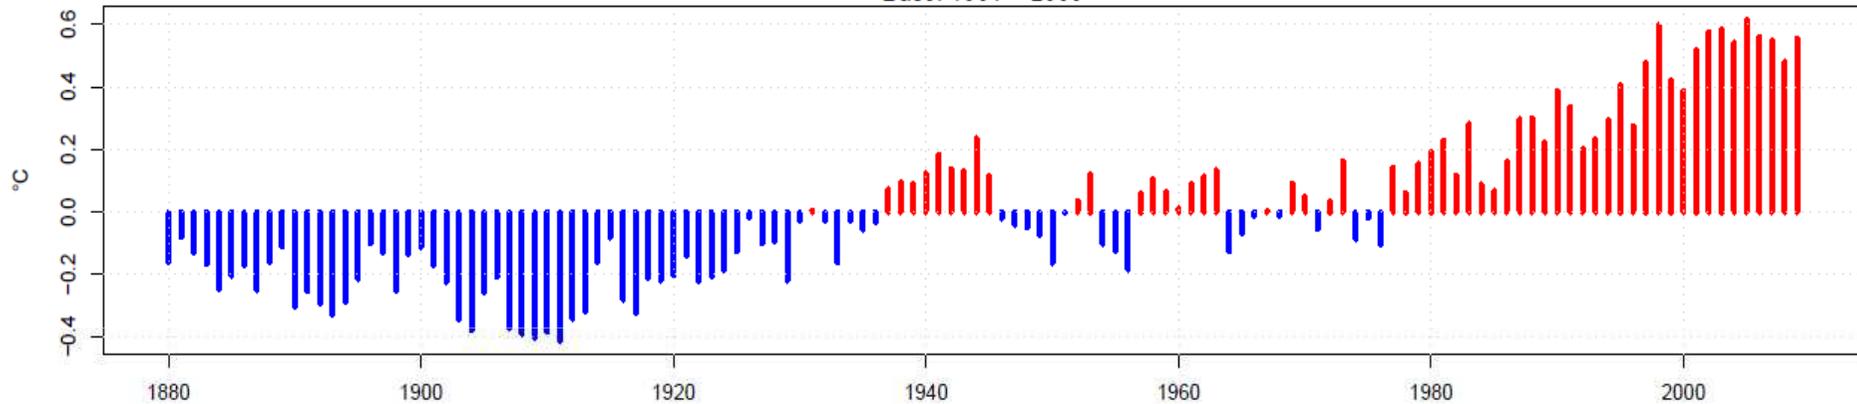
1. El modelo es lineal en los parámetros
2. $E[u_i | x_i] = 0$ para todo i
3. $\text{Var}(u_i | x_i) = \sigma^2$ para todo i
4. $\text{Cov}(u_i, u_j) = 0$ para todo $i \neq j$

El supuesto de normalidad no es necesario para que el estimador de MCO sea BLUE.

Tipos de datos: Series de tiempo

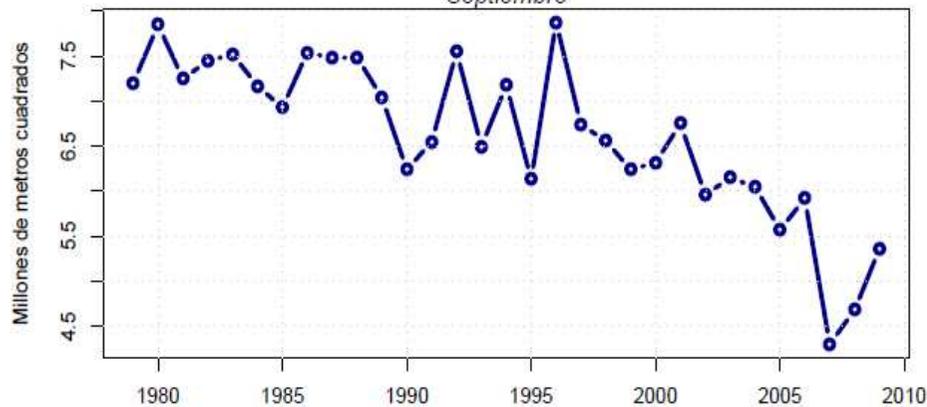
Anomalías de la temperatura global

Base: 1901 - 2000



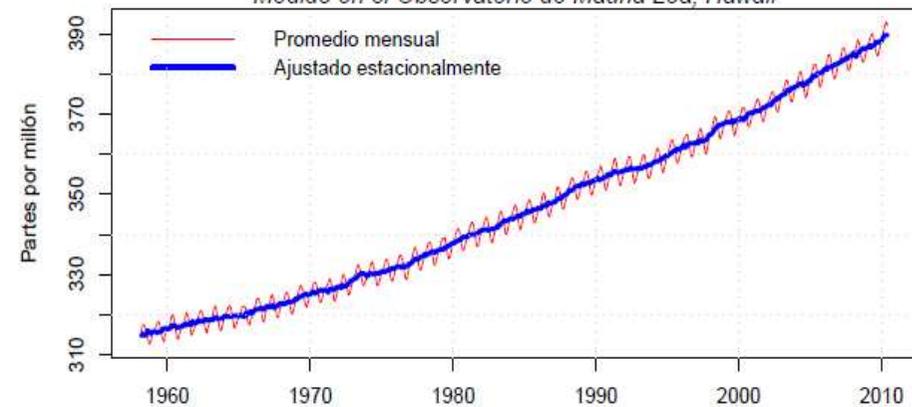
Extensión mínima promedio de área cubierta de hielo Ártico

Septiembre



CO2 en la atmósfera

Medido en el Observatorio de Mauna Loa, Hawaii



Tipos de datos: Sección cruzada

country	country isocode	year	cc	cg	ci	pc
Argentina	ARG	1990	65.50	17.83	10.98	64.82
Bolivia	BOL	1990	75.29	18.36	7.50	34.01
Brazil	BRA	1990	51.25	30.76	16.21	57.14
Chile	CHL	1990	54.02	22.89	19.41	47.71
Colombia	COL	1990	70.82	15.49	11.15	29.69
Costa Rica	CRI	1990	77.18	21.15	10.67	45.21
Cuba	CUB	1990	79.48	25.11	6.81	20.48

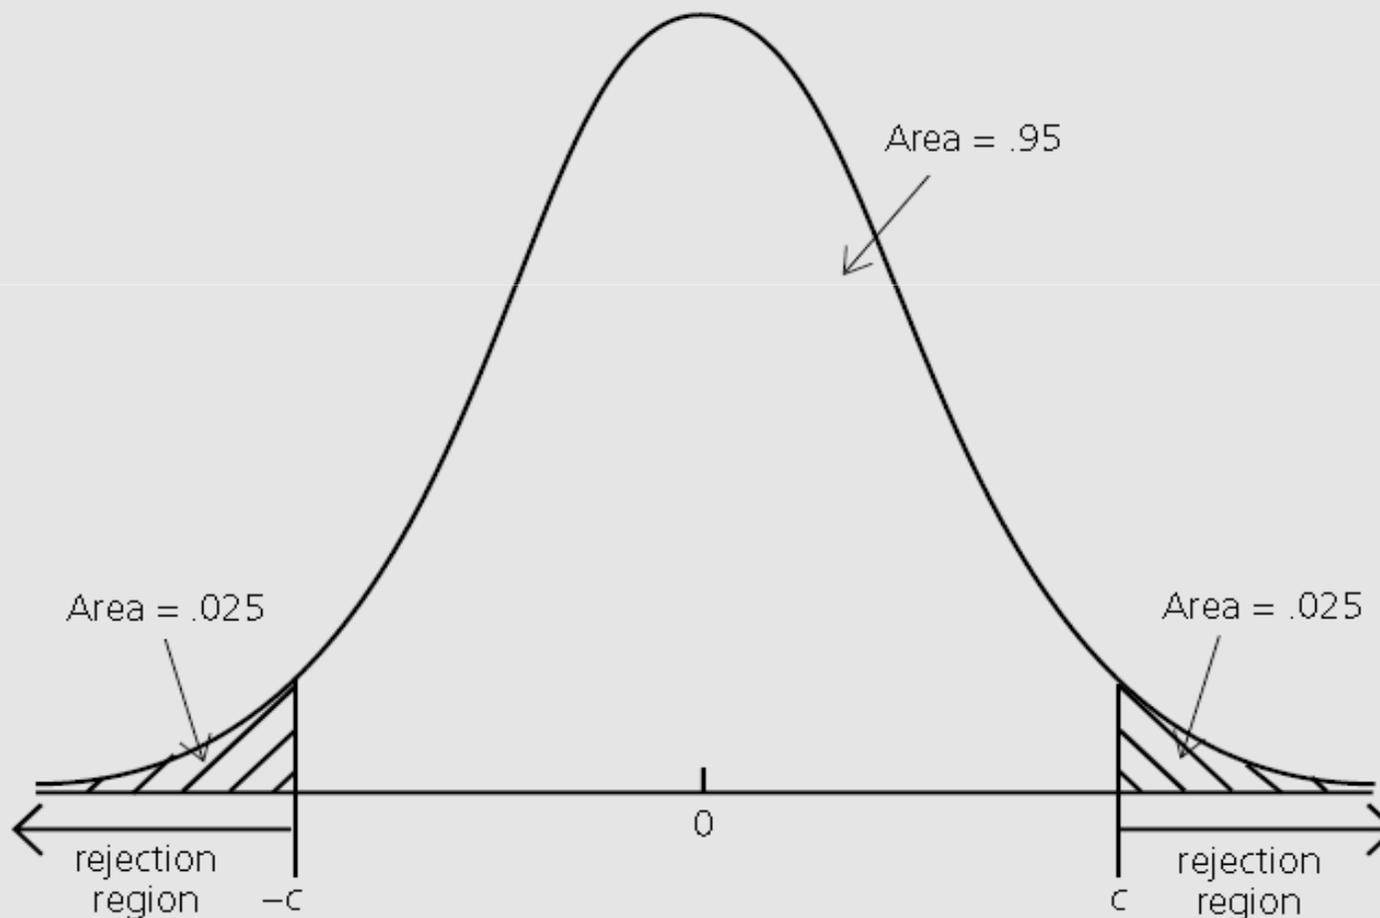
Fuente: Center for
International Comparisons of
Production, Income and
Prices

Tipos de datos: Datos panel

country	country isocode	year	cc	cg	ci	pc
Argentina	ARG	1999	69.24	17.10	15.41	69.06
Argentina	ARG	2000	68.70	17.46	14.48	67.54
Argentina	ARG	2001	67.83	18.06	12.85	65.88
Bolivia	BOL	1999	80.45	18.49	11.47	34.81
Bolivia	BOL	2000	80.20	18.64	10.64	33.53
Bolivia	BOL	2001	79.17	18.71	7.95	30.78
Brazil	BRA	1999	64.11	21.90	15.53	44.06
Brazil	BRA	2000	63.45	21.57	16.49	45.74
Brazil	BRA	2001	63.96	22.02	15.02	37.39
Chile	CHL	1999	60.48	18.01	19.24	48.28
Chile	CHL	2000	59.46	17.88	20.81	46.45
Chile	CHL	2001	59.71	18.19	20.49	40.43
Costa Rica	CRI	1999	71.62	14.29	8.27	46.09
Costa Rica	CRI	2000	73.73	15.02	8.39	46.78
Costa Rica	CRI	2001	75.79	15.96	11.26	47.60
Cuba	CUB	1999	73.76	26.21	3.07	39.43
Cuba	CUB	2000	73.05	26.65	3.35	40.04
Cuba	CUB	2001	73.35	26.47	3.27	38.87

Prueba de hipótesis

Rejection region for a 5% significance level test against the two-sided alternative $H_1: \mu \neq \mu_0$.



Prueba de hipótesis: Estadístico t

- A nosotros nos gustaría probar

$H_0: \beta_1 = \text{algun valor dado por la teoría}$

Vs.

$H_1: \beta_1 \neq \text{algun valor dado por la teoría}$

Para ello utilizamos la **prueba t**. Se puede demostrar que:

$$(\hat{\beta}_j - \beta_j) / \text{se}(\hat{\beta}_j) \sim t_{n-k-1}$$

Prueba de hipótesis: Estadístico t

Dónde n es el número de observaciones y k es el número de regresores diferentes a la constante.

Podemos verlo de esta manera:

$$t = \frac{(\textit{estimate} - \textit{hypothesized value})}{\textit{standard error}}.$$

Los programas econométricos regularmente muestran la hipótesis nula de que $\beta_1=0$.

Métodos econométricos

MODELOS UNIVARIADOS

Introducción

- ¿Podemos observar una serie de tiempo y obtener algunas conclusiones acerca de su comportamiento pasado que nos permita inferir algo sobre su probable comportamiento futuro?
 - Tendencia
 - Ciclo
 - Patrones estacionales
- Se puede construir un modelo que replique el comportamiento pasado y nos ayude a pronosticar el comportamiento futuro.

Modelos de series de tiempo

- Un **modelo de serie de tiempo** explica los patrones en los movimientos pasados y usa esta información para predecir los movimientos futuros.
 - Un modelo de series de tiempo es un método refinado de extrapolación de datos
 - Ofrecen buenos pronósticos

Características

- Objetivos:
 - Realización de pronósticos
- Ventajas:
 - Sólo requiere información
 - Produce buenos pronósticos
- Desventajas:
 - No permite simular políticas

Modelos determinísticos de series de tiempo

- No hacen referencia a las fuentes de aleatoriedad subyacente de la serie
- Útiles para formular pronósticos iniciales de forma rápida y ofrecen pronósticos aceptables
- No proporcionan tanta precisión como los modelos estocásticos

Modelos determinísticos de series de tiempo

Modelo	Especificación	Propiedades
Tendencia lineal	$Y_t = c_0 + c_1 * t$	Crecimiento absoluto constante
Tendencia exponencial	$\text{Log}(Y_t) = c_0 + c_1 * t$	Crecimiento porcentual constante
Tendencia autorregresiva	$Y_t = c_0 + c_1 * Y_{t-1}$	Crecimiento histórico
Tendencia autorregresiva logarítmica	$\text{Log}(Y_t) = c_0 + c_1 * \text{log}(Y_{t-1})$	Crecimiento histórico
Tendencia cuadrática	$Y_t = c_0 + c_1 * t + c_2 * t^2$	Crecimiento acelerado, amortiguado o decrecimiento
Curva de crecimiento logístico	$\Delta \text{Log}(Y_t) = c_0 + c_1 * Y_{t-1}$	Crecimiento en forma de S

Modelos de series de tiempo estocásticas

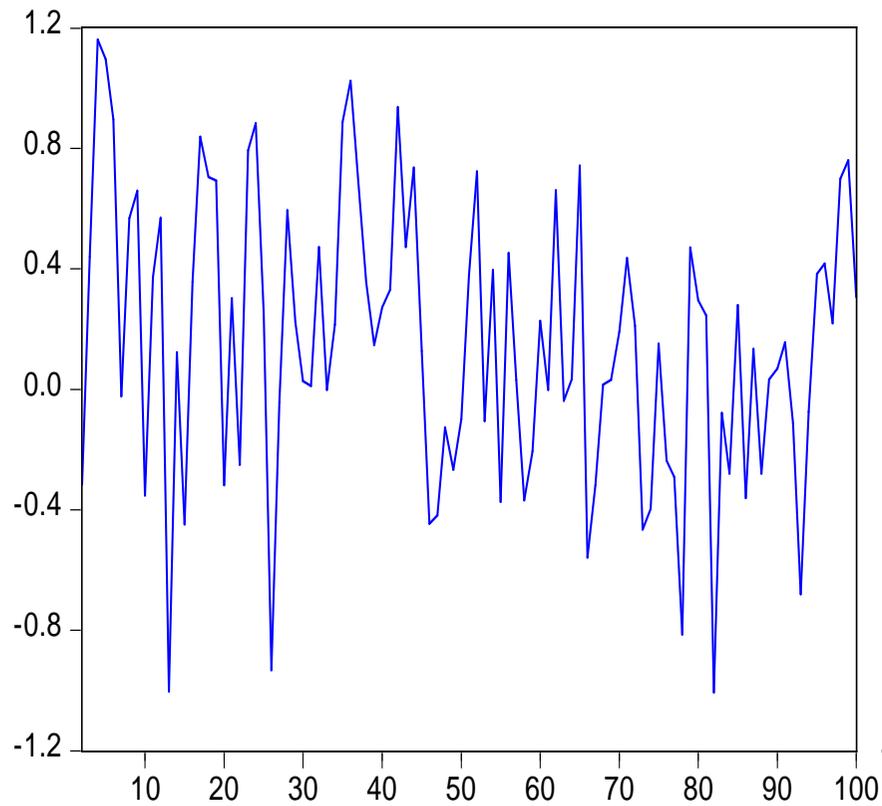
- Se basan en la suposición de que las series a modelar y pronosticar se han generado por un proceso estocástico (cada valor de la serie se han extraído de manera aleatoria de una distribución de probabilidad).
- Buscamos obtener una aproximación razonable del proceso que generó la serie.

Características deseables de las series

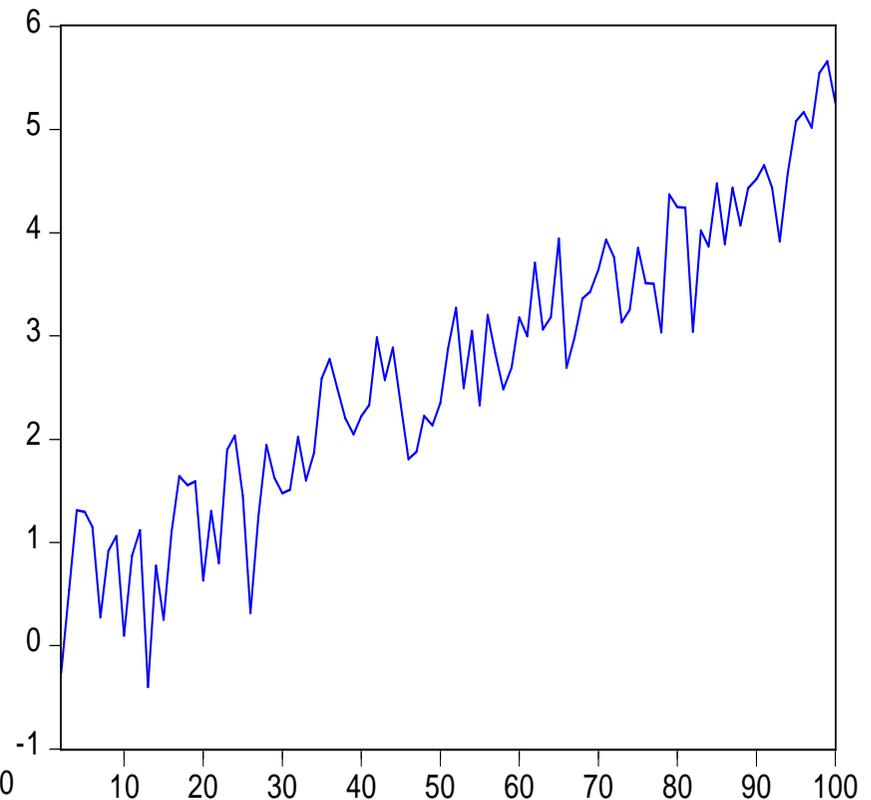
- Nos interesa conocer si el proceso estocástico subyacente que generó las variables es invariable en el tiempo.
- Si las características del proceso estocástico cambian con el tiempo, se le conoce como **proceso no estacionario** y será difícil representar la serie.
- Si están fijas en el tiempo se conoce como **proceso estacionario** → podemos modelar el proceso a partir de datos pasados.

Variables estacionarias

Serie estacionaria
 $Y1=0.09+0.3*Y1(-1)+\text{error}$

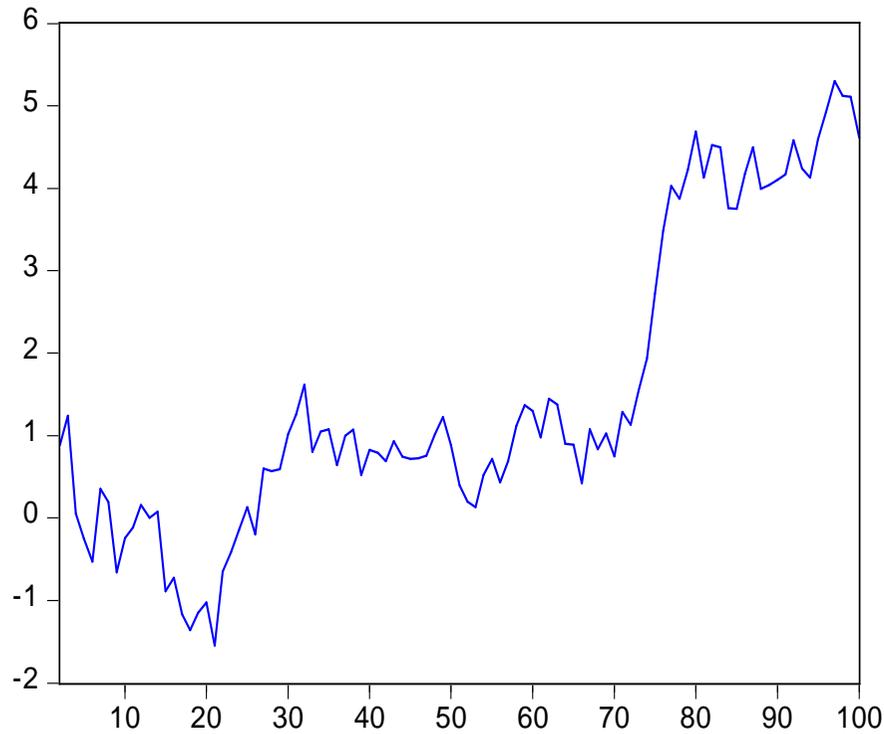


Serie estacionaria con tendencia determinística
 $Y1a = 0.9 + 0.3*Y1(-1) + \text{tendencia} + \text{error}$

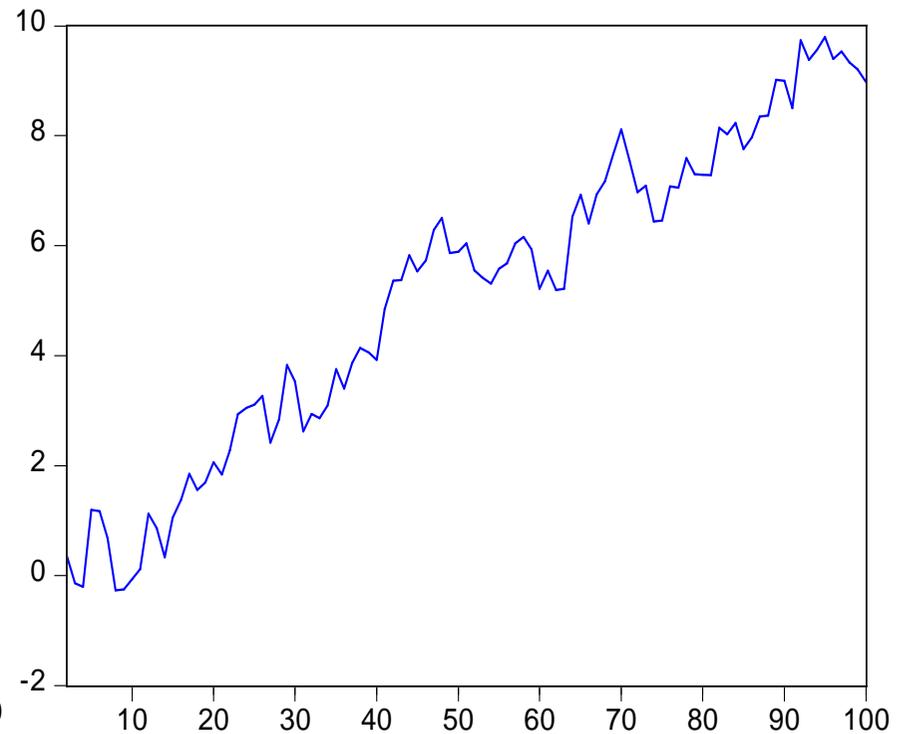


Variables no estacionarias

Random Walk sin constante
 $Y_2 = Y_2(-1) + \text{error}$

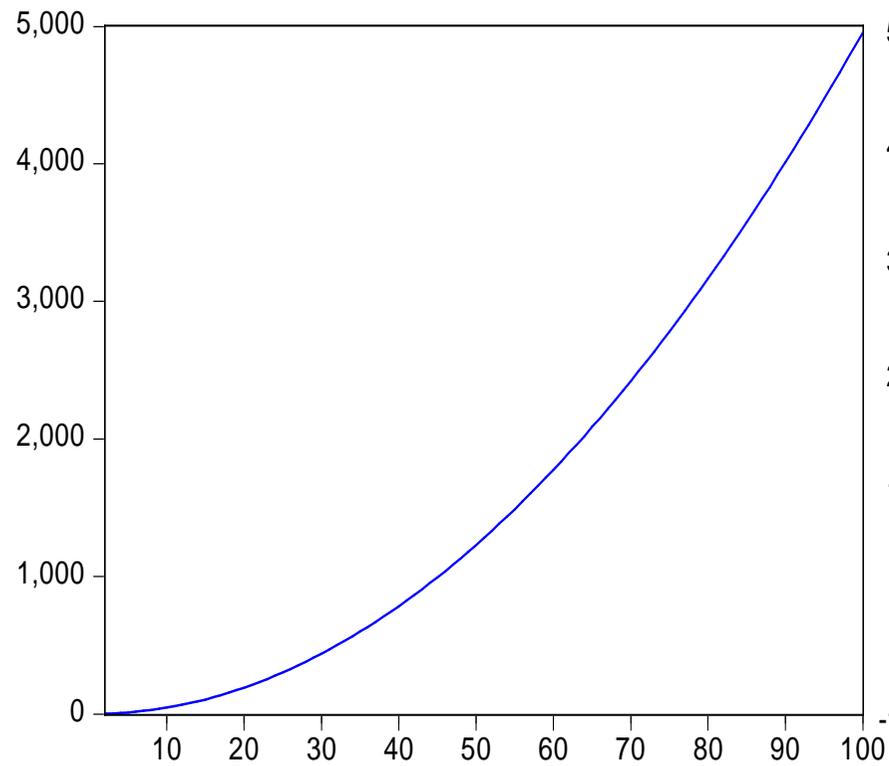


Random walk con constante positiva
 $Y_3 = 0.09 + Y_3(-1) + \text{error}$

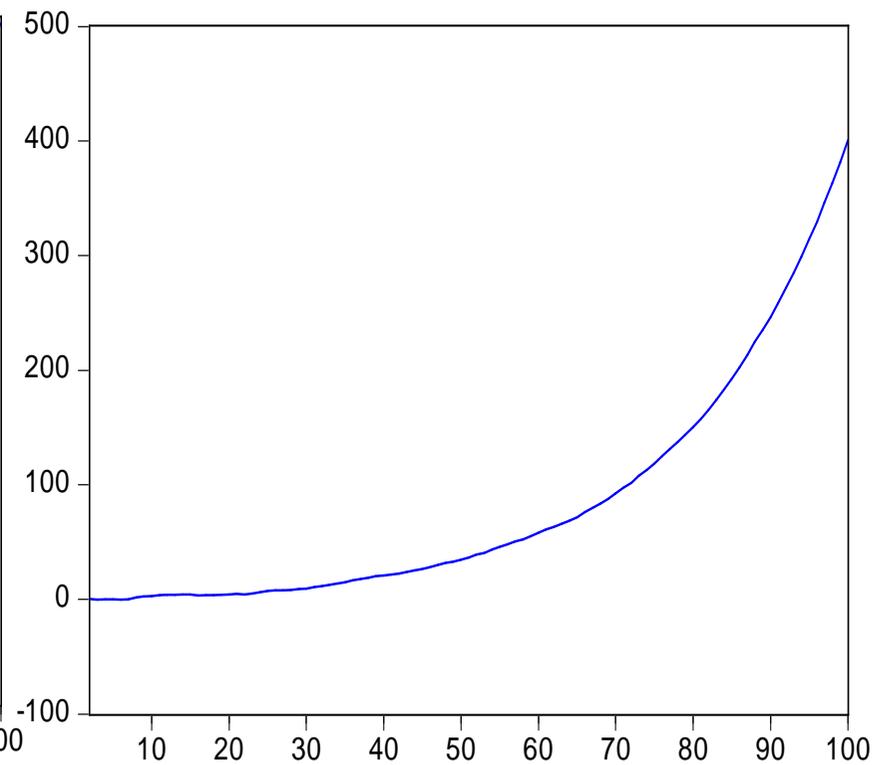


Variables no estacionarias

Random Walk con constante y tendencia
 $Y_6 = 0.09 + Y_6(-1) + \text{tendencia} + \text{error}$



Serie Explosiva
 $Y_4 = 0.09 + 1.05 * Y_4(-1) + \text{error}$



Orden de integración

- Pocas series que encontramos en la práctica son estacionarias. Podemos inducir estacionaridad al diferenciar las series:

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

- Una variable es integrada de orden d , escrita $I(d)$, si debe ser diferenciada d veces para volverse estacionaria → Una variable estacionaria es integrada de orden cero: $I(0)$
- Si las series están en logaritmos se cumple que la primera diferencia es una aproximación a la tasa de crecimiento

Estacionariedad

- **Correlograma:** Si la serie es estacionaria las autocorrelaciones deben desaparecer con rapidez a medida que aumenta el número de rezagos.
- **Pruebas de raíces unitarias:** Es la forma más rigurosa de probar si una serie es o no estacionaria

Caracterización de la serie: Correlograma

- Muestra cuánta correlación hay (e independencia) entre los datos individuales contiguos en la serie $y(t)$.

$$\rho_k = \text{Cov}(y(t), y(t+k)) / \sigma_{y(t)} \sigma_{y(t+k)}$$

Si la función de autocorrelación es cero o cercana a cero hay poco valor en usar modelos para pronosticar la serie

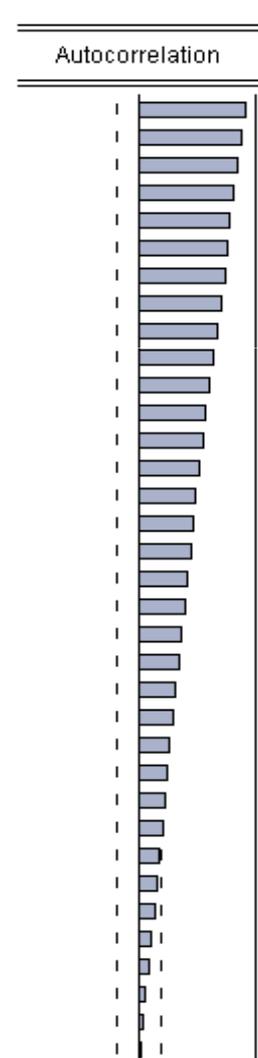
Correlograma y estacionaridad

- En una serie estacionaria la función de autocorrelación cae aceleradamente conforme k se incrementa.
- Si la función no cae es un indicador de no estacionaridad.

Estacionario



No estacionario



Modelos de promedio móvil (MA)

- Modelo promedios móviles de orden q ($MA(q)$):

$$y_t = \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots + \theta_q\varepsilon_{t-q}$$

- Donde ε es ruido blanco.
- La suma ponderada de procesos de ruido blanco pueden proporcionar buenas representaciones de procesos que no lo son.
- La función de autocorrelación (correlograma) muestra el orden de q .

Modelos autorregresivos (AR)

- Modelo autorregresivo de orden p $AR(p)$:

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \cdots + \varphi_p y_{t-p} + \varepsilon_t$$

- Donde ε es ruido blanco.
- La serie es generado por un promedio ponderado de observaciones pasadas que se remontan a p periodos.
- La función de autocorrelación parcial (correlograma) muestra el orden de p .

Modelos ARIMA

- Modelo ARIMA(p,d,q):

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

- Donde ε es ruido blanco.
- Patrones de las funcione de correlación:

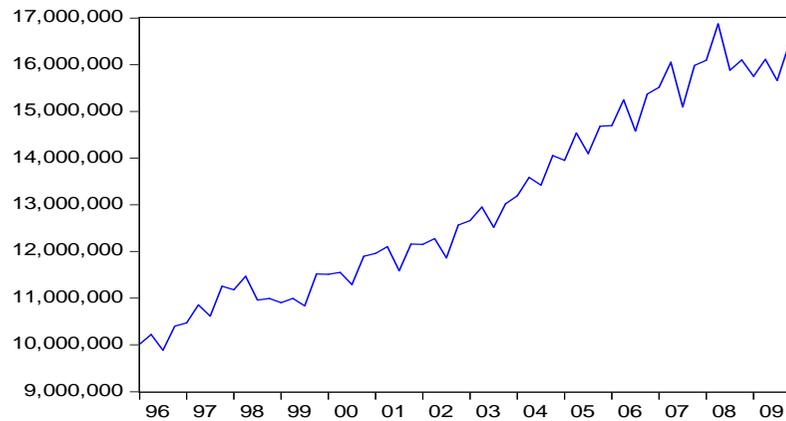
Proceso	Autocorrelación	Autocorrelación parcial
AR(p)	Infinito	Finito: decrece a partir del rezago p
MA(q)	Finito: decrece a partir del rezago q	Infinito
ARMA(p,q)	Infinito	Infinito

Método de Box y Jenkins

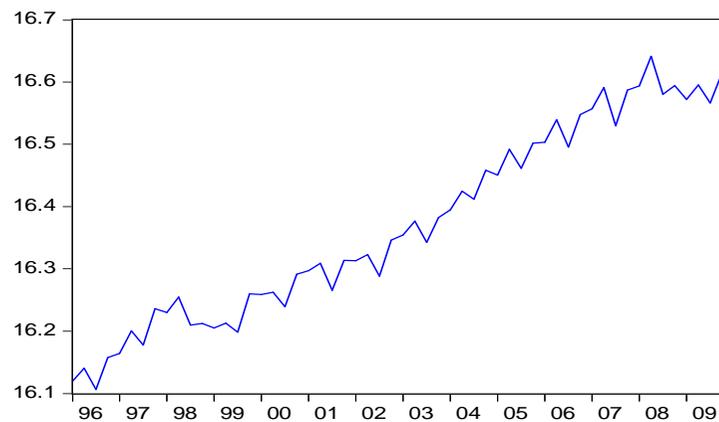
1. Transformar la variable de estudio para asegurar que sea estacionaria (que sus propiedades estocásticas sean invariantes en el tiempo)
2. Revisar el correlograma para inferir la estructura del modelo, estimar y realizar pruebas de diagnóstico para elegir la mejor especificación.
3. Realizar pronósticos

Ejemplo: PIB de Chile (PARTE I)

PIB de Chile
(Millones de pesos de 2003)

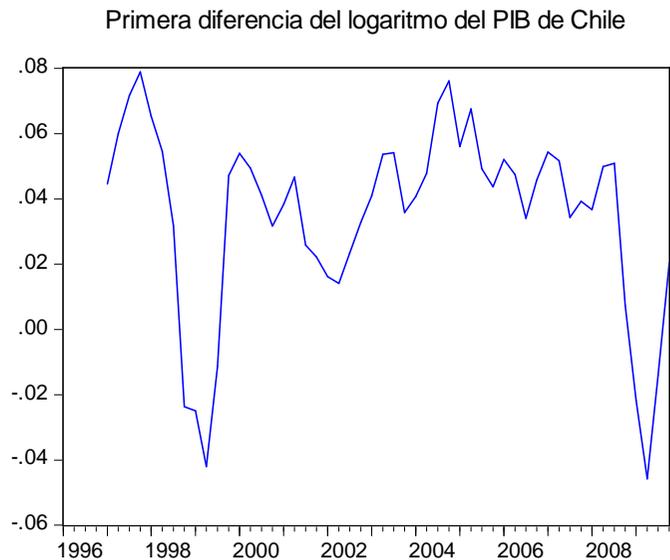


Logaritmo del PIB de Chile



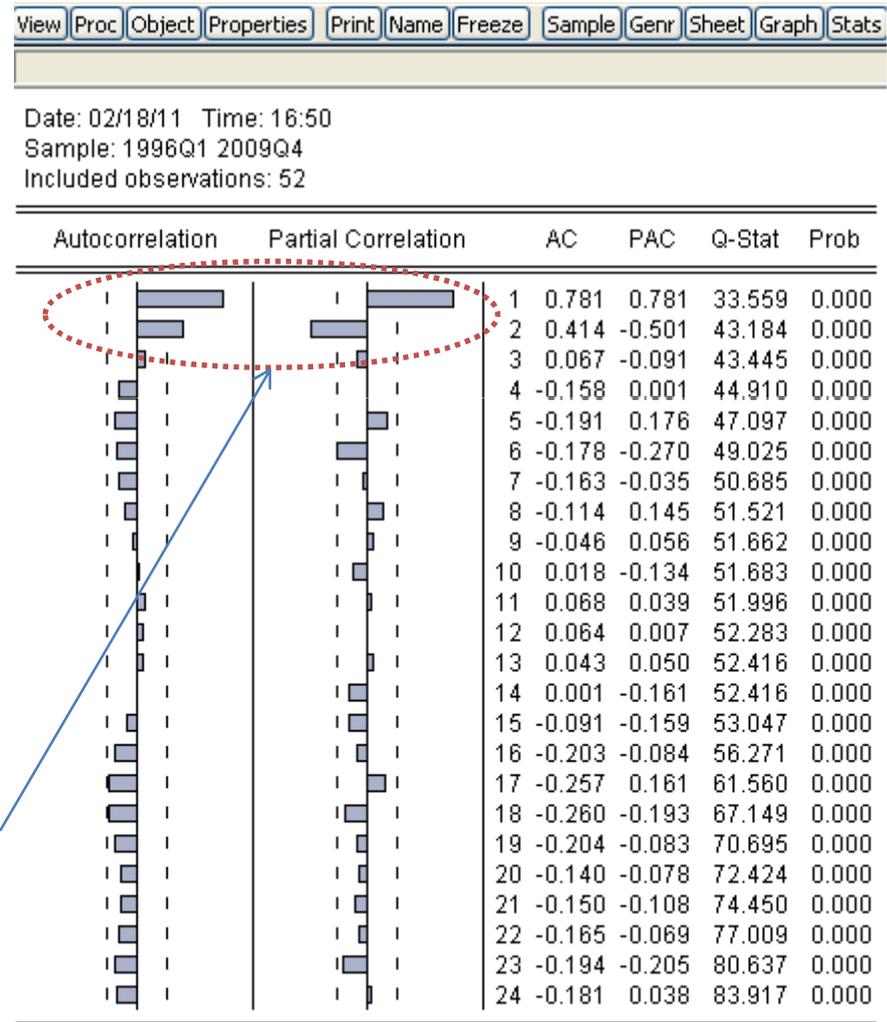
View Proc Object Properties Print Name Freeze Sample Genr Sheet Graph Stats						
Sample: 1996:1-2009:4						
Included observations: 56						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.930	0.930	51.092	0.000
		2	0.897	0.236	99.479	0.000
		3	0.830	-0.210	141.70	0.000
		4	0.803	0.177	181.95	0.000
		5	0.735	-0.205	216.31	0.000
		6	0.699	0.059	248.10	0.000
		7	0.629	-0.138	274.28	0.000
		8	0.600	0.119	298.65	0.000
		9	0.537	-0.091	318.61	0.000
		10	0.510	0.045	336.98	0.000
		11	0.445	-0.113	351.27	0.000
		12	0.405	-0.073	363.37	0.000
		13	0.334	-0.077	371.80	0.000
		14	0.292	-0.037	378.40	0.000
		15	0.222	-0.054	382.29	0.000
		16	0.187	0.054	385.14	0.000
		17	0.126	-0.036	386.47	0.000
		18	0.089	-0.062	387.14	0.000
		19	0.027	-0.045	387.21	0.000
		20	0.000	0.043	387.21	0.000
		21	-0.052	-0.058	387.46	0.000
		22	-0.081	-0.039	388.09	0.000
		23	-0.134	-0.021	389.85	0.000
		24	-0.155	0.022	392.29	0.000
		25	-0.196	-0.005	396.33	0.000
		26	-0.217	-0.066	401.42	0.000
		27	-0.262	-0.071	409.14	0.000
		28	-0.278	0.022	418.11	0.000
		29	-0.311	0.001	429.76	0.000
		30	-0.320	-0.024	442.59	0.000
		31	-0.353	-0.055	458.82	0.000
		32	-0.364	-0.027	476.77	0.000
		33	-0.389	0.006	498.11	0.000
		34	-0.389	-0.012	520.49	0.000
		35	-0.411	-0.040	546.58	0.000
		36	-0.410	-0.012	573.90	0.000

Ejemplo: PIB de Chile (PARTE I)



Al diferenciar una vez la serie se vuelve estacionaria.

El correlograma de la serie estacionaria muestra patrones consistentes con un AR(2) o MA(2)



Ejemplo: PIB de Chile

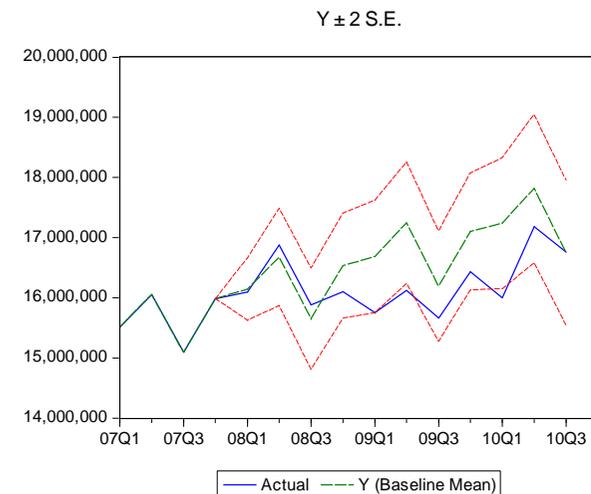
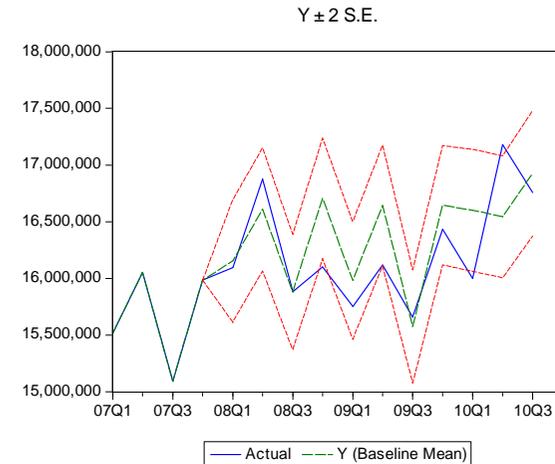
Dependent Variable: LOG(Y)-LOG(Y(-4))
 Method: Least Squares
 Date: 02/18/11 Time: 17:26
 Sample (adjusted): 1998Q1 2009Q4
 Included observations: 48 after adjustments
 Convergence achieved after 12 iterations
 MA Backcast: 1997Q3 1997Q4

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.034646	0.004342	7.979435	0.0000
AR(4)	-0.527814	0.166155	-3.176636	0.0027
MA(1)	1.128487	0.141048	8.000747	0.0000
MA(2)	0.681164	0.139685	4.876431	0.0000

R-squared	0.697802	Mean dependent var	0.032716
Adjusted R-squared	0.677198	S.D. dependent var	0.028699
S.E. of regression	0.016306	Akaike info criterion	-5.314934
Sum squared resid	0.011699	Schwarz criterion	-5.159001
Log likelihood	131.5584	Hannan-Quinn criter.	-5.256007
F-statistic	33.86662	Durbin-Watson stat	1.731449
Prob(F-statistic)	0.000000		

Inverted AR Roots	.60+.60i	.60+.60i	-.60-.60i	-.60-.60i
Inverted MA Roots	-.56+.60i	-.56-.60i		

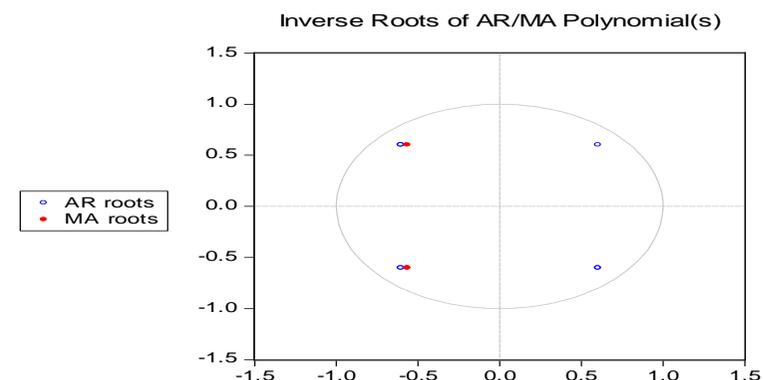
Al estimar la ecuación podemos realizar pronósticos



Ejemplo: PIB de Chile (PARTE I)

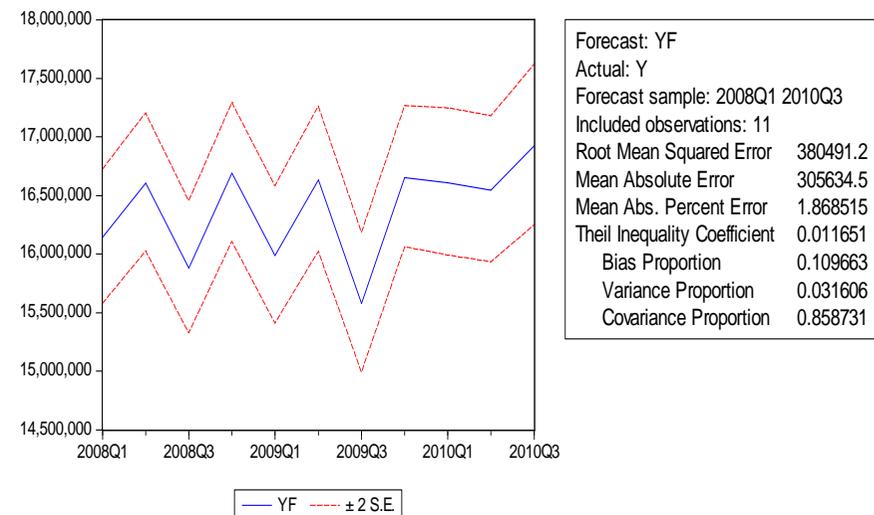
- Es importante buscar que el correlograma no tenga valores significativos
- También es importante que las raíces del modelo se encuentren dentro del círculo unitario

	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1			0.091	0.091	0.4242	
2			0.243	0.236	3.4950	
3			0.147	0.116	4.6537	
4			0.000	-0.078	4.6537	0.031
5			0.043	-0.016	4.7573	0.093
6			0.104	0.113	5.3790	0.146
7			-0.004	-0.011	5.3797	0.251
8			-0.115	-0.188	6.1723	0.290
9			0.043	0.043	6.2880	0.392
10			-0.024	0.071	6.3250	0.502
11			0.085	0.106	6.7981	0.559
12			-0.058	-0.139	7.0230	0.635
13			-0.013	-0.052	7.0338	0.722
14			-0.063	0.007	7.3146	0.773
15			-0.022	0.028	7.3488	0.834
16			-0.202	-0.266	10.409	0.660
17			-0.066	-0.061	10.742	0.706
18			-0.202	-0.055	14.021	0.524
19			-0.175	-0.041	16.544	0.416
20			-0.004	0.022	16.545	0.486



ARIMA: Ajuste y discriminación entre modelos

- Medidas de ajuste: R^2 , criterios de información:
 - Akaike,
 - Schwartz, y
 - Hannan-Quinn
- Error de pronóstico



Métodos econométricos

PRUEBAS DE DIAGNÓSTICO

Supuestos del modelo de regresión

Supuesto

1. Los residuales se distribuyen de una forma normal ($u_i \sim N(0, \sigma^2)$)
2. Los residuales no exhiben autocorrelación
 - $Cov(u_i, u_j) = 0$ para todo $i \neq j$
3. Los residuales no exhiben heteroscedasticidad
 - $Var(u_i | x_i) = \sigma^2$ para todo i

Consecuencia del no cumplimiento del supuesto

1. No podemos hacer inferencia
2. El estimador de MCO es insesgado pero ineficiente
→ Los errores estándar son incorrectos y las estadísticas de prueba basadas en ellos son inválidas

Prueba de normalidad de los errores

PRUEBA JARQUE – BERA

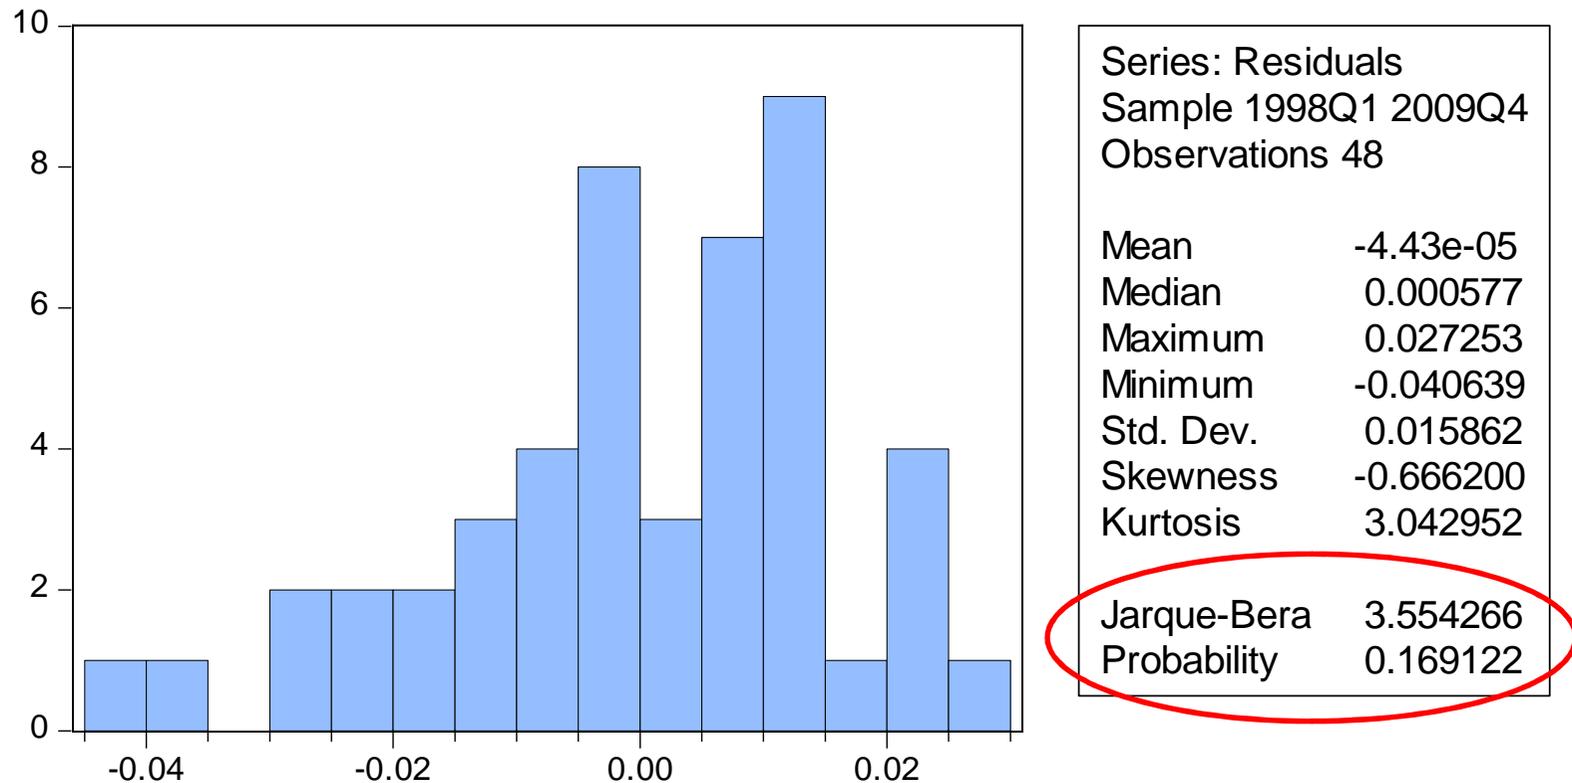
H_0 : Los errores son consistentes con una distribución normal

H_1 : Los errores no son consistentes con una normal.

La estadística de prueba se distribuye, bajo la hipótesis nula, asintóticamente como una distribución $\chi^2(2)$.

El rechazo de la hipótesis nula puede sugerir variables omitidas, no linealidades o errores heteroscedásticos no consideradas en el modelo

Prueba de normalidad de los errores



- La hipótesis nula es rechazada si el estadístico es alto (mayor a 5.99 al 5% \rightarrow Probabilidad < 0.05)

Elección de rezagos para las pruebas

- Las pruebas de autocorrelación y heteroscedasticidad requieren que especifiquemos el número de rezagos, éste dependerá de la frecuencia de las series:
 - Anual: hasta 2 rezagos
 - Trimestral: hasta 4 rezagos
 - Mensual: hasta 12 rezagos

Prueba de autocorrelación de los errores

PRUEBA BREUSCH-GODFREY

H_0 : Los residuales **no** muestran autocorrelación

H_1 : Los errores muestran autocorrelación.

Para muestras pequeñas usar la prueba F

Para muestras grandes usar la prueba χ^2

Prueba de autocorrelación de los errores

- Los grados de libertad dependen del número de rezagos que incluyamos en la prueba y del número de observaciones.
- **Se rechaza la H0 para valores altos, generalmente cuando probabilidad < 0.05**
- La existencia de autocorrelación sugiere una mala especificación dinámica del modelo

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	1.396725	Prob. F(4,40)	0.2526
Obs*R-squared	5.882303	Prob. Chi-Square(4)	0.2081

Test Equation:

Dependent Variable: RESID
Method: Least Squares
Date: 02/18/11 Time: 11:16
Sample: 1998Q1 2009Q4
Included observations: 48
Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.000209	0.005367	-0.038945	0.9691
AR(2)	-0.120418	0.385604	-0.312285	0.7564
AR(4)	0.088414	0.257740	0.343035	0.7334
MA(1)	0.034562	0.121677	0.284047	0.7778
RESID(-1)	0.219863	0.198962	1.105048	0.2757
RESID(-2)	0.198583	0.463982	0.427997	0.6709
RESID(-3)	-0.301968	0.206929	-1.459282	0.1523
RESID(-4)	0.068553	0.326243	0.210130	0.8346

R-squared	0.122548	Mean dependent var	-4.43E-05
Adjusted R-squared	-0.031006	S.D. dependent var	0.015862
S.E. of regression	0.016106	Akaike info criterion	-5.268264
Sum squared resid	0.010376	Schwarz criterion	-4.956397
Log likelihood	134.4383	Hannan-Quinn criter.	-5.150409
F-statistic	0.798077	Durbin-Watson stat	1.997402
Prob(F-statistic)	0.593543		

Prueba de heteroscedasticidad de los errores

PRUEBA ARCH

- H_0 : Los residuales **no** muestran heteroscedasticidad
 - H_1 : Los errores muestran heteroscedasticidad.
-
- Para muestras pequeñas usar la prueba F
 - Para muestras grandes usar la prueba χ^2

Prueba de heteroscedasticidad de los errores

- Si rechazamos la nula debemos modelar la heteroscedasticidad
- **Se rechaza la H0 para valores altos, generalmente cuando probabilidad < 0.05**

Heteroskedasticity Test: ARCH

F-statistic	0.823603	Prob. F(4,39)	0.5181
Obs*R-squared	3.427265	Prob. Chi-Square(4)	0.4890

Test Equation:
Dependent Variable: RESID^2
Method: Least Squares
Date: 02/18/11 Time: 11:25
Sample (adjusted): 1999Q1 2009Q4
Included observations: 44 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000144	7.30E-05	1.976643	0.0552
RESID^2(-1)	0.083136	0.127368	0.652727	0.5178
RESID^2(-2)	0.194865	0.129820	1.501041	0.1414
RESID^2(-3)	-0.000462	0.128295	-0.003600	0.9971
RESID^2(-4)	0.043245	0.152232	0.284076	0.7779

R-squared	0.077892	Mean dependent var	0.000226
Adjusted R-squared	-0.016683	S.D. dependent var	0.000300
S.E. of regression	0.000303	Akaike info criterion	-13.25985
Sum squared resid	3.58E-06	Schwarz criterion	-13.05710
Log likelihood	296.7166	Hannan-Quinn criter.	-13.18466
F-statistic	0.823603	Durbin-Watson stat	1.775231
Prob(F-statistic)	0.518146		

Prueba de especificación de la forma funcional

Prueba RESET

- H_0 : El modelo está bien especificado
 - H_1 : La especificación del modelo es incorrecta
-
- Para muestras pequeñas usar la prueba F
 - Para muestras grandes usar la prueba χ^2

Prueba de especificación de la forma funcional

- Útil para detectar no linealidad en el modelo
- **Se rechaza la H0 para valores altos, generalmente cuando probabilidad < 0.05**

File Edit Object View Proc Quick Options Window Help
View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Ramsey RESET Test:

F-statistic	0.281670	Prob. F(3,16)	0.8379
Log likelihood ratio	1.286645	Prob. Chi-Square(3)	0.7323

Test Equation:
Dependent Variable: DLPG
Method: Least Squares
Date: 02/18/11 Time: 11:43
Sample: 1983 2007
Included observations: 25

Variable	Coefficient	Std. Error	t-Statistic	Prob.
DLPG(-1)	-0.304966	0.240024	-1.270567	0.2220
DLPG(-2)	0.408458	0.165574	2.466926	0.0253
DLY	0.587062	0.240082	2.445261	0.0264
DLPR	-0.144164	0.046846	-3.077399	0.0072
DLPR(-1)	-0.180060	0.126592	-1.422362	0.1741
ECM01(-1)	-0.283874	0.143198	-1.982395	0.0649
FITTED^2	1.763017	4.553049	0.387217	0.7037
FITTED^3	31.77430	52.02752	0.610721	0.5500
FITTED^4	-398.0810	557.8607	-0.713585	0.4858

R-squared	0.919881	Mean dependent var	0.027011
Adjusted R-squared	0.879822	S.D. dependent var	0.052933
S.E. of regression	0.018350	Akaike info criterion	-4.884653
Sum squared resid	0.005388	Schwarz criterion	-4.445858
Log likelihood	70.05817	Hannan-Quinn criter.	-4.762950
Durbin-Watson stat	1.846331		

Pruebas de estabilidad de los parámetros

- Pruebas de Chow
- Análisis recursivos: CUSUM y CUSUMQ

Prueba de estabilidad de los parámetros

PRUEBA DE CHOW

- H_0 : No hay cambio estructural
- H_1 : Hay cambio estructural
- Para muestras pequeñas usar la prueba F
- Para muestras grandes usar la prueba χ^2

Prueba de estabilidad de los parámetros

PRUEBA DE CHOW

- H_0 : No hay cambio estructural
- H_1 : Hay cambio estructural

Un problema es la elección del punto de quiebre

Se rechaza la H_0 para valores altos, generalmente cuando probabilidad < 0.05

File Edit Object View Proc Quick Options Window Help
View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Chow Breakpoint Test: 2000Q1
Null Hypothesis: No breaks at specified breakpoints

Equation Sample: 1998Q1 2009Q4

F-statistic	7.466541	Prob. F(4,40)	0.0001
Log likelihood ratio	26.76970	Prob. Chi-Square(4)	0.0000
Wald Statistic	22.56844	Prob. Chi-Square(4)	0.0002

WARNING: the MA backcasts differ for the original and test equation. Under the null hypothesis, the impact of this difference vanishes asymptotically.

File Edit Object View Proc Quick Options Window Help
View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Chow Forecast Test: Forecast from 2000Q1 to 2009Q4

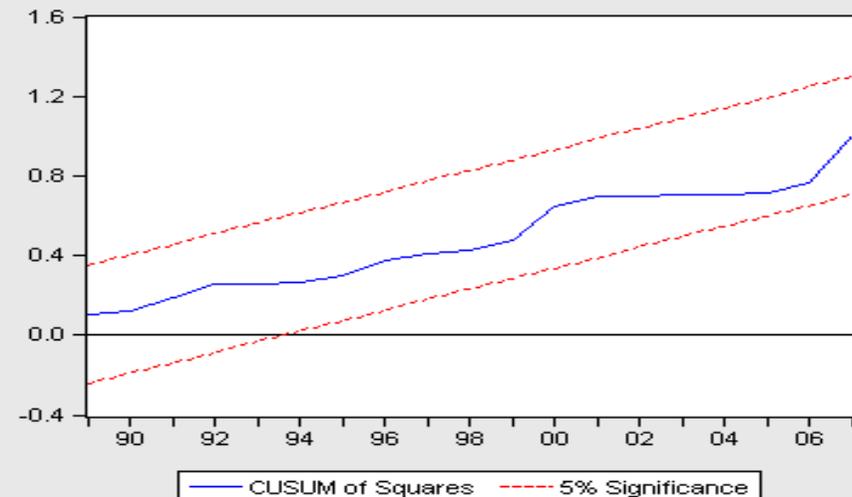
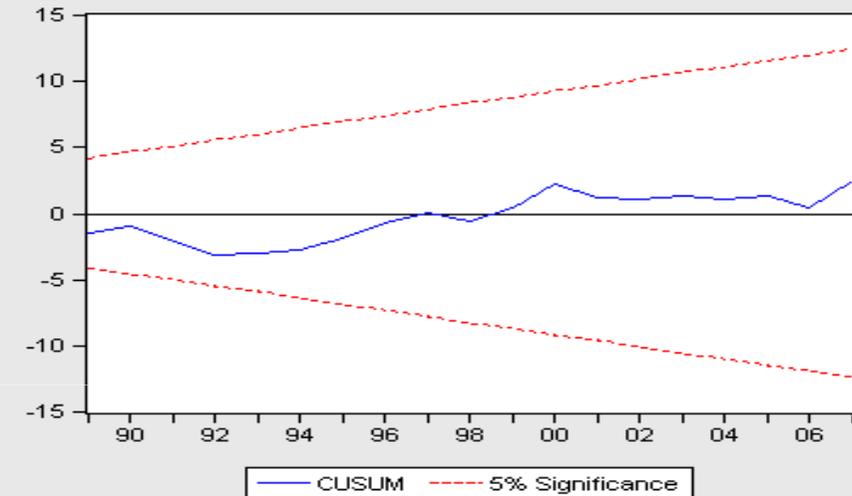
F-statistic	1.679101	Prob. F(40,4)	0.3321
Log likelihood ratio	138.1773	Prob. Chi-Square(40)	0.0000

WARNING: the MA backcasts differ for the original and test equation. Under the null hypothesis, the impact of this difference vanishes asymptotically.

Prueba de estabilidad de los parámetros

PRUEBA CUSUM y CUSUMQ

- H_0 : No hay cambio estructural
- H_1 : Hay cambio estructural



Métodos econométricos

PRUEBAS DE RAÍCES UNITARIAS Y COINTEGRACIÓN

Proceso de elaboración de un modelo: Especificación

Por ejemplo, un modelo de demanda de gasolina:

$$(1) \quad \text{Ln } CG_t = \beta_1 + \beta_2 * \text{Ln } PR_t + \beta_3 * \text{Ln } Y^d_t + u_t$$

$$\beta_2 < 0 \text{ y } \beta_3 > 0$$

Donde,

CG: consumo de gasolina

PR: precios relativos de la gasolina

Y^d : Ingreso personal disponible

Ln: Indica logaritmo natural

u: término de error

Regresores no estacionarios

- Si los regresores son no estacionarios aparecen dos problemas:
 - Las estadísticas t , F o χ^2 tienen distribuciones no estándar → **no podemos hacer inferencia.**
 - Regresión espuria.
- Debemos trabajar con variables estacionarias para poder realizar inferencia.

Regresores no estacionarios

- Si se demuestra que los datos son no estacionarios (prueba de raíz unitaria) podemos eliminar el carácter no estacionario diferenciando las series (trabajar con variables $I(0)$).
- Esto significa una pérdida de información valiosa proveniente de la teoría económica referente a las propiedades de equilibrio de largo plazo

Pruebas de raíces unitarias

Nos interesa el orden de integración de las series
Consideremos el siguiente modelo

$$Y_t = \mu + \phi_1 Y_{t-1} + \beta t + \varepsilon_t$$

Modelo	Conjunto de parámetros	Descripción	Propiedades
1	$\mu \neq 0, \phi_1 < 1, \beta \neq 0$	Estacionario con tendencia determinística	I(0)
2	$\mu \neq 0, \phi_1 = 1, \beta \neq 0$	Random walk con constante y tendencia determinística	I(1)
3	$\mu \neq 0, \phi_1 = 1, \beta = 0$	Random walk con constante	I(1)
4	$\mu \neq 0, \phi_1 = 0, \beta \neq 0$	Tendencia determinística	I(0)
5	$\mu = 0, \phi_1 = 1, \beta = 0$	Random walk puro	I(1)

Prueba de Dickey - Fuller

- Nos interesa saber si $\phi_1 = 1$, es decir, si el modelo presenta raíz unitaria
- Restando Y_{t-1} a ambos lados de la ecuación obtenemos la siguiente especificación:

$$\Delta Y_t = \mu + \gamma Y_{t-1} + \beta t + \varepsilon_t$$

Donde :

$$\Delta Y_t = Y_t - Y_{t-1}$$

$$\gamma = \phi - 1$$

Prueba de Dickey - Fuller

- La hipótesis nula de la prueba es:

$H_0: \gamma = 0$. (la serie tiene una raíz unitaria \rightarrow no estacionaria)

Vs.

$H_1: \gamma < 0$. (la serie **no** tiene una raíz unitaria \rightarrow estacionaria)

Prueba de Dickey – Fuller Aumentada

- Para mejorar las propiedades de la prueba, la reespecificaron de la siguiente manera:

$$\Delta Y_t = \mu + \gamma Y_{t-1} + \beta t + \sum_{i=1}^k \theta_i \Delta Y_{t-i} + \varepsilon_t$$

Donde :

$$\Delta Y_t = Y_t - Y_{t-1}$$

$$\gamma = \phi - 1$$

- La elección del número de rezagos se hace utilizando los criterios de información o mediante el método t-sig

Especificación de la prueba: determinación de la variable determinística

1. Inspección visual de la serie:

- Si muestra tendencia, incluir tendencia en la prueba
- Si fluctúa alrededor de un valor diferente de cero, incluir constante en la prueba
- Si fluctúa alrededor del cero, no incluir ni constante ni tendencia

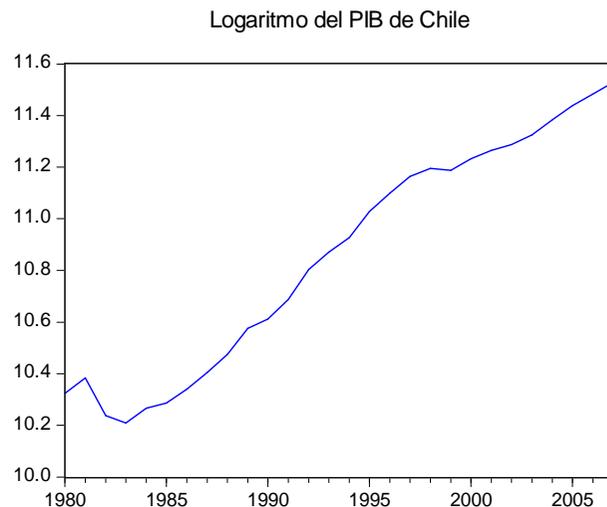
Especificación de la prueba: Criterios de información y método t-sig para la elección de rezagos

Elegir el número de rezagos que minimice los criterios de información.

- Método t-sig:
 1. Comenzar con un número alto de rezagos dependiendo de la frecuencia de la serie
 2. Eliminar iterativamente los rezagos si estos no son significativos al 10%

Ejemplo: PIB de Chile

- Se especifica con constante y tendencia
- No se rechaza la Hipótesis nula (prob > 0.05)



Null Hypothesis: LY has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic based on SIC, MAXLAG=6)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.415503	0.3640
Test critical values:		
1% level	-4.339330	
5% level	-3.587527	
10% level	-3.229230	

*MacKinnon (1996) one-sided p-values

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(LY)
 Method: Least Squares
 Date: 02/21/11 Time: 15:45
 Sample (adjusted): 1981 2007
 Included observations: 27 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
LY(-1)	-0.243769	0.100919	-2.415503	0.0237
C	2.486503	1.017820	2.442969	0.0223
@TREND(1980)	0.014207	0.005512	2.577570	0.0165
R-squared	0.224381	Mean dependent var		0.044621
Adjusted R-squared	0.159746	S.D. dependent var		0.048808
S.E. of regression	0.044740	Akaike info criterion		-3.271437
Sum squared resid	0.048041	Schwarz criterion		-3.127455
Log likelihood	47.16440	Hannan-Quinn criter.		-3.228624
F-statistic	3.471514	Durbin-Watson stat		1.443927
Prob(F-statistic)	0.047400			

Ejemplo: PIB de Chile

- Se especifica con constante
- Se rechaza la Hipótesis nula (prob < 0.05) → La serie es I(1)

Null Hypothesis: D(LY) has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic based on SIC, MAXLAG=6)

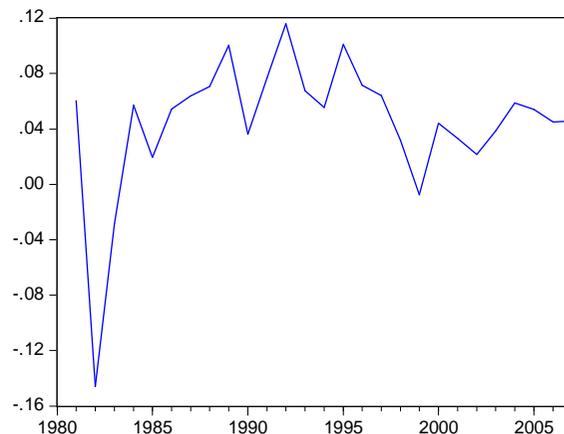
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.601694	0.0129
Test critical values:		
1% level	-3.711457	
5% level	-2.981038	
10% level	-2.629906	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(LY,2)
 Method: Least Squares
 Date: 02/21/11 Time: 15:46
 Sample (adjusted): 1982 2007
 Included observations: 26 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(LY(-1))	-0.699679	0.194264	-3.601694	0.0014
C	0.030631	0.012841	2.385419	0.0253
R-squared	0.350864	Mean dependent var		-0.000559
Adjusted R-squared	0.323816	S.D. dependent var		0.058795
S.E. of regression	0.048347	Akaike info criterion		-3.147021
Sum squared resid	0.056098	Schwarz criterion		-3.050245
Log likelihood	42.91128	Hannan-Quinn criter.		-3.119153
F-statistic	12.97220	Durbin-Watson stat		1.187533
Prob(F-statistic)	0.001432			

Primera diferencia del logaritmo del PIB



Cointegración

- La teoría económica identifica relaciones de equilibrio de largo plazo entre variables económicas, las que si no se satisfacen echarán a andar fuerzas económicas para retornar al equilibrio.
- Una variable no estacionaria fluctúa extensamente, pero algunos pares de variables no estacionarias pueden fluctuar en forma que no se separen mucho o que fluctúen de manera conjunta → Aunque sean $I(1)$ una combinación lineal particular de ellas es $I(0)$. Dicha combinación se interpreta como una relación de equilibrio.

Cointegración

- Sea $y_t \sim I(1)$ y $x_t \sim I(1)$ si existe b tal que

$$y_t - b x_t \sim I(0)$$

Se dice que y_t y x_t están cointegradas.

Es posible demostrar que si existe una relación de equilibrio de largo plazo es posible representarla como un modelo de corrección de errores y viceversa (Teorema de representación de Granger, 1986).

Modelo de corrección de errores: Introducción

El modelo de corrección de errores se especifica de la siguiente manera:

$$\Delta y_t = \beta_0 + \sum_{i=0}^k \beta_i \Delta x_{t-i} + \sum_{i=1}^k \delta_i \Delta y_{t-i} + \alpha (y_{t-1} - \beta x_{t-1}) + \epsilon_t$$

Las variables involucradas son todas $I(0)$. El último término es el término de corrección del error, se interpreta como un reflejo de las respuestas al desequilibrio. El parámetro α ***debe ser siempre significativo y negativo.***

Modelo de corrección de errores: Método de especificación – de lo general a lo específico

1. Comenzar con un número alto de rezagos dependiendo de la frecuencia de la serie
2. Eliminar progresivamente las variables no significativas, considerando los menos significativos.
3. Realizar pruebas de diagnóstico del modelo final

Modelo de corrección de errores: Método de Engle y Granger

1. Determinar el orden de integración de las series (pruebas de raíces unitarias)
2. Correr la regresión de cointegración sugerida por la teoría económica
3. Aplicar prueba de raíces unitarias al residuo de la regresión en (2) para verificar la cointegración
4. Si se acepta la cointegración estimar el modelos de corrección de errores

Modelo de corrección de errores: Método de Johansen

1. Determinar el orden de integración de las series (pruebas de raíces unitarias)
2. Verificar la cointegración utilizando el procedimiento de Johansen
3. Si se acepta la cointegración, obtener el vector de cointegración
4. Estimar el modelo de corrección de errores o el vector de corrección de errores

Ejemplo: Demanda de gasolina

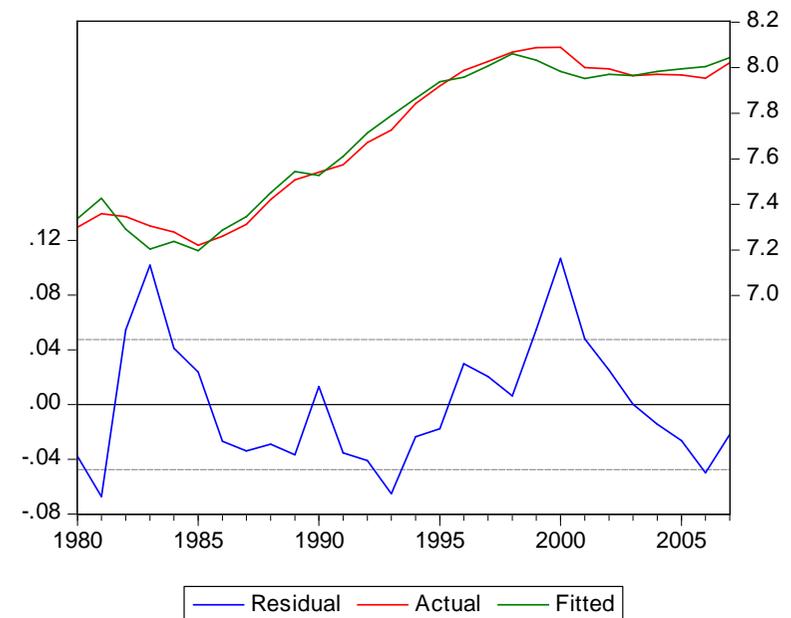
- Estimación de la relación de largo plazo

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: LCG
Method: Least Squares
Date: 02/16/11 Time: 15:50
Sample (adjusted): 1980 2007
Included observations: 28 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.508139	0.266064	5.668322	0.0000
LY	0.762868	0.022564	33.80937	0.0000
LPR	-0.345047	0.040696	-8.478697	0.0000

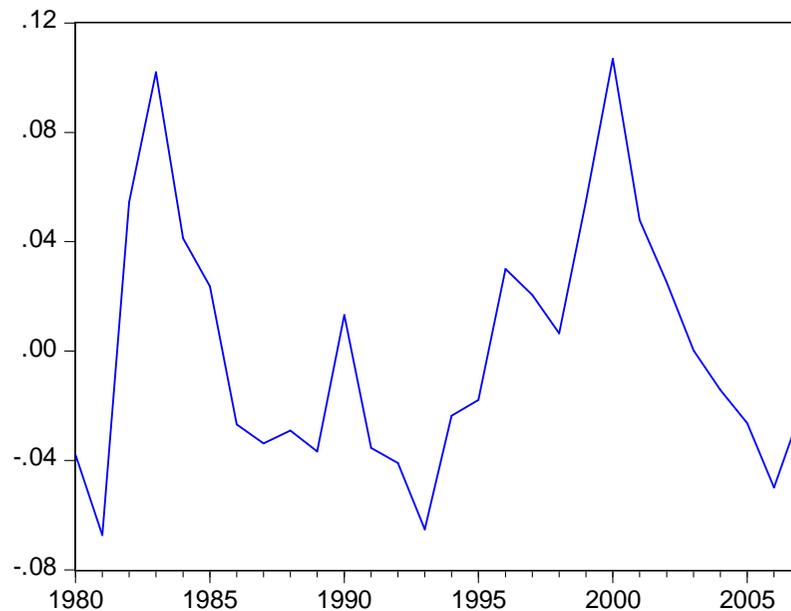
R-squared	0.979248	Mean dependent var	7.704204
Adjusted R-squared	0.977588	S.D. dependent var	0.317447
S.E. of regression	0.047524	Akaike info criterion	-3.154219
Sum squared resid	0.056463	Schwarz criterion	-3.011483
Log likelihood	47.15906	Hannan-Quinn criter.	-3.110583
F-statistic	589.8603	Durbin-Watson stat	0.811252
Prob(F-statistic)	0.000000		



Ejemplo: Demanda de gasolina

- Prueba de cointegración

ECM01



Null Hypothesis: ECM01 has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic based on SIC, MAXLAG=6)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.653900	0.0100
Test critical values:		
1% level	-2.653401	
5% level	-1.953858	
10% level	-1.609571	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(ECM01)
 Method: Least Squares
 Date: 02/21/11 Time: 16:21
 Sample (adjusted): 1981 2007
 Included observations: 27 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
ECM01(-1)	-0.417600	0.157353	-2.653900	0.0134
R-squared	0.212988	Mean dependent var		0.000593
Adjusted R-squared	0.212988	S.D. dependent var		0.041969
S.E. of regression	0.037232	Akaike info criterion		-3.706958
Sum squared resid	0.036042	Schwarz criterion		-3.658964
Log likelihood	51.04394	Hannan-Quinn criter.		-3.692687
Durbin-Watson stat	1.697258			

Ejemplo: Demanda de gasolina – Modelo final

- Formulación general del MCE

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: DLCG									
Method: Least Squares									
Date: 02/16/11 Time: 15:54									
Sample (adjusted): 1983 2007									
Included observations: 25 after adjustments									
Variable	Coefficient	Std. Error	t-Statistic	Prob.					
DLCG(-1)	-0.333811	0.149703	-2.229816	0.0380					
DLCG(-2)	0.442106	0.096682	4.572771	0.0002					
DLY	0.654548	0.091063	7.187852	0.0000					
DLPR	-0.155253	0.038085	-4.076428	0.0006					
DLPR(-1)	-0.208808	0.068067	-3.067679	0.0063					
ECM01(-1)	-0.302462	0.126204	-2.396600	0.0270					
R-squared	0.915650	Mean dependent var	0.027011						
Adjusted R-squared	0.893453	S.D. dependent var	0.052933						
S.E. of regression	0.017278	Akaike info criterion	-5.073188						
Sum squared resid	0.005672	Schwarz criterion	-4.780657						
Log likelihood	69.41485	Hannan-Quinn criter.	-4.992052						
Durbin-Watson stat	1.911257								

Métodos y técnicas del análisis del cambio climático

joseeduardo.alatorre@cepal.org

orlando.reyes@cepal.org

División de Desarrollo Sostenible y Asentamientos Humanos
CEPAL

Febrero 2011