

# Taller de Política Comercial, Cadenas de Valor e Indicadores Sociales

Daniel Cracau, Oficial de Asuntos Económicos

José Durán Lima, Oficial de Asuntos Económicos

Alfonso Finot, Consultor

Bogotá, 16 y 19 de Mayo de 2017



CEPAL



# Modulo 2

## *“Evidence-based policymaking: métodos cuantitativos para el análisis de los efectos de los PTA”*



# Modulo 2: “Evidence-based policymaking: métodos cuantitativos para el análisis de los efectos de los PTA”

1. Bases de datos necesarios para la aplicación de métodos cuantitativos.
2. Introducción sobre indicadores básicos de comercio y de política comercial.
3. Ejercicios aplicados para el caso de Colombia (trabajo en grupos).
4. Modelos de Gravedad el análisis del comercio internacional.
5. **Modelos de Series temporales y Equilibrio parcial.**
6. Modelo de Equilibrio General y Micro simulaciones .
7. Ejercicios aplicados para el caso de Colombia.
8. Métodos de evaluación ex post.



# Modulo 2.5:

## Modelos de Series temporales y Equilibrio parcial.

# Series de tiempo

- Cuando trabajamos con series de tiempo, a diferencia de la modelación de corte transversal en que teníamos varias variables, aquí tendremos una serie y su historia a lo largo del tiempo
  - $y_t$  y su periodicidad (la historia de la serie)
  - Es justamente eso lo que vamos a modelar
  - La periodicidad de la serie que puede ser de 2 tipos: regular o irregular
  - Regular, cuando los sucesos se producen en forma continua: ventas, producción, cotizaciones, precios,...
  - Irregular, cuando se producen de tanto en tanto (lluvias, terremotos, erupciones volcánicas, etc.)

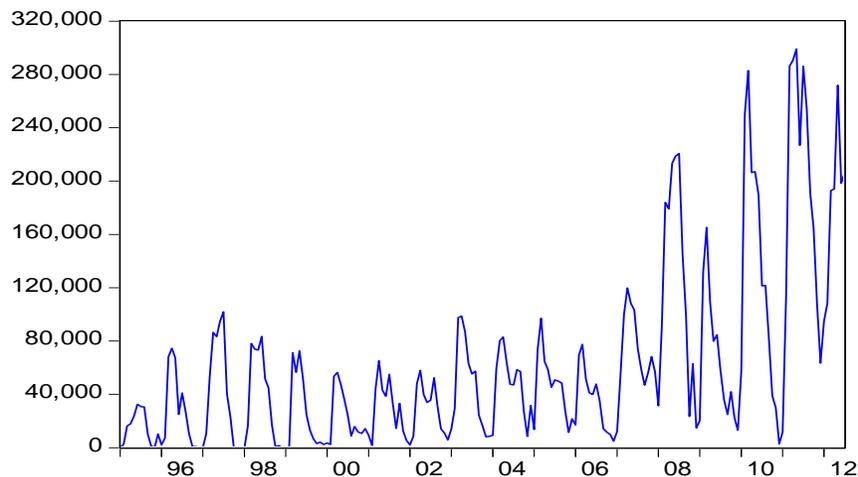
# Series de tiempo

- Definimos una serie temporal al conjunto de datos que corresponden a un fenómeno económico ordenados en el tiempo
  - días, meses, trimestres
  - tenemos una única variable ( $y_t$ )
- En el análisis de regresión teníamos dos variables, y explicábamos una variable en función de la otra. Ahora tenemos una única variable, y la explicamos en función de su pasado histórico.
  - $$Y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-n})$$

# Componentes de una serie temporal

- Las series temporales suelen tener cuatro componentes:
  - T = Tendencia
  - E = Componente estacional
  - C = Componente cíclica
  - I = Componente irregular

**Exportaciones de soja de Paraguay, 1995 - 2012**



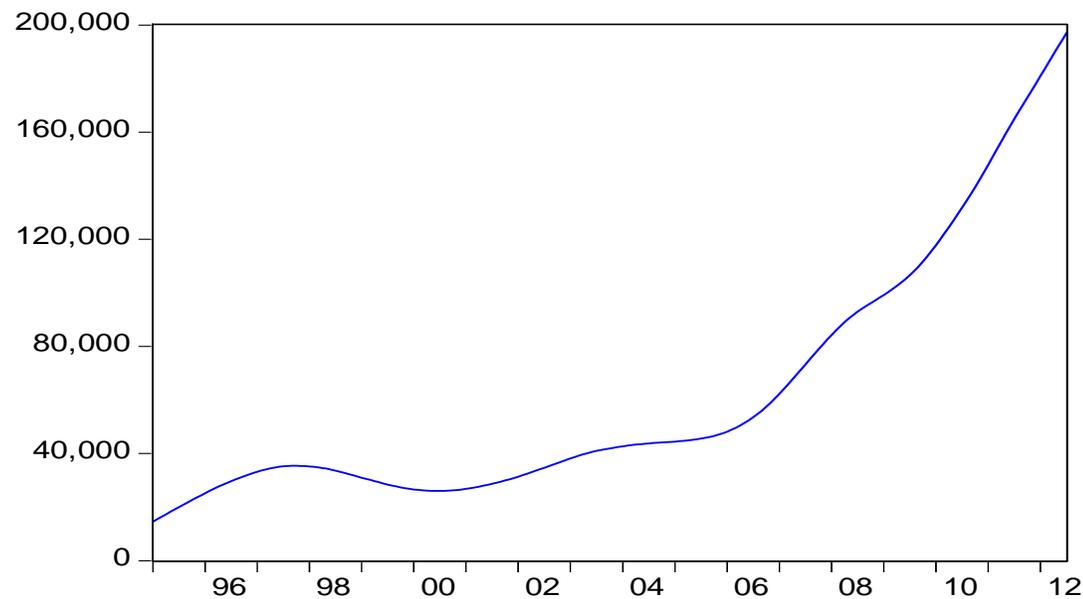
En el gráfico tenemos las exportaciones mensuales de soja del Paraguay desde enero de 1995 hasta junio de 2012.

Vamos a utilizar esta serie para analizar los componentes de una serie de tiempo.

# Tendencia

- La tendencia de una serie de tiempo es la componente a largo plazo que representa el crecimiento o disminución de la serie durante un período largo.
- El punto inicial y el punto final de una serie particular determina la tendencia.

TENDENCIA EXPORTACIONES DE SOJA, ENERO 1995 a JUNIO 2012

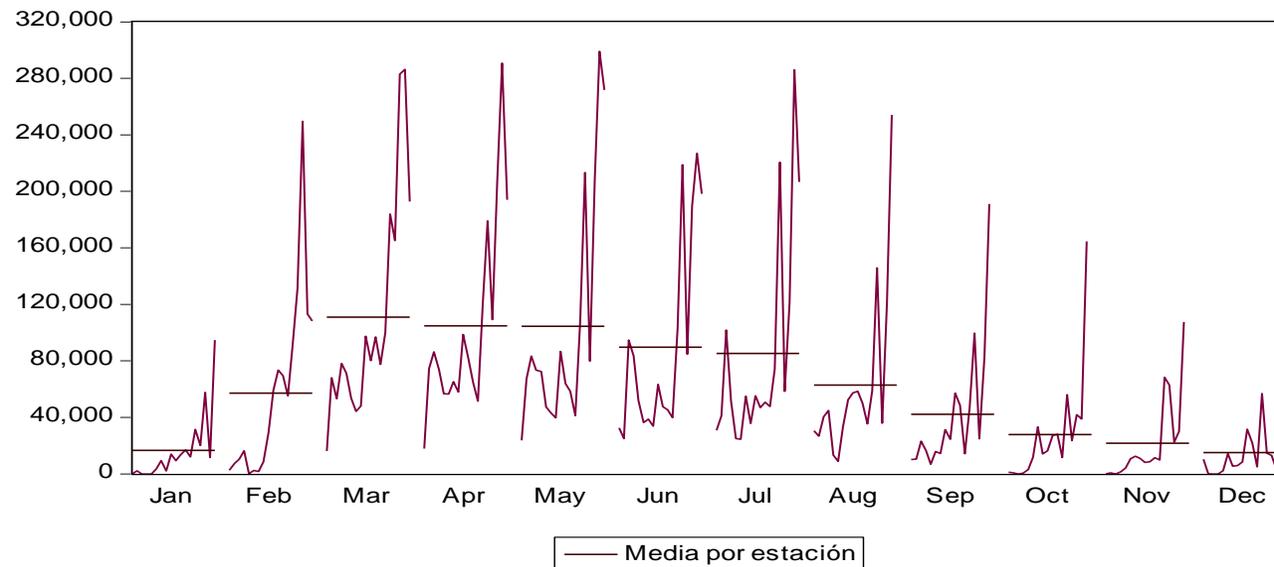


Las fuerzas básicas responsables de la tendencia de una serie económica son: población, crecimiento, inflación de precios, cambios tecnológicos e incrementos de la productividad.

# Componente estacional

- Son fluctuaciones en períodos relativamente cortos que se repiten de manera casi irregular. Por lo general están asociados a los diferentes meses del año. La utilizaron los meteorólogos (utilizaron el seno y el coseno)
- El estudio de la variación estacional permite encontrar índices mediante las cuales se puede desestacionalizar la serie.

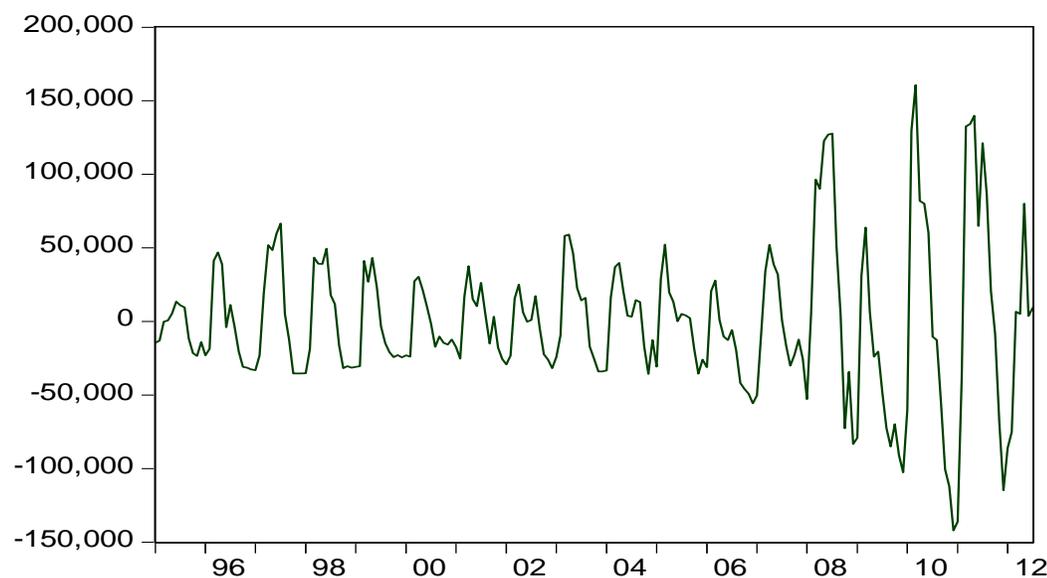
Soja, componente estacional, 1995 -2012



# Componente Cíclica

- Son llamados también ciclos económicos y muestran las variaciones en períodos de mediano plazo.
- se requiere información de por lo menos 15 a 20 años.
- descartado por ciertos autores => asimilado por el componente de tendencia.

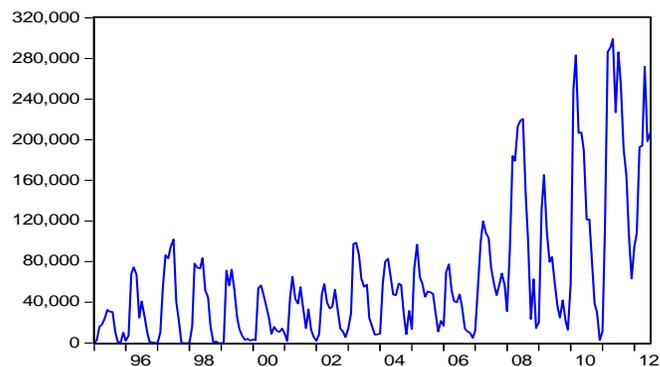
**Componente Cíclico serie de Soja, 1995-2012**



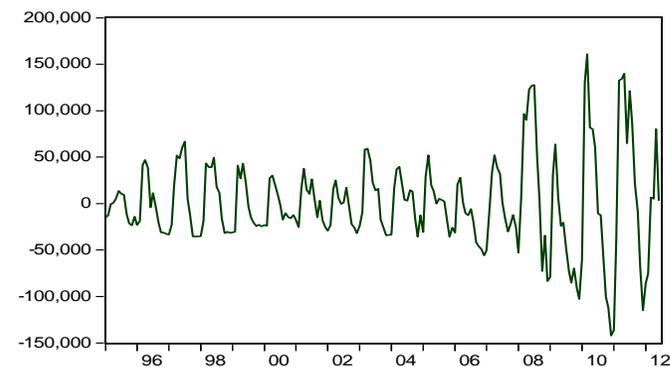
# Componente irregular

- Son variaciones aleatorias que ocurren por acontecimientos inesperados y que no estoy considerando en lo otros componentes, por ejemplo: terremotos, inundaciones, huelgas, imprevistos, corte de energía eléctrica, etc. (el ruido de la serie)

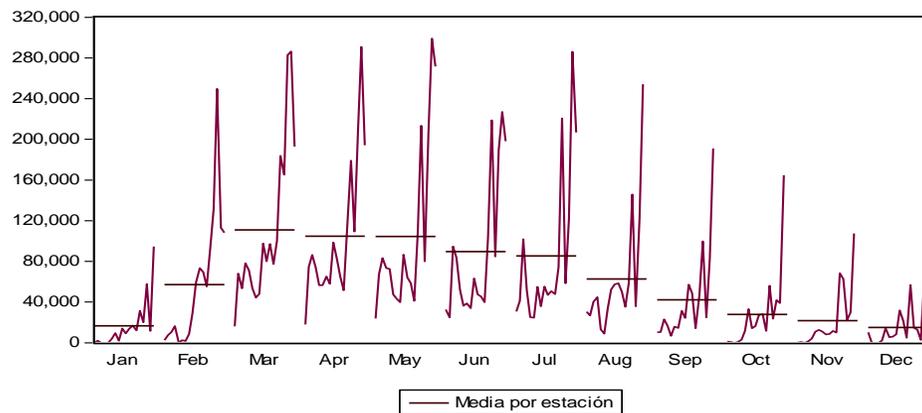
**Exportaciones de soja de Paraguay, 1995 - 2012**



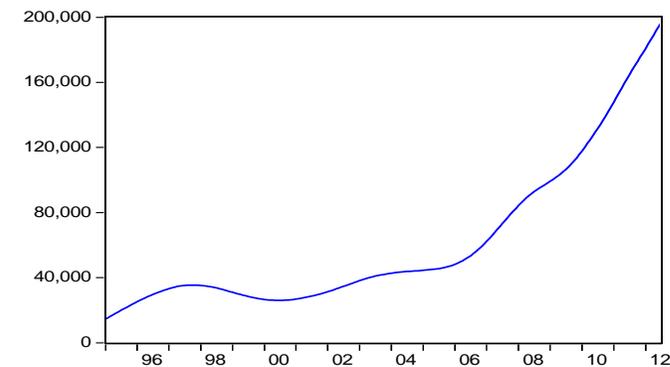
**Componente Cíclico serie de Soja, 1995-2012**



**Soja, componente estacional, 1995 -2012**

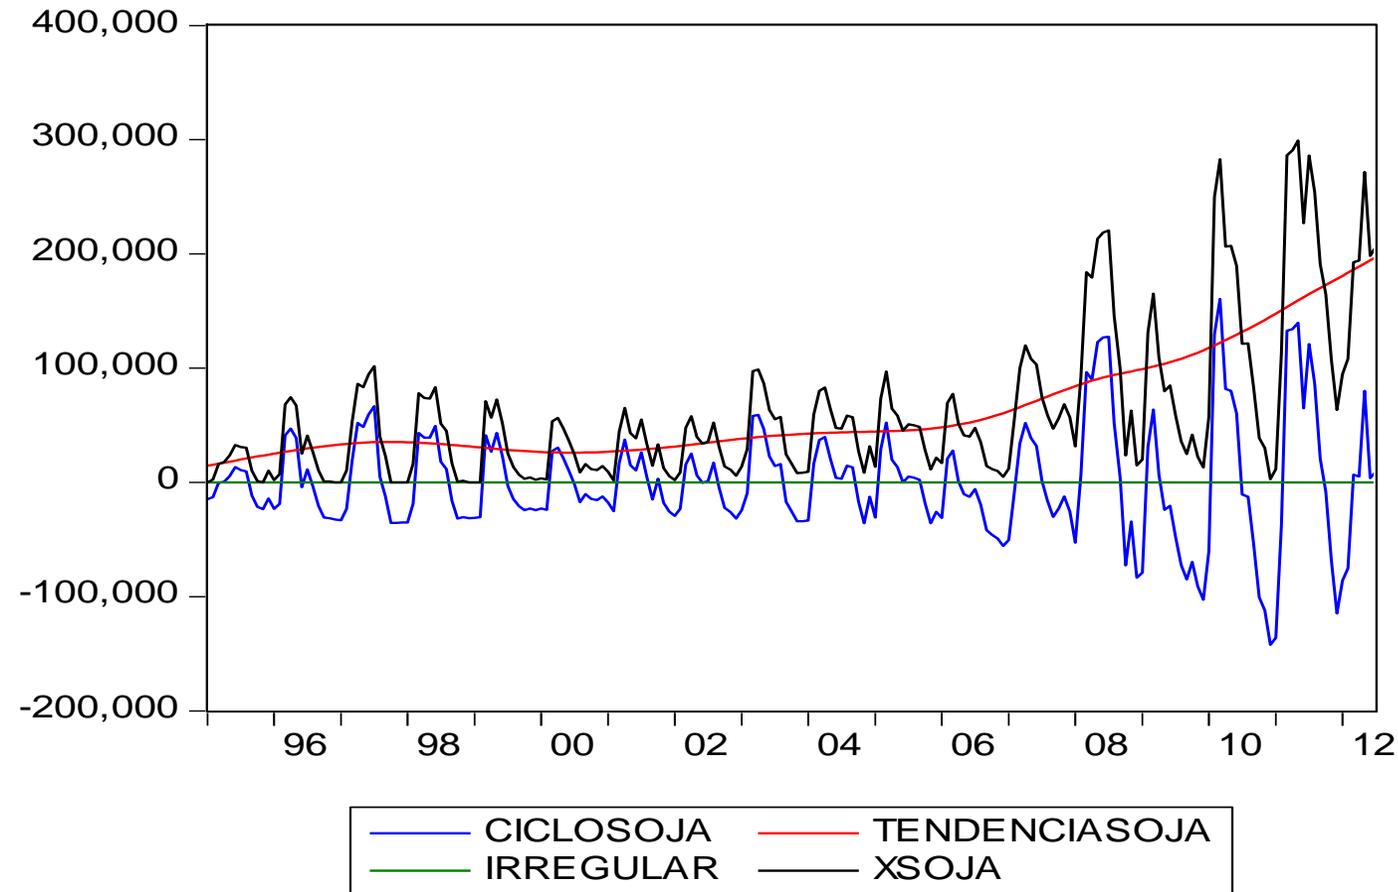


**TENDENCIA EXPORTACIONES DE SOJA, ENERO 1995 a JUNIO 2012**



# Todos los componentes de una serie temporal

- Exportaciones de soja, tendencia y ciclo, 1995-2012



# MODELOS ARIMA (1)

- Autoregressive Integrate Moving Average
- Componente Autorregresiva

$$y_t = \beta_0 + \beta_1 y_{t-1} + \varepsilon_t \quad \text{AR}(1)$$

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \varepsilon_t \quad \text{AR}(2)$$

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_n y_{t-n} + \varepsilon_t \quad \text{AR}(p)$$

- ¿Cuánto del pasado influye en el presente? AR(1) es el componente autorregresivo de orden 1 que me indica que la realización de un evento de la serie en el mes pasado me afecta hoy. AR(2), dos meses anteriores, y AR(p) significa que p períodos todavía afectan a la variable de hoy.

# MODELOS ARIMA (2)

- Autoregressive Integrate Moving Average
- Componente Media Móvil

$$y_t = \phi_0 + \phi_1 \varepsilon_{t-1} + \varepsilon_t \quad \text{MA(1)}$$

$$y_t = \phi_0 + \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \varepsilon_t \quad \text{MA(2)}$$

$$y_t = \phi_0 + \phi_1 \varepsilon_{t-1} + \phi_1 \varepsilon_{t-2} + \dots + \phi_n \varepsilon_{t-n} + \varepsilon_t \quad \text{MA(q)}$$

- ¿Cuánto del ruido del pasado afecta a mi variable? MA(1) es el componente exógeno de orden 1 que me afecta a mi variable. El ruido del mes anterior me afecta el comportamiento de mi variable el mes actual. MA(2), dos meses anteriores, y MA(q) significa que q períodos todavía afectan a la variable de hoy.

# MODELOS ARIMA (3)

- Podemos tener los dos componentes juntos

- ARMA(1,1)

$$y_t = \beta_0 + \beta_1 y_{t-1} + \phi_1 \varepsilon_{t-1} + \varepsilon_t \quad \text{ARMA(1,1)}$$

- ARMA(q,q)

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_n y_{t-n} + \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \dots + \phi_n \varepsilon_{t-n} + \varepsilon_t \quad \text{ARMA(q,q)}$$

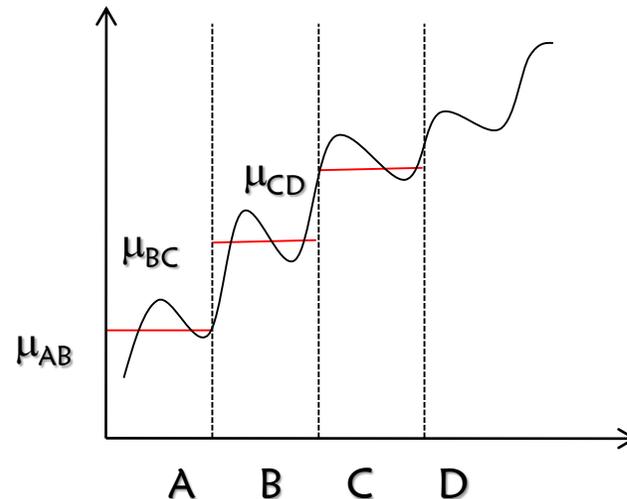
- SUPUESTOS QUE DEBEN CUMPLIRSE

- Que la serie sea estacionaria. Esto es que la media sea estable y que no dependa del tiempo
  - $E(y_t) = \mu$
- Que la varianza sea homocedástica
  - $\text{Var}(y_t) = \sigma^2$
- Que la covarianza de la variable de hoy con su pasado sea igual a una constante
  - $\text{Cov}(y_t, y_{t-1}) = \lambda$

# MODELOS ARIMA (4)

## • SUPUESTOS QUE DEBEN CUMPLIRSE

- Que la serie sea estacionaria. Esto es que la media sea estable y que no dependa del tiempo
  - $E(y_t) = \mu$



Ejemplo de serie  
no estacionaria

- Si la serie no es estacionaria hay que transformarla para que sea estacionaria.
- Un primer paso es tomar el logaritmo natural de la serie y verificar si es estacionaria
- Un segundo paso es diferenciar una vez, y si no es estacionaria se recomienda una segunda diferenciación, pero NO MÁS DE 2.

# MODELOS ARIMA (5)

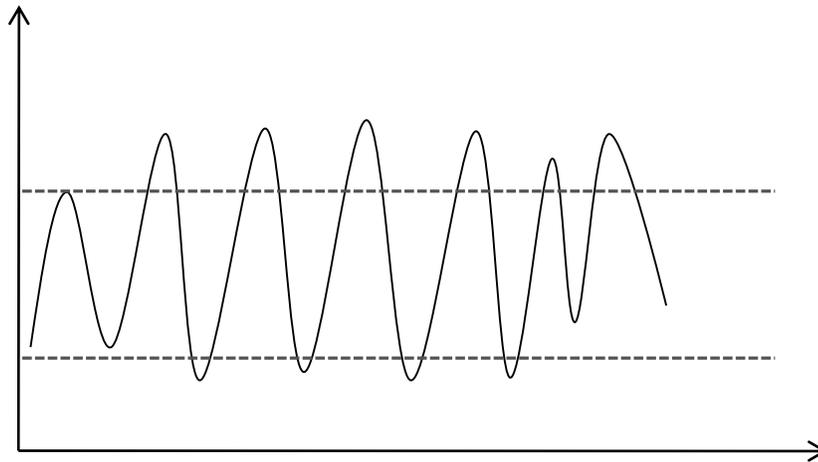
- SUPUESTOS QUE DEBEN CUMPLIRSE

- Que la varianza sea homocedástica

- $\text{Var}(y_t) = \sigma^2$

- Que la covarianza de la variable de hoy con su pasado sea igual a una constante

- $\text{Cov}(y_t, y_{t-1}) = \lambda$



Si se sale del túnel  
no es constante

# MODELOS ARIMA (6)

- ¿Cómo se que la serie es estacionaria?:
  - Puedo responder de 3 formas esta pregunta
    - Realizando una gráfica de la series
    - Analizando los correlogramas
  - Si la serie no es estacionaria tengo 2 caminos para corregirla
    - El camino de la varianza;
    - El camino de la media.
    - Se recomienda comenzar por la varianza, esto es tomar el logaritmo de la serie.
    - Si sigue siendo estacionaria calculo la diferencia del logaritmo (el camino de la media)

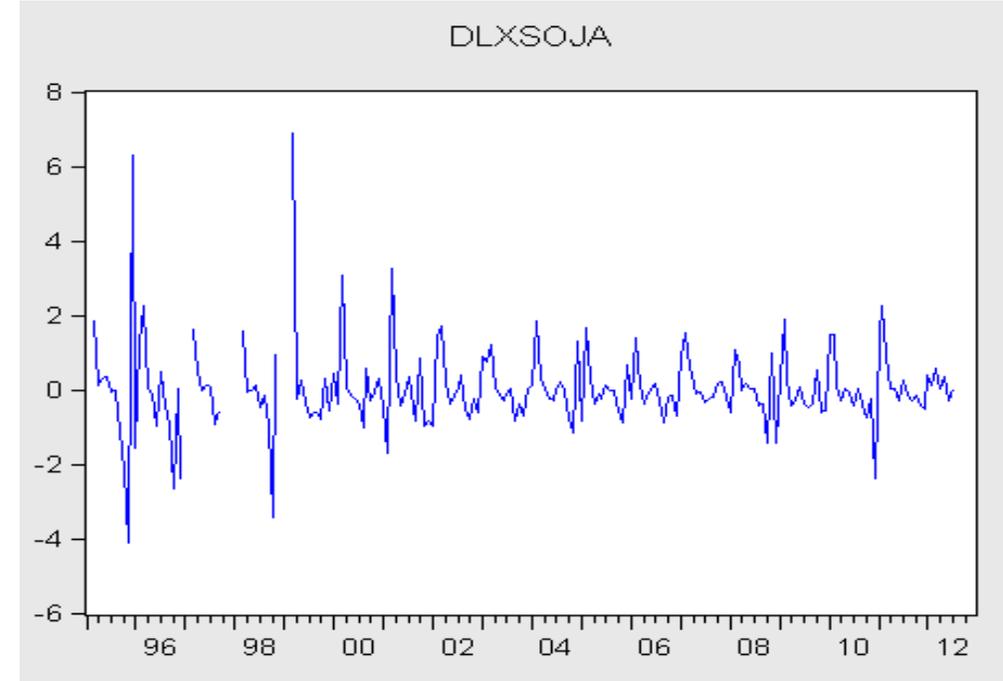
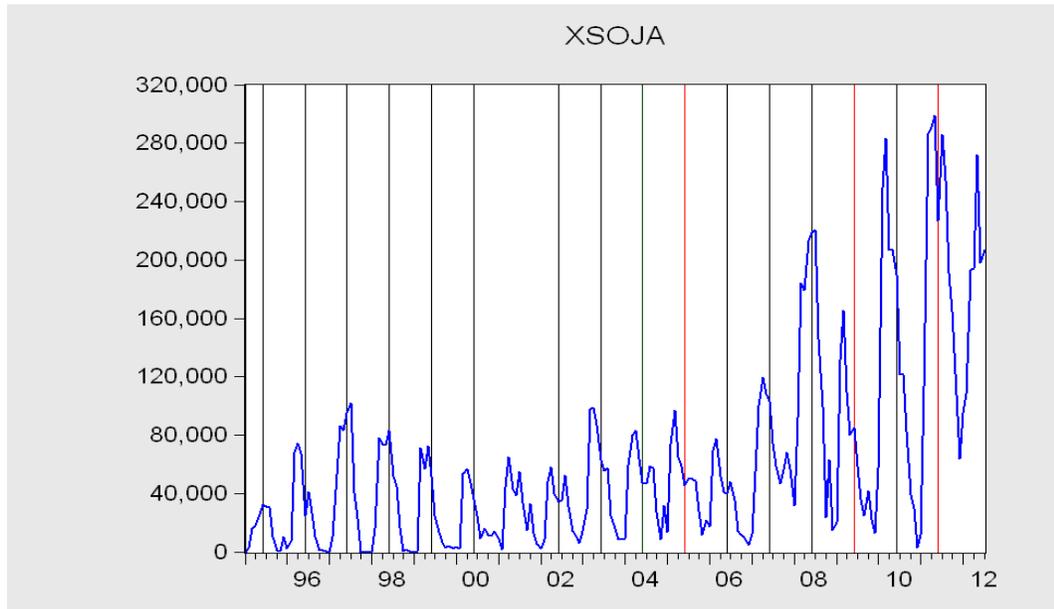
# MODELACIÓN CON ARIMA (7)

- Box-Jenkins indican 4 pasos
  - 1.- Identificación
    - Verificar que la serie sea estacionaria
      - Si es directa  $I(0)$ ,
      - Si se diferencia una vez  $I(1)$
      - Si se diferencia 2 veces  $I(2)$
  - 2.- Determino los rezagos. -Si la serie es estacionaria
    - Vemos  $p$  y  $q$  analizando los correlogramas
  - 3.- Estimación.- Estimamos el modelo con MCO (Optimización no lineal).
    - Corremos la regresión y sacamos los valores de  $p$  y  $q$  no significativos hasta tener el mejor modelo (PARSIMONIA)
    - Verifico los supuestos  $E(\mu)=0$ ;  $\text{Var } \varepsilon = \sigma^2$  ; Homocedasticidad
  - 4.- Pronóstico. Es este el objetivo principal de la modelación.

# MODELACIÓN CON ARIMA (8)

- Comparemos las series obtenidas

La serie ahora sí es estacionaria



# MODELACIÓN CON ARIMA (9)

- Verifico los rezagos para proceder a correr mi regresión ARIMA

Correlación parcial = AR

Autocorrelación = MA

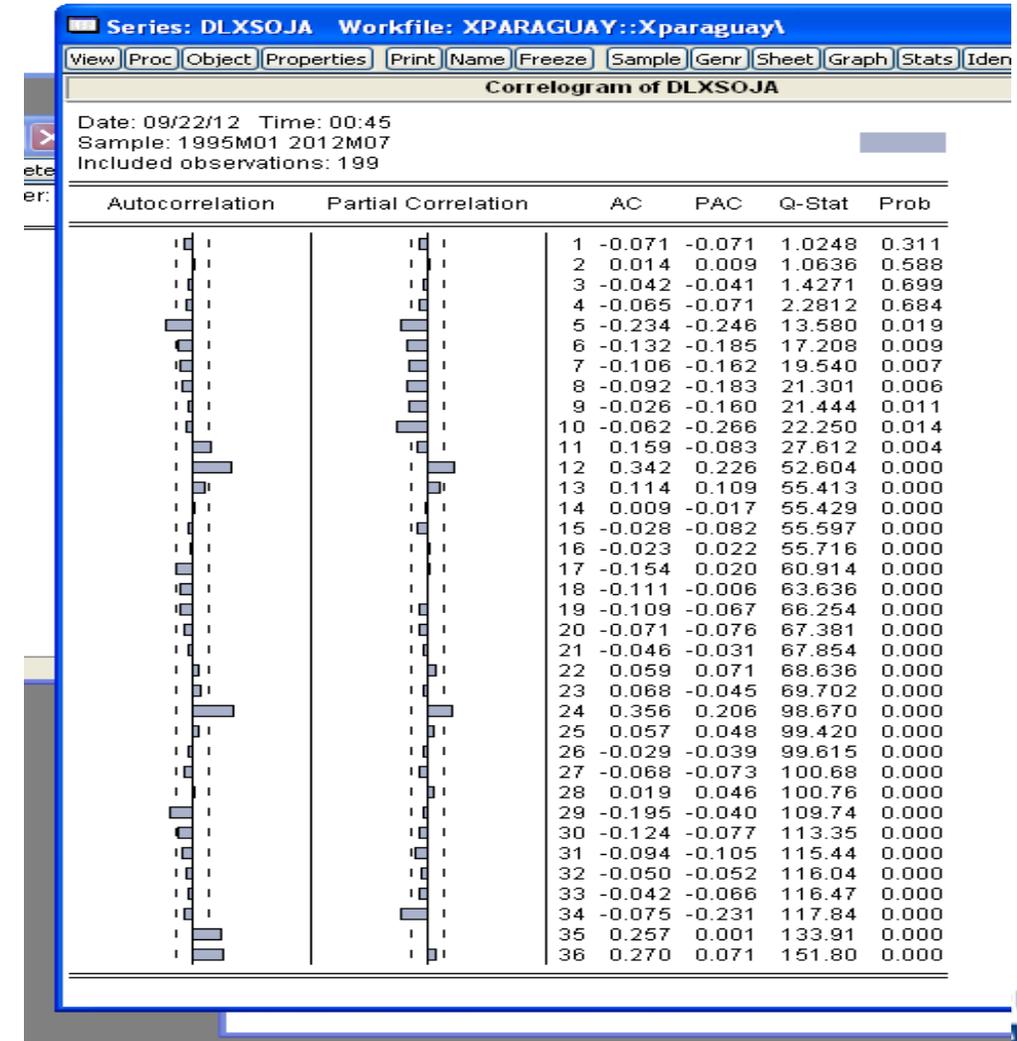
AR = (5, 10, 12, 24, 34)

MA =(5, 11, 12, 17, 24, 29, 35, 36)

Ahora procedo a correr el modelo con Eviews

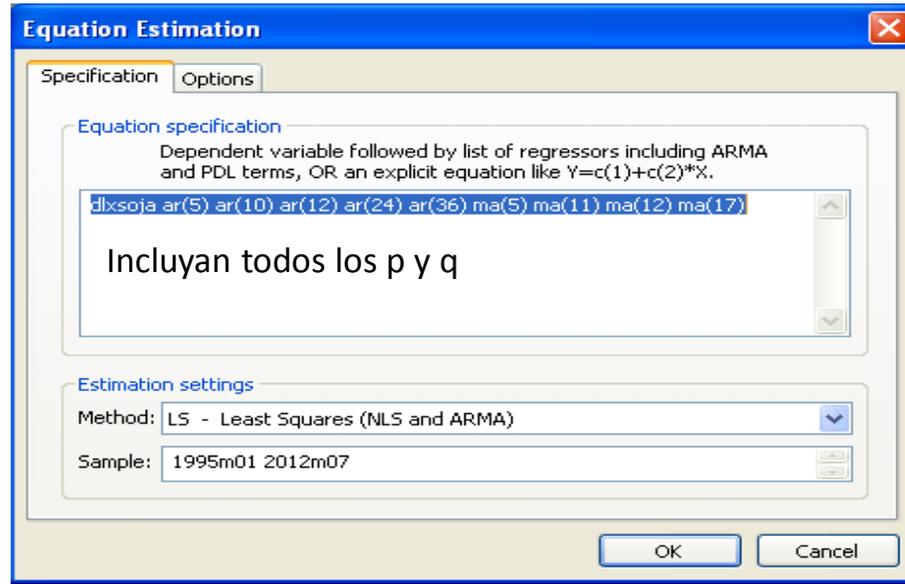
equation modelo1

modelo1.ls dlxsoja c ar(5) ar(10) ar(12) ar(24) ar(34) ma(5) ma(11) ma(12) ma(17) ma(24) ma(29) ma(35) ma(36)



# MODELACIÓN CON ARIMA (10)

- Estimamos el modelo



Retiramos los coeficientes que no son significativos, comenzando por los que tienen una probabilidad más alta.

Equation: MODELO1 Workfile: XPARAGUAY::Xparaguay

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: DLXSOJA  
Method: Least Squares  
Date: 09/22/12 Time: 14:24  
Sample (adjusted): 2002M01 2012M07  
Included observations: 127 after adjustments  
Failure to improve SSR after 8 iterations  
MA Backcast: 1999M01 2001M12

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.042934	0.102593	0.418490	0.6764
AR(5)	-0.094501	0.125062	-0.755629	0.4514
AR(10)	-0.077629	0.094219	-0.823925	0.4117
AR(12)	0.135840	0.107569	1.262817	0.2093
AR(24)	0.175900	0.093101	1.889351	0.0614
AR(34)	-0.066203	0.077263	-0.856850	0.3933
MA(5)	0.084803	0.119691	0.708512	0.4801
MA(11)	0.081237	0.093353	0.870209	0.3860
MA(12)	0.158457	0.105014	1.508920	0.1341
MA(17)	0.028868	0.100665	0.286770	0.7748
MA(24)	0.094144	0.098986	0.951083	0.3436
MA(29)	-0.158313	0.080841	-1.958340	0.0527
MA(35)	0.418255	0.081486	5.132820	0.0000
MA(36)	0.352873	0.080338	4.392323	0.0000

R-squared	0.481897	Mean dependent var	0.028740
Adjusted R-squared	0.422292	S.D. dependent var	0.720803
S.E. of regression	0.547861	Akaike info criterion	1.738084

AR = (5, ~~10~~, 12, 24, 34)

MA = (~~5~~, ~~11~~, ~~12~~, ~~17~~, 24, 29, 35, 36)

# MODELACIÓN CON ARIMA (11)

- Sigo haciendo pruebas y quitando lo que no es significativo

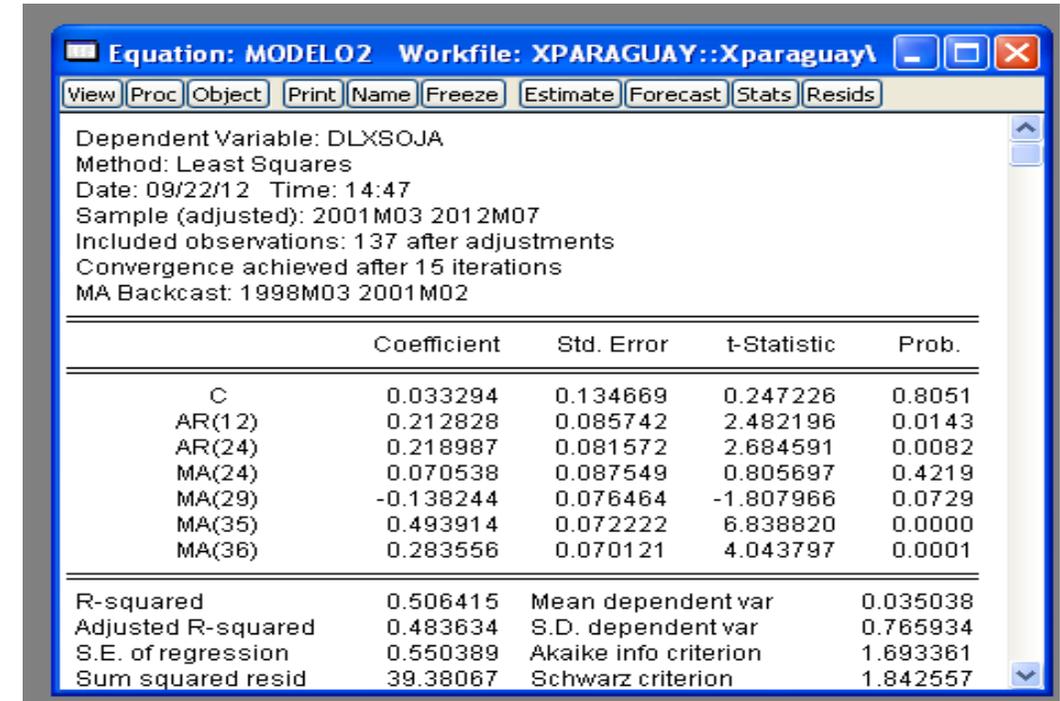
Hago un nuevo modelo con lo que me sirve

equation modelo2

```
modelo2.ls dlxsoja c ar(12) ar(24) ma(24) ma(29) ma(35) ma(36)
```

MA 24 Y MA 29 también se quitan, y la constante

```
Dlxsoja ar(12) ar(24) ma(35) ma(36)
```



Equation: MODELO2    Workfile: XPARAGUAY::Xparaguay

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: DLXSOJA  
Method: Least Squares  
Date: 09/22/12 Time: 14:47  
Sample (adjusted): 2001M03 2012M07  
Included observations: 137 after adjustments  
Convergence achieved after 15 iterations  
MA Backcast: 1998M03 2001M02

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.033294	0.134669	0.247226	0.8051
AR(12)	0.212828	0.085742	2.482196	0.0143
AR(24)	0.218987	0.081572	2.684591	0.0082
MA(24)	0.070538	0.087549	0.805697	0.4219
MA(29)	-0.138244	0.076464	-1.807966	0.0729
MA(35)	0.493914	0.072222	6.838820	0.0000
MA(36)	0.283556	0.070121	4.043797	0.0001

R-squared	0.506415	Mean dependent var	0.035038
Adjusted R-squared	0.483634	S.D. dependent var	0.765934
S.E. of regression	0.550389	Akaike info criterion	1.693361
Sum squared resid	39.38067	Schwarz criterion	1.842557

# MODELACIÓN CON ARIMA (12)

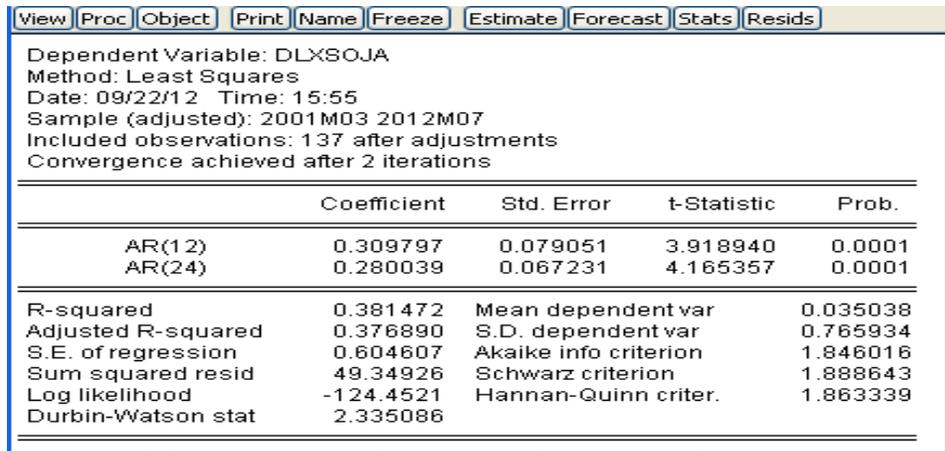
- Sigio haciendo pruebas y quitando lo que no es significativo

Hago un nuevo modelo con lo que me sirve

equation modelo3

modelo3.ls dlxsoja c ar(12) ar(24)

Corremos esta regresión y volvemos a revisar los correlogramas para ver si hay algo que agregar



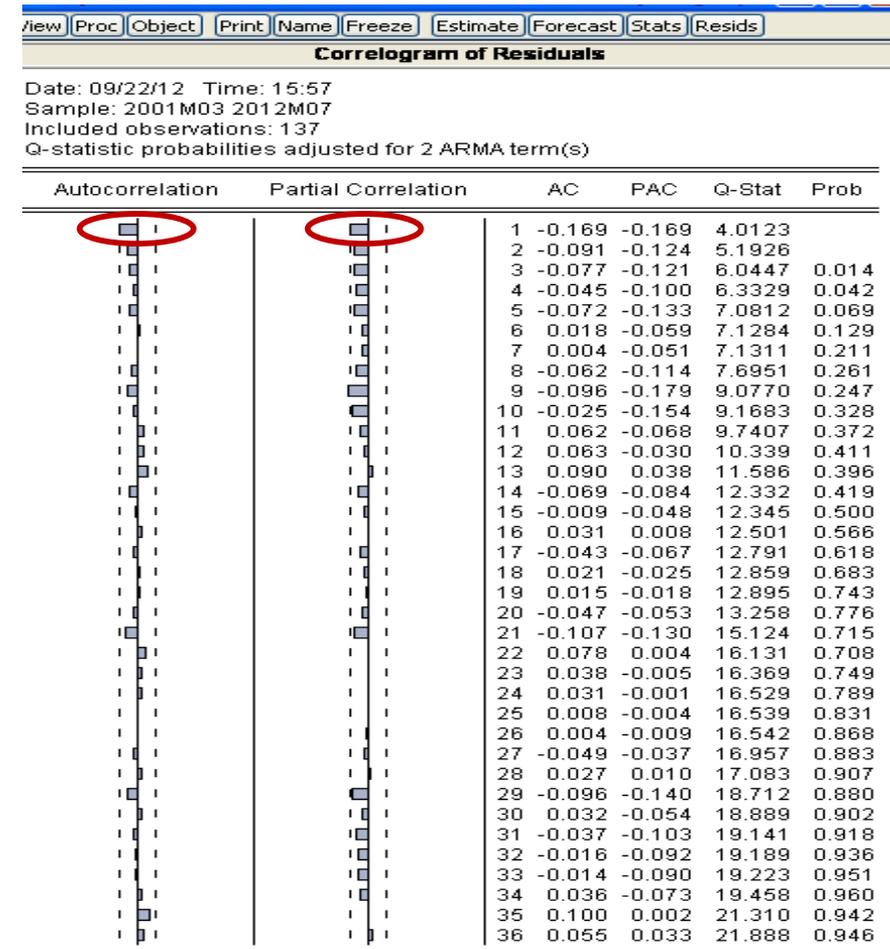
View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: DLXSOJA  
Method: Least Squares  
Date: 09/22/12 Time: 15:55  
Sample (adjusted): 2001M03 2012M07  
Included observations: 137 after adjustments  
Convergence achieved after 2 iterations

	Coefficient	Std. Error	t-Statistic	Prob.
AR(12)	0.309797	0.079051	3.918940	0.0001
AR(24)	0.280039	0.067231	4.165357	0.0001

R-squared	0.381472	Mean dependent var	0.035038
Adjusted R-squared	0.376890	S.D. dependent var	0.765934
S.E. of regression	0.604607	Akaike info criterion	1.846016
Sum squared resid	49.34926	Schwarz criterion	1.888643
Log likelihood	-124.4521	Hannan-Quinn criter.	1.863339
Durbin-Watson stat	2.335086		



# MODELACIÓN CON ARIMA (13)

- Agrego entonces un ar(1) y un ma(1)

equation modelo4

modelo4.ls dlxsoja c ar(12) ar(24) ar(1) ma(1)

Equation: MODELO4 Workfile: XPARAGUAY::Xparaguay

View Proc Object Print Name Freeze Estimate Forecast Stats Resids

Dependent Variable: DLXSOJA  
 Method: Least Squares  
 Date: 09/22/12 Time: 16:01  
 Sample (adjusted): 2001M03 2012M07  
 Included observations: 137 after adjustments  
 Convergence achieved after 13 iterations  
 MA Backcast: 2001M02

	Coefficient	Std. Error	t-Statistic	Prob.
C	0.007180	0.126409	0.056804	0.9548
AR(12)	0.339177	0.080443	4.216389	0.0000
AR(24)	0.296944	0.072611	4.089537	0.0001
AR(1)	0.181005	0.090015	2.010830	0.0464
MA(1)	-0.546495	0.104190	-5.245192	0.0000

R-squared	0.424388	Mean dependent var	0.035038
Adjusted R-squared	0.406945	S.D. dependent var	0.765934
S.E. of regression	0.589846	Akaike info criterion	1.817903
Sum squared resid	45.92520	Schwarz criterion	1.924471
Log likelihood	-119.5263	Hannan-Quinn criter.	1.861210
F-statistic	24.33029	Durbin-Watson stat	1.786698

**Correlogram of Residuals**

Date: 09/22/12 Time: 16:02  
 Sample: 2001M03 2012M07  
 Included observations: 137  
 Q-statistic probabilities adjusted for 4 ARMA term(s)

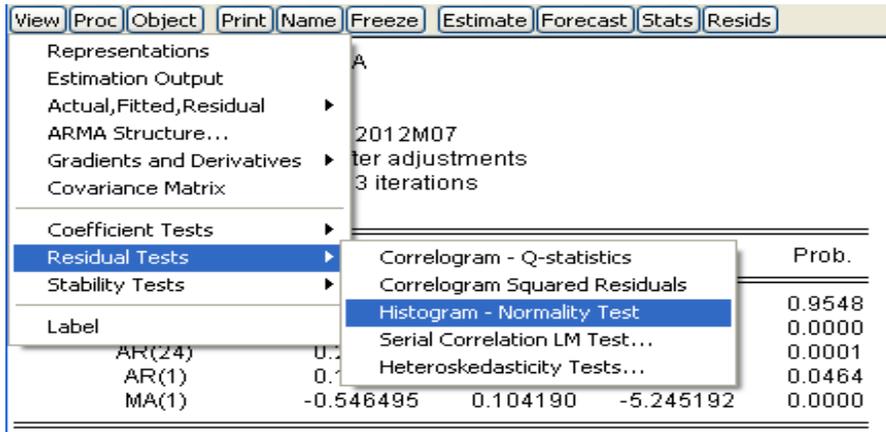
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.105	0.105	1.5443	
		2	-0.082	-0.094	2.4948	
		3	-0.123	-0.105	4.6352	
		4	-0.081	-0.066	5.5727	
		5	-0.063	-0.070	6.1516	0.013
		6	0.002	-0.011	6.1522	0.046
		7	-0.000	-0.028	6.1522	0.104
		8	-0.096	-0.119	7.5151	0.111
		9	-0.150	-0.152	10.881	0.054
		10	-0.093	-0.106	12.182	0.058
		11	0.056	0.012	12.658	0.081
		12	0.060	-0.021	13.205	0.105
		13	0.011	-0.054	13.225	0.153
		14	-0.087	-0.129	14.390	0.156
		15	-0.006	-0.019	14.396	0.212
		16	0.059	0.023	14.949	0.244
		17	0.034	-0.036	15.135	0.299
		18	0.066	0.009	15.829	0.324
		19	0.028	-0.012	15.959	0.385
		20	-0.065	-0.063	16.649	0.409
		21	-0.114	-0.094	18.784	0.341
		22	0.033	0.023	18.966	0.394
		23	0.050	-0.014	19.376	0.433
		24	0.015	-0.029	19.413	0.495
		25	-0.071	-0.080	20.276	0.504
		26	-0.052	-0.046	20.739	0.537
		27	-0.051	-0.064	21.184	0.570
		28	0.007	-0.034	21.192	0.627
		29	-0.064	-0.156	21.908	0.641
		30	0.024	-0.046	22.010	0.688
		31	-0.022	-0.101	22.097	0.732
		32	-0.020	-0.068	22.169	0.773
		33	0.023	-0.053	22.267	0.809
		34	0.069	-0.053	23.143	0.809
		35	0.126	0.019	26.099	0.717
		36	0.047	-0.013	26.523	0.740

Nuestro correlograma quedó bien



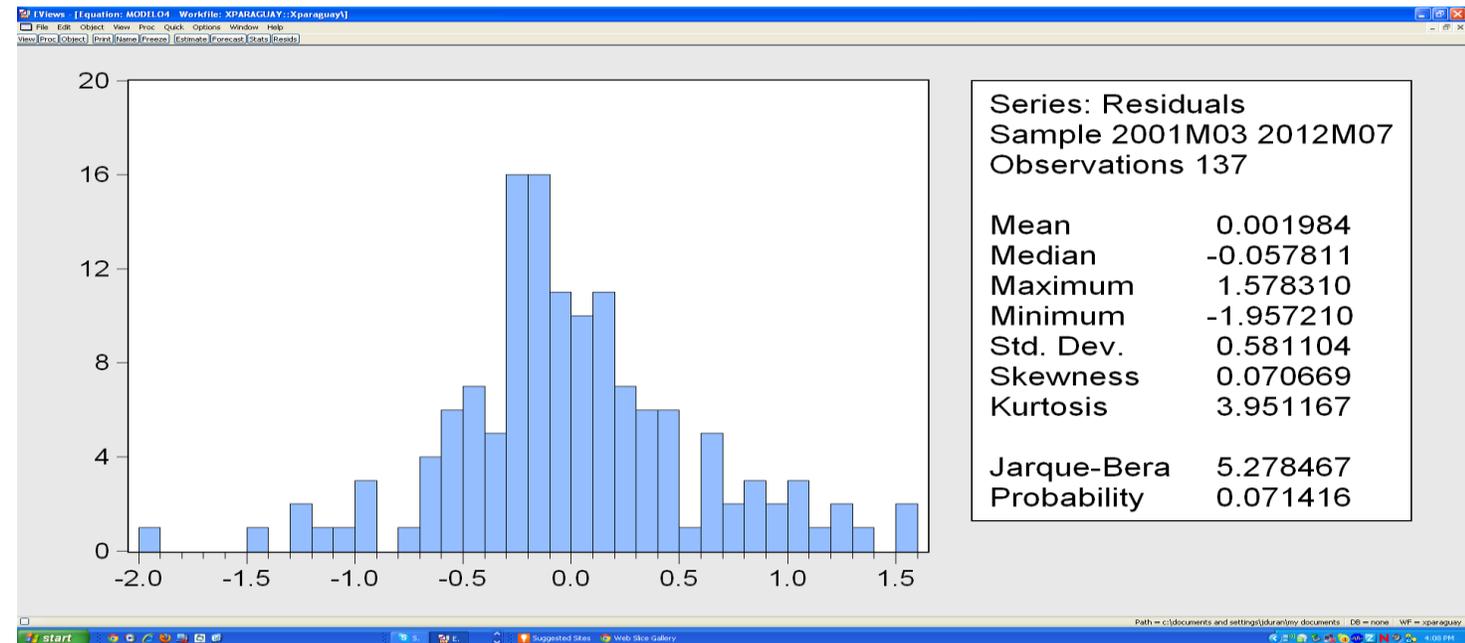
# MODELACIÓN CON ARIMA (14)

- Ahora hacemos los test de hipótesis
  - Test de normalidad de los residuos



The screenshot shows the EViews software interface. The 'Residual Tests' menu is open, listing various tests. Below the menu, a table displays the results for several tests.

Label				Prob.
AR(24)	0.000000			0.0000
AR(1)	0.000000			0.0464
MA(1)	-0.546495	0.104190	-5.245192	0.0000



# MODELACIÓN CON ARIMA (15)

- Ahora podemos proyectar  
Con el comando Forecast

**Forecast**

Forecast of  
Equation: MODELO4      Series: DLXSOJA

Series names  
Forecast name: **pronostico4**  
S.E. (optional):  
GARCH(optional):

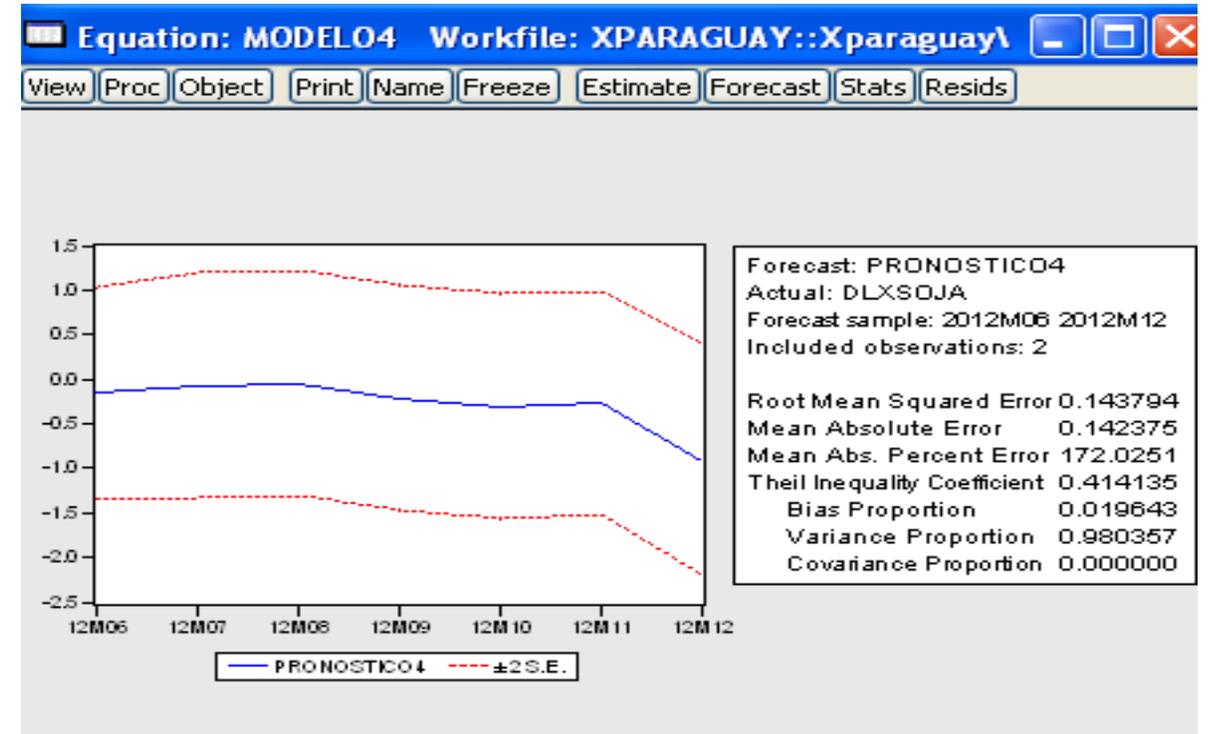
Method  
 Dynamic forecast  
 Static forecast  
 Structural (ignore ARMA)  
 Coef uncertainty in S.E. calc

Forecast sample  
**2012m06|2012m12**  
MA backcast: Estimation period

Insert actuals for out-of-sample observations

Output  
 Forecast graph  
 Forecast evaluation

OK      Cancel



- Dependerán de sí prima la creación (CC) o desviación de comercio (DC).
- El alcance de los efectos dependerá de:
  - Si las *estructuras productivas* de los países son *complementarias o sustitutivas*.
  - Del *tamaño* de la Unión Aduanera o Zona de Libre Comercio,
  - Del *nivel previo de aranceles*.
  - De *las diferencias en los costes de producción*.
  - De los *costes de transporte y transacción*.
  - De la *flexibilidad de las economías* y su capacidad para adaptarse a las nuevas condiciones y especializarse en las producciones que genere con mayor eficiencia.

# Modelación con Equilibrio Parcial

- La metodología de equilibrio parcial es ampliamente utilizada para analizar el impacto de variaciones arancelarias sobre la creación y desviación de comercio.
- Una gran ventaja de esta metodología es su sencillez y rapidez de aplicación comparado con otros análisis. Asimismo, permite una evaluación muy desagregada a nivel de producto.
- El modelo calcula el impacto estático de reducciones arancelarias sobre el comercio en el año base. En otras palabras estima cómo sería el comercio si los aranceles se reducen o aumentan

# Modelación con Equilibrio Parcial (cont.)

- Debido a la posibilidad de analizar los efectos de una liberalización arancelaria a un nivel muy desagregado de datos es posible realizar evaluaciones bastante precisas.
- En un modelo de equilibrio parcial, el análisis se realiza a partir de la consideración de los efectos de una política determinada a nivel de los mercados directamente afectados, a saber, el mercado de bienes importados, el de bienes exportados.
- Es importante recalcar que un modelo de este tipo no tiene en cuenta las interacciones entre los diversos mercados de una economía. A diferencia del equilibrio parcial, en los modelos de Equilibrio General se consideran simultáneamente la interacción de todos los mercados.
- Para realizar una evaluación ex-ante, la metodología de equilibrio parcial contempla el uso de elasticidades que permitan predecir el futuro del comportamiento del comercio.

# Creación de comercio

$$\Delta M = \varepsilon * M_0 \frac{(t_1 - t_0)}{(1 + t_0)}$$

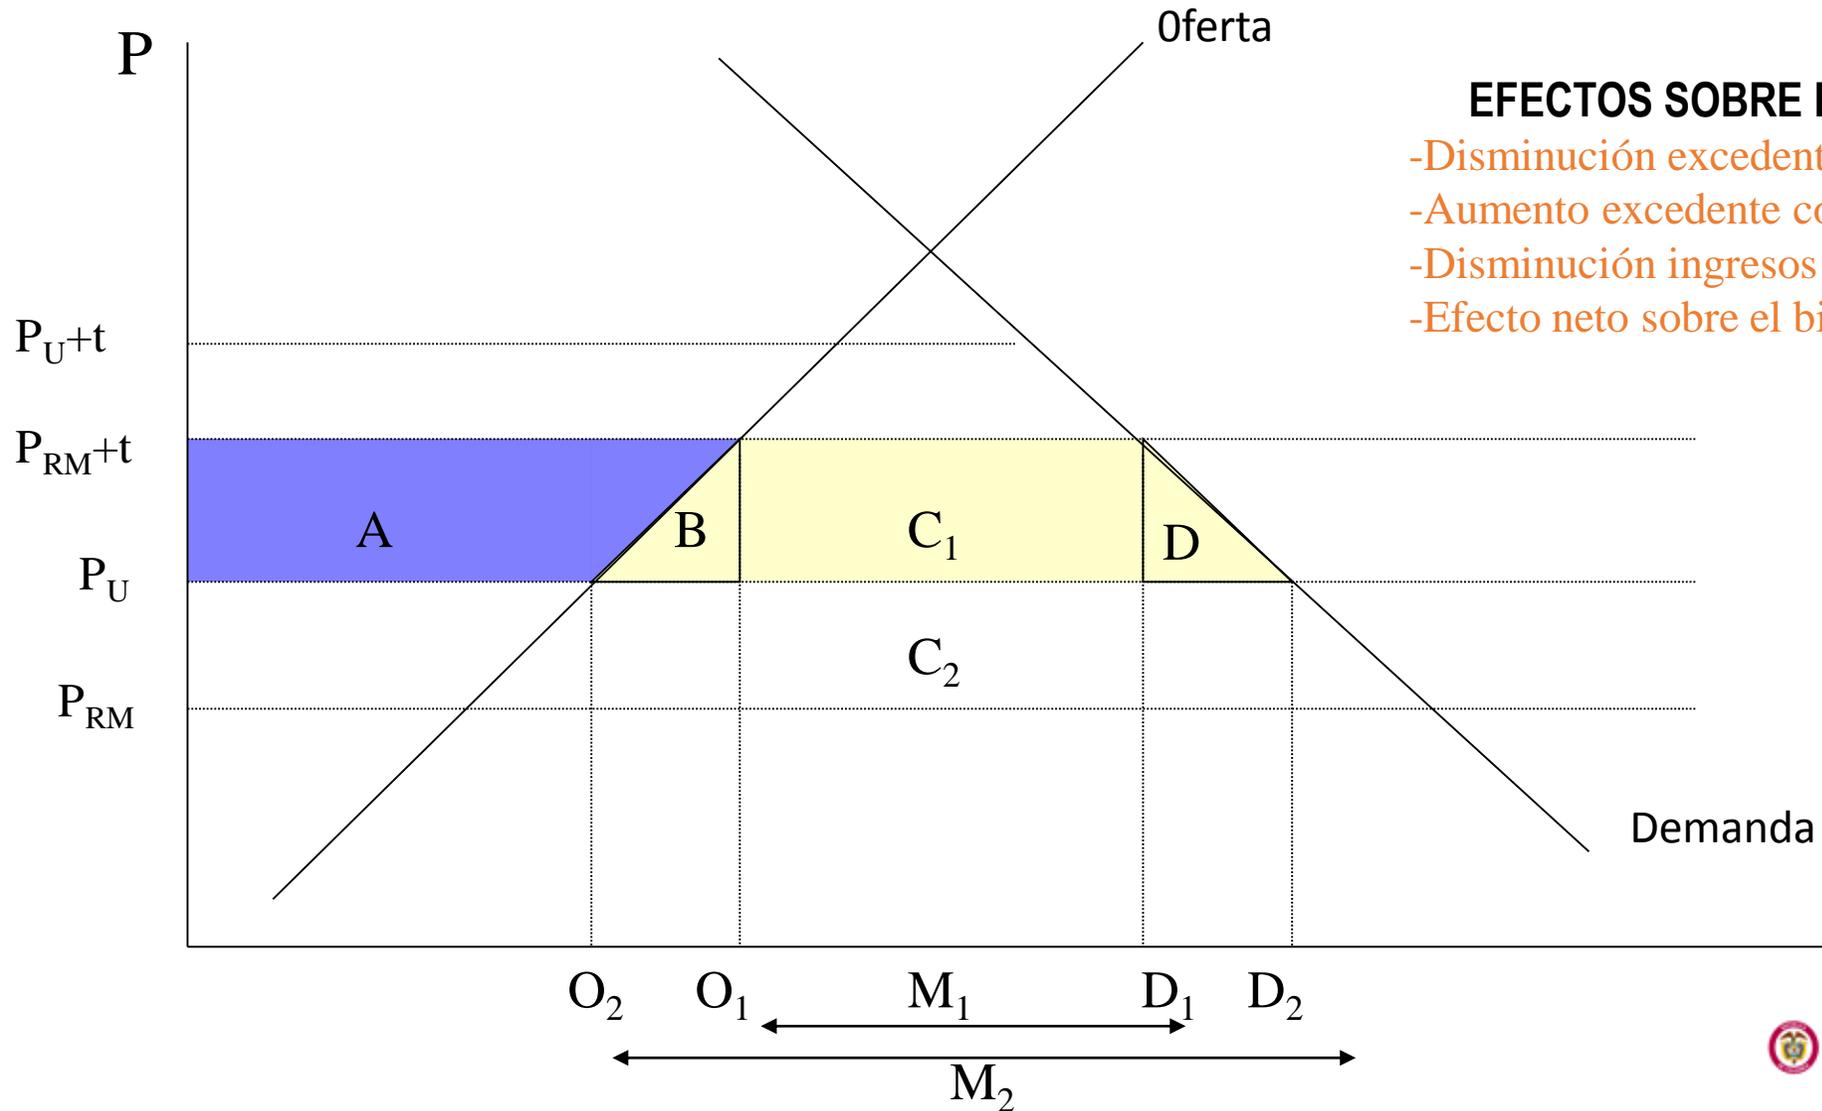
$$\Delta X = X_0 t_0 * (1 + \gamma + \gamma t_1)$$

# Resultado Creación de comercio para el caso de Nicaragua

Productos	Año base		Simulación 1		Cambios sobre la base	
	Xs	Ms	Xs	Ms	Xs	Ms
Productos agrícolas	88	1	88,1	1,2	0,6	3,5
Petróleo y Minería	0	0	0,3	0,3	0,0	3,1
Manufacturas Livianas	31	37	32,7	37,6	6,7	1,4
Manufacturas pesadas	7	131	6,8	140,6	0,2	7,0
Servicios	95	114	95,3	114,4	0,0	0,2
<b>Total</b>	<b>221</b>	<b>284</b>	<b>223</b>	<b>294</b>	<b>1,2</b>	<b>3,5</b>

# MODELO DE EQUILIBRIO PARCIAL PARA EVALUAR IMPACTOS COMERCIALES

## Efectos estáticos



### EFFECTOS SOBRE EL BIENESTAR

- Disminución excedente productor:  $-A$
- Aumento excedente consumidor:  $+A+B+C_1+D$
- Disminución ingresos arancelarios:  $-C_1-C_2$
- Efecto neto sobre el bienestar:  $(B+D)-C_2$