

Consultoría para el Análisis de Series de Tiempo de variables de volumen y precios de la actividad agropecuaria en Centroamérica

PRODUCTO 1. Documento metodológico para el análisis de series de tiempo

PRODUCTO 2. Estudio cuantitativo sobre el orden de integración y modelos univariados para una serie de volumen y otra de precios del sector agropecuario

PRODUCTO 3. Análisis del componente estacional

PRODUCTO 4. Los pronósticos de corto plazo

Msc. Sandra Hernández

21 de diciembre de 2015

TABLA DE CONTENIDO

<i>INTRODUCCIÓN</i>	3
<i>CAPÍTULO I: METODOLOGÍA DE ANÁLISIS DE SERIES DE TIEMPO</i>	5
1.1. Introducción.....	5
1.2. Modelos ARIMA univariantes	5
1.3. Los modelos ARIMA con variables de Intervención	16
1.4. Pruebas de integración.....	19
1.5. Descomposición de series de tiempo	23
<i>CAPÍTULO II: DESCRIPCIÓN DE LAS SERIES ANALIZADAS</i>	29
2.1. Introducción.....	29
2.2. Recolección de los datos.....	29
2.3. El índice de precios al consumidor del grupo alimentos	30
2.4. El indicador de corto plazo de la Actividad Agropecuaria	35
2.5. Cálculos regionales.....	39
2.6. Paquetes estadísticos para el análisis de los datos	43
<i>CAPÍTULO III: ORDEN DE INTEGRACIÓN Y MODELOS ARIMA</i>	45
3.1. Introducción.....	45
3.2. Análisis previo	45
3.3. Modelos ARIMA para el IPC del grupo alimentos	50
3.4. Modelos ARIMA para la producción agropecuaria.....	70
<i>CAPÍTULO IV: ANÁLISIS DEL COMPONENTE ESTACIONAL</i>	93
4.1 Introducción.....	93
4.2. El componente estacional del índice de precios de alimentos	94
4.3. El componente estacional de la actividad agropecuaria.....	100
4.4. Recomendaciones internacionales sobre el ajuste estacional	111
<i>CAPÍTULO V: LOS PRONÓSTICOS DE CORTO PLAZO</i>	116
5.1 Introducción.....	116
5.2 Los pronósticos de corto plazo del IPC de alimentos	117
5.3 Los pronósticos de corto plazo de la actividad agropecuaria.....	129
<i>CONCLUSIONES Y RECOMENDACIONES</i>	140
<i>BIBLIOGRAFÍA</i>	143
<i>ANEXO 1: ESTRUCTURAS TEÓRICAS DE ALGUNAS FUNCIONES DE AUTOCORRELACIÓN PARA DISTINTOS MODELOS ARIMA</i>	145
<i>ANEXO 2: SERIES DE DATOS UTILIZADAS EN ESTE INFORME</i>	149
<i>ANEXO 3: PONDERADOS UTILIZADOS PARA LA CONSTRUCCIÓN DE INDICADORES REGIONALES</i>	154
<i>ANEXO 4: ANÁLISIS PREVIO DEL IPC DE ALIMENTOS</i>	155
<i>ANEXO 5: PRUEBAS DE INTEGRACIÓN DEL IPC DE ALIMENTOS</i>	162
<i>ANEXO 6: RESULTADOS MODELOS DEL IPC DE ALIMENTOS</i>	176
<i>ANEXO 7: ANÁLISIS PREVIO DE LA PRODUCCIÓN AGROPECUARIA</i>	197
<i>ANEXO 8: PRUEBAS DE INTEGRACIÓN DE LA PRODUCCIÓN AGROPECUARIA</i>	205
<i>ANEXO 9: RESULTADOS MODELOS DE LA PRODUCCIÓN AGROPECUARIA</i>	217

INTRODUCCIÓN

El presente documento tiene como objetivo contribuir al análisis de las variables de volumen y precios de la actividad agropecuaria mediante la construcción de un marco metodológico de análisis de series de tiempo, aplicado a variables relevantes de los países de Centroamérica y Panamá, que permita contar con series desestacionalizadas y modelos univariados para pronósticos de corto plazo; técnicas esenciales en el análisis de coyuntura.

En ese marco se han seleccionado para este estudio los índices de precios al consumidor del grupo “alimentos y bebidas no alcohólicas”, disponibles en forma mensual para todos los países; y el índice mensual de actividad económica (IMAE) del “sector agropecuario” para los países centroamericanos y el Producto Interno Bruto (PIB) trimestral del “sector agropecuario” para Panamá. Adicionalmente, se construyeron indicadores regionales, tanto para los precios de alimentos como para la actividad agropecuaria, mediante un promedio ponderado de los indicadores de cada país. De tal modo que el análisis se aplicó a un total de catorce series.

Este documento está estructurado en cinco capítulos. En el primer capítulo se describen los fundamentos teóricos de los modelos ARIMA univariantes, los cuales son utilizados tanto para el pronóstico como para la descomposición de las series. Se incluyen las variables de intervención y de calendario, que resultan fundamentales para lograr una buena especificación del modelo. Además, se describen las principales pruebas de integración, herramienta básica en la fase exploratoria de las series de tiempo. Finalmente, se aborda el tema de los componentes de una serie de tiempo, aspecto que da origen a las series desestacionalizadas, a la tendencia, al ciclo y al componente irregular.

En el capítulo II se realiza una descripción de las series que serán analizadas en este documento. Se describe cada serie de precios al consumidor del grupo alimentos y cada indicador de corto plazo de la producción agropecuaria. Se mencionan las fuentes

primarias de datos, los años base, el periodo de datos disponible para cada serie, así como cualquier otro hecho relevante que deba ser conocido para lograr una buena comprensión de las series bajo análisis. Adicionalmente se describe el proceso de construcción de los indicadores regionales, tanto para el índice de precios al consumidor de alimentos como para la variable de producción agropecuaria.

En el capítulo III se describen los modelos ARIMA que fueron identificados para cada una de las series de producción agropecuaria y del índice de precios de alimentos, tanto a nivel de cada país como para el agregado regional. Se realiza un resumen de los principales hallazgos, se justifica cada modelo seleccionado y se describe la ecuación resultante. Adicionalmente, se incluye una sección de análisis previo, donde se resumen los resultados de las pruebas de integración y una prueba de igualdad de variancias.

En el capítulo IV se estima el componente estacional, se interpretan los factores estacionales del año 2014 y se presenta y analiza la serie desestacionalizada, tanto en niveles como en tasas de variación. Para ello se utilizan los modelos ARIMA que fueron identificados en el capítulo III. Se incluye además un resumen de las recomendaciones internacionales sobre la publicación de señales en el análisis de coyuntura.

Finalmente, en el capítulo V se realizan pronósticos para un periodo de 12 meses fuera de la muestra, utilizando los modelos ARIMA ajustados en el capítulo III. Adicionalmente, se realiza un pronóstico dentro del espacio muestral para definir la capacidad del modelo para predecir $t+h$ períodos por delante. Para ello se evalúan horizontes de 1, 3, 6 o 12 meses.

CAPÍTULO I: METODOLOGÍA DE ANÁLISIS DE SERIES DE TIEMPO

1.1. Introducción

En este capítulo se describen los fundamentos teóricos de los modelos ARIMA univariantes que serán utilizados en este estudio, tanto para efectos de pronóstico como en la descomposición de las series. Se hace énfasis en las variables de intervención que resultan fundamentales para lograr una buena especificación del modelo. Además, se describen las principales pruebas formales de integración, herramienta básica en la fase exploratoria de las series de tiempo. Finalmente, se aborda el tema de los componentes de una serie de tiempo, aspecto que da origen a las series desestacionalizadas, a la tendencia y al ciclo.

1.2. Modelos ARIMA univariantes

A) Descripción

Los modelos ARIMA (Autoregressive Integrated Moving Average) fueron introducidos por Box y Jenkins (1970), cuyo trabajo revolucionario se mantiene vigente en la actualidad. El objetivo de estos modelos es encontrar una buena representación del mecanismo generador de un proceso que ha producido una realización en particular (Pankratz, 1983). Se caracterizan porque el pronóstico se realiza tomando en cuenta únicamente la información del pasado, la cual implícitamente recoge el efecto de todas aquellas variables que lo causaron.

Los modelos ARIMA univariantes tratan de estimar el mecanismo de generación de las observaciones de una serie bajo el supuesto de que éstas son estadísticamente

dependientes¹. Se utiliza el concepto de correlación para medir la relación de Z en el momento t (Z_t) con periodos anteriores t-1, t-2, ... (Z_{t-1}, Z_{t-2}, \dots). El elemento aleatorio se supone que está idénticamente distribuido con media cero, variancia constante y autocorrelación nula en todos los rezagos.

El modelo teórico general se expresa de la siguiente forma²:

$$Z_t = \mu + \frac{\Theta(B)}{\Phi(B)} a_t$$

con,

$$\Theta(B) = (1 - \Theta_1 B - \Theta_2 B^2 - \dots - \Theta_q B^q) a_t$$

$$\Phi(B) = (1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p) Z_t$$

B es el operador de rezagos tal que $B^p Z_t = Z_{t-p}$

donde,

Z_t es una variable estocástica medida en el momento t, t-1, t-2, ...;

a_t es el residuo o innovación en cada momento t,

μ es el parámetro que se utiliza en la estimación de la media,

Φ_i y Θ_i son los ponderadores poblacionales (ϕ_i y θ_i son los estimadores muestrales).

En este contexto, a la discrepancia entre la predicción y el valor observado se le denomina “innovación” (a_t), debido a que se considera que refleja los elementos innovadores que provocaron algún cambio en la variable observada, no previsto por los estimadores de los parámetros.

Estos modelos descansan en dos conceptos principales:

- a) El polinomio $\Phi(B)$, denominado autorregresivo, recoge la estructura de correlaciones de la serie Z_t , a través de las estimaciones (ϕ_i) de los parámetros. En definitiva utiliza rezagos de la variable Z_t para explicar el futuro.

¹ Contrario al análisis de regresión tradicional, donde se supone que las observaciones de la variable y_t son independientes entre sí, esa dependencia temporal es la base en la formulación de un modelo ARIMA.

² Por facilidad se omite el polinomio del componente estacional, el cual se agrega más adelante.

b) El polinomio $\Theta(B)$, denominado de medias móviles, incorpora la función de correlación de los residuos mediante las estimaciones (θ_i) de los parámetros. Estos residuos (o innovaciones) mejoran los pronósticos debido a que incorporan las discrepancias que se dieron en el pasado entre el valor estimado y el observado, como un mecanismo de corrección de errores.

Si la serie tiene estacionalidad se agrega un polinomio de tipo MA, denominado $\Theta_s(B)$, y un polinomio de tipo AR, llamado $\Phi_s(B)$, cuya interpretación es semejante a la expuesta anteriormente pero referido a la periodicidad de la serie (mensual, trimestral, etc.), del siguiente modo:

$$\Phi(B)\Phi_s(B)Z_t = \mu + \Theta(B)\Theta_s(B)a_t$$

Estos modelos también pueden ser expresados mediante la notación introducida por Box & Jenkins:

ARIMA (p,d,q)(P,D,Q) s

donde

- **p** indica el número de parámetros autoregresivos de la parte regular de la serie y **P** de la parte estacional;
- **q** indica el número de parámetros de medias móviles de la parte regular de la serie y **Q** de la parte estacional;
- **d** y **D** es el número de diferenciaciones regulares y estacionales, respectivamente, requeridas para que la serie sea estacionaria (que se explica en el apartado 1.3);
- **s** es la periodicidad de la serie (4 para trimestral, 12 para mensual, etc.).

Ejemplos de dos modelos sencillos son:

ARIMA (0,0,1) o MA(1): $y_t = a_t - \theta a_{t-1}$

ARIMA (1,0,0) o AR(1): $y_t = \phi y_{t-1} + a_t$

B) Supuestos

Los modelos ARIMA descansan en tres supuestos:

a) Estacionariedad:

Los modelos ARIMA son aplicables a series que son estacionarias o integradas de orden cero $I(0)$ ³. Una serie estacionaria es aquella que tiene media, variancia y función de autocorrelación que son constantes a través del tiempo (Pankratz, 1991)⁴. Este supuesto simplifica la estructura estadística de la serie y ayuda a obtener estimaciones de los parámetros a partir de un número moderado de datos⁵.

b) Invertibilidad:

El modelo resultante debe ser invertible, es decir, los pesos asignados a las observaciones pasadas disminuyen conforme aumenta el orden del rezago. La invertibilidad garantiza que, para un proceso estacionario, cualquier función de autocorrelación dada corresponde en *forma única* a un mecanismo generador ARIMA (Pankratz, 1983).

La invertibilidad también se aplica a los modelos de medias móviles ya que todo proceso MA se puede escribir como un proceso AR, es decir, en función de las observaciones pasadas. El siguiente ejemplo ilustra el concepto.

Sea un modelo MA(1): $y_t = a_t - \theta_1 a_{t-1}$

Si se despeja a_t del MA(1) se tiene: $a_t = y_t + \theta_1 a_{t-1}$

Rezagos de a_t se pueden escribir como: $a_{t-1} = y_{t-1} + \theta_1 a_{t-2}$

$$a_{t-2} = y_{t-2} + \theta_1 a_{t-3}$$

sustituyendo a_{t-1} en el modelo MA(1) se obtiene: $y_t = a_t - \theta_1 (y_{t-1} + \theta_1 a_{t-2})$

$$y_t = a_t - \theta_1 y_{t-1} - \theta_1^2 a_{t-2}$$

³ Una serie integrada de orden d , $I(d)$, es aquella que se puede hacer estacionaria mediante una transformación. El número de transformaciones requeridas define el orden p de la integración.

⁴ Esta definición de estacionariedad es llamada de *forma débil*. La estacionariedad de *forma estricta* requiere que la función de distribución de probabilidad de la serie sea independiente del tiempo. Si los residuos a_t están normalmente distribuidos, ambas definiciones son idénticas (Pankratz, 1991).

⁵ Pankratz (1983) sugiere disponer al menos de 50 observaciones. No obstante, frecuentemente los paquetes estadísticos imponen sus propias restricciones en cuanto al número de datos.

sustituyendo a_{t-2} en la ecuación anterior se obtiene:

$$y_t = a_t - \theta_1 y_{t-1} - \theta_1^2 (y_{t-2} + \theta_1 a_{t-3})$$

$$y_t = a_t - \theta_1 y_{t-1} - \theta_1^2 y_{t-2} - \theta_1^3 a_{t-3}$$

luego, con sustituciones sucesivas se obtiene que: $y_t = a_t - (\theta_1 B + \theta_1^2 B^2 + \theta_1^3 B^3 + \dots) y_t$

De tal modo que un modelo MA(1) es invertible cuando $\theta_1 < 1$.

c) Residuos ruido blanco:

Los residuos del modelo deben tener características de ruido blanco, esto es, *media cero, variancia constante y no autocorrelacionados*, lo cual se denota como:

$$E(a_t) = 0 \quad t = 1, 2, \dots, n$$

$$E(a_t^2) = \sigma^2 \quad t = 1, 2, \dots, n$$

$$E(a_t, a_{t^*}) = 0 \quad t, t^* = 1, 2, \dots, n \quad \text{y } t \neq t^*$$

Debido a que estos modelos se basan en la estructura de correlaciones de la serie, el análisis de los residuos es muy importante porque ayuda a detectar fallas en la especificación del mismo. Aun cuando la normalidad no es un requisito del ruido blanco, se recomienda verificar esta propiedad por las facilidades que se obtienen para realizar pruebas de hipótesis en la etapa de verificación.

C) Transformación de los datos

Aunque el supuesto de estacionariedad podría sugerir que los modelos ARIMA no son de validez general, ya que los fenómenos económicos no tienden a oscilar alrededor de un valor constante ni con una dispersión constante, ocurre que transformaciones de las variables pueden generar procesos estacionarios.

Una de las transformaciones más utilizadas es la diferenciación, que se define como:

$$Z_t = Y_t - Y_{t-1} = (1-B) Y_t = \Delta Y_t$$

donde:

Y_t es la variable original no estacionaria

Z_t es una variable transformada que es estacionaria

Las diferenciaciones son utilizadas para transformar una serie no estacionaria Y_t en una estacionaria Z_t . Diferenciaciones sucesivas se aplican a series cuya primera diferencia no es estacionaria, es decir, si ΔY_t no es estacionaria, posiblemente $\Delta^2 Y_t$ sí lo es. En términos generales $\Delta^d Y_t$ representa el número de diferenciaciones (d) requeridas para lograr estacionariedad. Hay varias notaciones para ello, una de las más populares es $I(d)$, conocida como el orden de integración de la serie, con igual interpretación.

Cuando una serie no es estacionaria *en la variancia* se puede aplicar cualquier transformación matemática que mejore la dispersión de los datos alrededor del nivel medio. En muchas variables los incrementos tienden a ser proporcionales a su correspondiente nivel, mostrando incrementos absolutos que son cada vez mayores por el simple hecho de que la serie crece. Esto hace que la variancia no sea homogénea y que una transformación logarítmica sea apropiada para corregir este problema.

¿Es la serie estacionaria en la media?

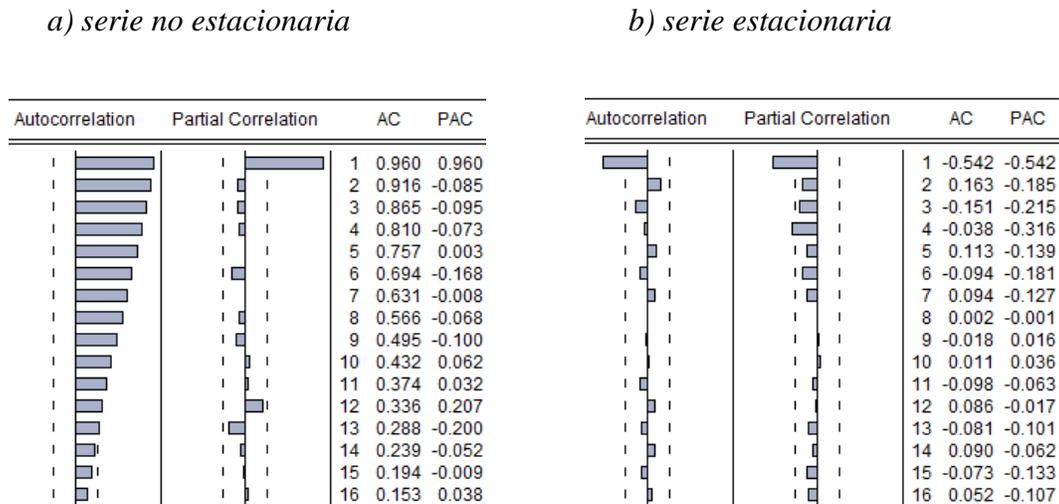
Hay varias formas de analizar la presencia de estacionariedad en la media y determinar el número de diferenciaciones requeridas para conseguir estacionariedad:

- En primer lugar se realiza una inspección visual de la serie (o de la serie transformada) para determinar si los datos oscilan alrededor de una media constante.
- Otra forma es observando la estructura del correlograma⁶. Si la función de autocorrelación cae rápidamente a cero, esto es evidencia de que la serie es estacionaria en la media; si la función de autocorrelación desciende lentamente hacia cero, la serie es probablemente no estacionaria (Pankratz, 1983). En el caso de series no estacionarias, se toma una primera diferencia y se inspecciona nuevamente el correlograma. Ver gráfico 1.1.

⁶ El correlograma es la representación gráfica de la función de autocorrelación. Es un gráfico de barras donde se muestra la magnitud de la correlación para distintos rezagos (k) de la variable Z_t . De tal modo que r_k representa la correlación entre Z_t y Z_{t-k} . Ver figuras a y b del Gráfico 1.

- También se pueden llevar a cabo pruebas formales de integración, tal como las desarrolladas por Dickey-Fuller y las de Phillips-Perron, según se explica en la sección 1.4 de este capítulo.

Gráfico 1.1 Correlogramas simple y parcial



¿Es la serie estacionaria en la variancia?

De igual forma un proceso es estacionario en la variancia si la dispersión se mantiene constante durante el periodo de estudio. Esto también se evalúa graficando la serie en el tiempo. Cualquier transformación algebraica puede ser aplicada para lograr una variancia estable, sin embargo, es común el uso de logaritmos por las facilidades de interpretación de los resultados: *los cambios en $\log(Z_t)$ son cambios relativos (porcentajes) mientras que los cambios en la serie original Z_t son cambios absolutos*. Esta transformación funciona muy bien en los casos en que la desviación estándar es proporcional al nivel medio de la serie (Pankratz, 1991).

D) Identificación del modelo

El proceso de identificación de los modelos ARIMA univariantes consiste en definir los valores de **p**, **P**, **q**, **Q** adecuados para explicar el comportamiento de una serie que es estacionaria. El instrumento fundamental en esta etapa es el correlograma simple y parcial de la serie original (o transformada).

Box y Jenkins (1970) desarrollaron unos modelos teóricos sobre el comportamiento que muestra el correlograma simple y parcial para distintos modelos ARIMA. Las funciones de autocorrelación teóricas de un AR(1), MA(1), AR(2), MA(2) y ARMA(1,1) se adjuntan en el anexo 1. Estos modelos (con pocos parámetros) son los que se usan comúnmente en la práctica. La identificación se realiza comparando el correlograma de la serie con los patrones teóricos. En términos generales se dice que:

- Si el correlograma simple tiene algún tipo de estructura (decreciente por ejemplo) y el correlograma parcial muestra una correlación significativa en $k=1$ y el resto cercanas a cero (punto de corte), se dice que lo apropiado es un modelo AR(1).
- Si el correlograma simple tiene una correlación significativa en $k=1$ y el resto cercanas a cero (punto de corte), mientras que en el correlograma parcial hay algún tipo de estructura (decreciente por ejemplo) se dice que lo apropiado es un modelo MA(1).
- Cuando en el correlograma simple y en el parcial se aprecia algún tipo de estructura es posible que se requiera un modelo mixto tipo ARMA.

Un resumen de estas características se muestra en la tabla 1.1.

Si la serie tiene estacionalidad, el modelo ARIMA(P,D,Q) también se determina analizando los correlogramas, con la diferencia que en esta ocasión se compara el comportamiento de las autocorrelaciones múltiplos de s (12, 24, 36,... en una serie mensual y 4, 8, 12,... en una serie trimestral) con los mismos patrones teóricos del anexo 1.

Tabla 1.1: Características de los correlogramas para distintos modelos ARIMA

Modelo	Correlograma simple	Correlograma Parcial
AR(p)	estructura	Punto de corte en $k=p$
MA(q)	Punto de corte en $k=q$	estructura
ARMA(1,1)	estructura	estructura

Fuente: elaboración propia.

E) Verificación del modelo seleccionado

¿Es el modelo invertible y estacionario?

Un modelo ARIMA es invertible si cumple con las condiciones que se especifican en la tabla 1.2:

- Un modelo MA es invertible si puede ser expresado en función de los rezagos de Y_t con pesos que disminuyen con el tiempo. Esto se cumple cuando los valores de los parámetros MA son menores a la unidad.
- Un modelo AR es estacionario si depende cada vez menos de los valores del pasado. No es explosivo.

Tabla 1.2. Condiciones de estacionariedad e invertibilidad de varios modelos ARIMA univariantes

Tipo de modelo	Condiciones de estacionariedad	Condiciones de invertibilidad
AR(1)	$ \phi_1 < 1$	Es invertible
AR(2)	$ \phi_2 < 1$ y $\phi_2 + \phi_1 < 1$ y $\phi_2 - \phi_1 < 1$	Es invertible
MA(1)	Es estacionario	$ \theta_1 < 1$
MA(2)	Es estacionario	$ \theta_2 < 1$ y $\theta_2 + \theta_1 < 1$ y $\theta_2 - \theta_1 < 1$

Fuente: Pankratz (1983). pag' 299.

¿Son los residuos ruido blanco?

A continuación se describen las pruebas más utilizadas para verificar el supuesto de ruido blanco en los residuos (media cero, variancia constante, no autocorrelacionados y normalidad):

- a) Una inspección visual de los residuos resulta fundamental para analizar su comportamiento. Se espera que los residuos oscilen alrededor de cero y que presenten una variabilidad homogénea. Adicionalmente se puede realizar una prueba de hipótesis $H_0: \mu = 0$, con el estadístico t , para verificar que la media de los residuos del modelo es cero.
- b) El correlograma aplicado a los residuos es una herramienta básica en la etapa de diagnóstico. Se espera que todas las autocorrelaciones (hasta un rezago k) sean iguales a cero. Para ello se lleva a cabo una prueba *t-student* para verificar la hipótesis $H_0: \rho_k = 0$, es decir, *no hay autocorrelación de orden k en los residuos*. Esta prueba frecuentemente se realiza calculando bandas de confianza para un conjunto grande de rezagos $1, \dots, k$. Las barras que se salen de las bandas representan correlaciones que son significativas y que invalidan el supuesto de no autocorrelación.
- c) Otra prueba importante de independencia de los residuos es el estadístico Q de Ljung-Box⁷, que consiste en una prueba conjunta $H_0: \rho_1 = \dots = \rho_{k^*} = 0$, o bien, H_0 : *los residuos son independiente o no correlacionados*. La fórmula es la siguiente:

$$Q = n(n+2) \sum_{k=1}^{k^*} (n-k)^{-1} \hat{\rho}_k^2 \quad \text{donde } k^* \text{ es el máximo rezago considerado.}$$

El estadístico Q tiene una distribución χ^2 con $k^* - p - q$ grados de libertad. Un aspecto fundamental es la definición del número de rezagos k^* que se utilizan para llevar a cabo la prueba. Si se selecciona un valor muy pequeño, el estadístico no será capaz de detectar correlaciones de mayor orden; si se selecciona un valor muy alto el estadístico podría tener menor potencia debido a que una correlación significativa en un determinado rezago podría estar diluida por correlaciones no significativas en

⁷ La Q de Ljung Box es una modificación del cálculo original de Box-Pierce. Se prefiere porque se aproxima más a una distribución Chi cuadrada cuando el tamaño de la muestra es moderado (Pankratz, 1983).

otros rezagos. Usualmente se trata de utilizar un valor k^* que incluya autocorrelaciones estacionales, por ejemplo $k^*=24$ o 36 para una serie mensual.

Para medir la significancia del valor calculado se utiliza la probabilidad de ocurrencia, de modo que si **Prob** < **0.05** se rechaza la hipótesis nula y se concluye que los residuos están autocorrelacionados (no son independientes). El valor de comparación (0.05) lo define el analista de datos al determinar el nivel de confianza de la prueba (0.95).

- d) Para verificar normalidad en los residuos se dispone de las pruebas de asimetría (S), curtosis (K) y la prueba de normalidad de Bera-Jarque, con la siguiente notación:

$$S = \frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \bar{y}}{\hat{\sigma}} \right)^3, \text{ que debería ser cercano a cero;}$$

$$K = \frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \bar{y}}{\hat{\sigma}} \right)^4, \text{ que debería ser cercano a tres; y}$$

$$BJ = \frac{N-k}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \text{ que se distribuye como } \chi^2 \text{ con 2 grados de libertad.}$$

donde $\hat{\sigma}$ es la desviación estándar y k el número de coeficientes estimados. En la prueba de Bera-Jarque la hipótesis nula es *Ho: los residuos siguen una distribución normal* y con un nivel de significancia del 5% el valor del $\chi^2_{2 \text{ gl}} = 5.99$. El primer paso para detectar la presencia de valores extremos es probar la normalidad de los residuos; cuando éstos no son normales puede deberse a observaciones que son extremas.

- e) El supuesto de homogeneidad de la variancia residual se puede comprobar de varias formas. Se mencionan dos métodos:
- Mediante un análisis visual del gráfico de los residuos. Los residuos deberían mostrar una dispersión aparentemente homogénea alrededor de la media.
 - Mediante el correlograma de los residuos al cuadrado. El correlograma no debería mostrar correlaciones significativas y el estadístico Q no debería ser significativo

(Prob > 0.05 para todo k). Esto sirve para comprobar si la variancia de los residuos presenta un patrón autorregresivo tipo ARCH (Autoregressive Conditional Heteroskedasticity), es decir, cuando la variancia de los residuos del momento t se ve afectada por los valores de los residuos en $t-1$.

1.3. Los modelos ARIMA con variables de Intervención

A) Variables de intervención binarias

Las series económicas frecuentemente están afectadas por fenómenos externos, tales como nuevas medidas de política pública, incluidas las económicas, cambios tecnológicos, huelgas de trabajadores, fenómenos climáticos, etc., que provocan alteraciones en el nivel de las series. Estos fenómenos son llamados intervenciones ya que interfieren en el comportamiento original de la serie. Cuando estos fenómenos son conocidos, se debe evaluar su efecto e incorporarlo al modelo ARIMA a través de variables artificiales binarias, del siguiente modo:

$$y_t = \frac{w(B)}{\delta(B)} I_t + \frac{\theta(B)}{\phi(B)} a_t$$

Donde,

$$\omega(B) = (\omega_0 - \omega_1 B^1 - \omega_2 B^2 - \dots - \omega_s B^s)$$

$$\delta(B) = (1 - \delta_1 B^1 - \delta_2 B^2 - \dots - \gamma_r B^r)$$

$$\theta(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q), \text{ polinomio de medias móviles}$$

$$\phi(B) = (1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p), \text{ polinomio autoregresivo}$$

I_t es una variable binaria y es la que se encarga de definir el momento en que se da la intervención.

a_t es la innovación del modelo ARIMA.

El término $w(B)/\delta(B)$ caracteriza y cuantifica el efecto de la intervención sobre la serie y_t .

Usualmente los valores anómalos no son conocidos a priori, pues no se conocen los fenómenos exógenos que afectan a una serie de tiempo, y más bien la serie es modelada sin considerar el efecto de las variables de intervención. Posteriormente, en la etapa de verificación, se observan residuos anormales, mayores que lo esperado, que son el resultado de esos eventos exógenos. Las variables artificiales que resulten de este proceso son incorporadas a la ecuación para ajustar en forma conjunta el modelo ARIMA y las variables artificiales.

Hay varios tipos de variables de intervención, dependiendo de la definición de la variable artificial. En cualquier caso, la variable artificial y su coeficiente se suman a los resultados brindados por el modelo ARIMA. El caso más simple se escribe como:

$$\phi(B)Z_t = \theta(B)a_t + w I_t$$

Con esta ecuación se pueden recoger dos tipos de fenómenos:

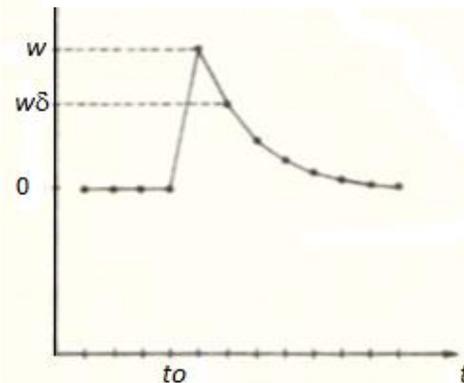
- Aquellos que se reflejan como una elevación o caída momentánea del nivel en t_0 , que desaparece sin influir sobre el comportamiento posterior de la serie. A este tipo de efectos se le llama “impulso” (AO) y se ajusta con una variable I_t que tiene ceros en todo momento y un uno en el momento t_0 .
- Los que ejercen una influencia sostenida sobre el nivel de la serie, pero dejan intacta la estructura básica de su parte estocástica. Cuando el nivel de todas las observaciones a partir de t_0 son afectadas por la misma cantidad se le llama “escalón” (LS) y su forma más simple puede ser ajustada con una variable I_t que tiene ceros en todo momento y unos a partir del momento t_0 .

Adicionalmente existen funciones dinámicas de intervención que permiten recoger fenómenos exógenos con efectos complejos. En estos casos se puede utilizar un polinomio de orden s en el numerador, $w(B)$, y un polinomio de orden r en el denominador $\delta(B)$. Un caso común en la práctica es el uso de “cambios transitorios” (TC) representado por el siguiente polinomio:

$$\frac{\omega}{(1 - \delta B)} I_t = (\omega - \omega\delta B^1 - \omega\delta^2 B^2 - \dots - \omega\delta^r B^r) I_t$$

que recoge el shock inicial en t_0 (w) y disminuciones paulatinas de ese efecto hasta retornar al nivel original de la serie.

Gráfico 1.2. Ejemplo de un shock del tipo "cambio transitorio"



B) Variables de intervención de efecto calendario

Dentro del Análisis de Intervención también se consideran los ajustes por semana santa y por días laborables. Estos cambios en el calendario pueden afectar los niveles de la serie y por tanto afectar el ajuste del modelo ARIMA y las estimaciones del componente estacional. Los efectos de calendario se pueden separar en tres grupos:

- **Días de trabajo (*trading days*):** consiste en el ciclo semanal que se presenta en algunas series cuando los días de la semana tienen un nivel de actividad distinto, unido a la distinta longitud de los meses; de tal modo que, por ejemplo, un mes en particular podría tener un nivel de ventas superior a otro, debido únicamente a que posee un mayor número de días laborables. Esta oscilación semanal se trata con técnicas de regresión que permiten cuantificar el peso en la serie de un día laborable; posteriormente se ajusta con una variable *dummy* (o varias) que contiene el número de días hábiles de cada mes. Este fenómeno es especialmente importante en las variables tipo *quantum*.
- **Efecto Semana Santa (*easter day*):** es el efecto que sobre el nivel de la serie provoca el hecho de que la semana santa sea móvil. Esta movilidad es la que impide que este efecto se recoja en los coeficientes de estacionalidad. También con regresión se estima el efecto que tiene la semana santa en una serie en particular y se agrega una variable binaria con unos en los meses donde la Semana Santa está

presente y ceros en el resto de meses del año. Este fenómeno usualmente es importante en variables de producción.

- **Otros feriados y años bisiestos:** se refiere al efecto que sobre el nivel de una serie puede tener una festividad de un país en particular. Los carnavales son ejemplos típicos para algunos países. También se incluye en este grupo el efecto que puede tener un día adicional en febrero en los años bisiestos.

1.4. Pruebas de integración

Muchas series de tiempo son claramente no estacionarias en el sentido de que la media y la variancia dependen y evolucionan con el tiempo. Cuando las observaciones tienden a alejarse de un cierto valor determinado, a medida que transcurre el tiempo, se dice que la serie tiene tendencia; una serie con tendencia es una serie no estacionaria.

La estacionariedad es uno de los requisitos que debe cumplir una serie para poder ajustar un modelo ARIMA, tal como se explicó en el apartado 1.2 de este capítulo. También se dijo que las diferenciaciones permiten transformar una serie no estacionaria en estacionaria. No obstante, la tendencia en una serie también se puede eliminar agregando dentro del modelo una variable determinística, llamada “variable tiempo”. De tal modo que la tendencia se suele eliminar de dos formas:

- a) Ajustando regresiones incluyendo a la variable tiempo⁸ (T) como explicativa.
- b) Diferenciando en forma sucesiva la serie $Z_t = Y_t - Y_{t-1}$, esto es $Z_t = \Delta Y_t$.

El primer caso será adecuado cuando la tendencia es determinística, no cambia con el tiempo, de modo que sus valores a futuro son predecibles sin error. El segundo caso se aplica a tendencias estocásticas.

⁸ En el caso de una tendencia lineal, se agrega un vector de datos que crezcan linealmente, tal como 1,2,3,4,...etc. También se pueden agregar tendencias cuadráticas T^2 u otras formas.

Dickey y Fuller, en 1979, desarrollaron una prueba para conocer cuál es el mecanismo más apropiado para eliminar la tendencia en una serie particular, ajustando una regresión como la siguiente:

$$y_t = \alpha + \delta y_{t-1} + \beta T + \varepsilon_t \quad \text{con } \varepsilon_t \text{ I}(0)$$

Si $\delta=1$ y $\beta=0$ la diferenciación es la adecuada, de modo que la serie tiene tendencia estocástica y requiere de una diferenciación para lograr una serie estacionaria. Si $|\delta| < 1$ incluir la variable tiempo es lo adecuado⁹ y se dice que la serie es estacionaria alrededor de una tendencia T. Entonces, el procedimiento para contrastar la hipótesis $H_0: \delta = 1$ se conoce como prueba de *raíces unitarias*¹⁰. La hipótesis nula de estas pruebas es $H_0: y_t$ tiene raíz unitaria, es decir, se sostiene que las series de tiempo son estacionarias en diferencias, a menos que exista evidencia para rechazarla. Cuando un proceso tiene raíz unitaria ($\delta=1$), se dice que la serie es *Integrada* de orden 1 o I(1). En el caso de que se trate de una serie estacionaria, se dice que es Integrada de orden 0 o I(0).

En el método Box y Jenkins (1970) la existencia de raíces unitarias se evalúa mediante una inspección visual del correlograma, tal como se explicó en la sección 1.2 de este capítulo. Las pruebas de raíces unitarias son una formalización de esto y a veces dan resultados opuestos (especialmente cuando la muestra es pequeña), razón por la cual se recomienda mirar el correlograma como complemento de una prueba de raíces unitarias (Maddala, 1996).

A continuación se describen brevemente las pruebas clásicas de integración: Dickey-Fuller, Dickey-Fuller aumentada y Phillip-Perron. En la actualidad existen nuevas pruebas de integración, muchas de ellas introducidas como variantes a las pruebas clásicas. Los paquetes estadísticos ofrecen conjuntos de pruebas de integración dentro de los cuales, sin duda, estarán las pruebas clásicas que se describen a continuación.

⁹ El caso de $|\delta| > 1$ no es muy común, pues causaría que la serie y_t sea explosiva.

¹⁰ La terminología proviene de las series de tiempo. Si $y_t = \alpha + \delta y_{t-1} + \varepsilon_t$, se puede representar como un proceso AR, que en términos generales se escribe $\phi(B)y_t = \varepsilon_t$, de modo que la estacionariedad del proceso depende de las raíces del polinomio $\phi(B) = 0$. Una raíz que es igual a 1 en valor absoluto es llamada raíz unitaria.

A) Prueba Dickey-Fuller (DF)

La prueba más conocida es la de Dickey y Fuller, quienes desarrollaron tablas con experimentos de Monte Carlo; estas tablas fueron introducidas en 1979 para distintos tamaños de muestra y para cualquier número de variables exógenas. Mackinnon en 1991 tabuló por primera vez una gran cantidad de simulaciones permitiendo encontrar el valor tabular para cualquier tamaño de muestra, tomando en consideración la constante y/o la tendencia en la ecuación. La ecuación es:

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

con ε_t ruido blanco

α es la constante de la ecuación

T es una tendencia lineal con valores 1, 2, 3, ... n

Ho: y_t tiene raíz unitaria; $\delta=1$; la serie es $I(1)$ o no estacionaria

Esta prueba se suele realizar con constante o sin ella y con tendencia o sin ella. La regresión se ajusta por mínimos cuadrados ordinarios y el valor *t-student* del coeficiente δ no se compara con el valor tabular de la *t-student* sino con las tablas desarrolladas específicamente para esta prueba¹¹ y que se presentan en la tabla 1.3. Esta regresión generalmente se ajusta no sobre los niveles de la serie sino sobre sus diferencias, entonces, en el caso más simple $y_t = \delta y_{t-1} + \varepsilon_t$, si se resta y_{t-1} a cada lado de la ecuación se obtiene $y_t - y_{t-1} = \delta y_{t-1} - y_{t-1} + \varepsilon_t$, $\Delta y_t = (1 - \delta) y_{t-1} + \varepsilon_t$ o bien $\Delta y_t = \gamma y_{t-1} + \varepsilon_t$, y entonces la prueba se hace sobre $H_0: \gamma=0$.

En el programa EViews solamente se consideran los siguientes tres casos: con constante; con constante y con tendencia; sin constante y sin tendencia. La recomendación es escoger una especificación que sea plausible para la serie bajo análisis: si la serie tiene tendencia, introducir la constante y la tendencia es lo

¹¹ Las valores *t-student* no pueden ser usadas ya que bajo la hipótesis nula ($\delta=1$) la distribución del estimador por mínimos cuadrados ordinarios de δ no es estándar, presenta un sesgo hacia el valor 0, porque cuando $n \rightarrow \infty$ el $\lim_{n \rightarrow \infty} \frac{X'X}{n}$ en vez de tender hacia un valor constante (Davidson y MacKinnon, 1993).

adecuado; si la serie no tiene tendencia pero oscila alrededor de una media distinta de cero se deberá agregar la constante. Se advierte que la inclusión de regresores irrelevantes reduce la potencia de la prueba para rechazar la hipótesis nula de raíz unitaria, de tal modo que hay que tener cuidado de no agregar tendencia y constante cuando no son necesarias.

En el caso que la prueba indique que la serie es estacionaria y la prueba se realizó utilizando la variable T, se dice que la serie es estacionaria alrededor de una tendencia que es determinística.

B) Prueba Dickey-Fuller aumentada (DFA)

Cualquiera de las ecuaciones utilizadas para la prueba DF asume que el residuo es ruido blanco, sin embargo, es muy frecuente encontrar que estos residuos presenten autocorrelación serial. Lo que hace DFA es incorporar a la regresión rezagos de la variable y_t hasta lograr que los residuos sean ruido blanco, del siguiente modo:

$$\Delta y_t = \alpha + \gamma y_{t-1} + \beta T + \sum \xi_i \Delta y_{t-i} + \varepsilon_t$$

Ho: y_t tiene raíz unitaria; $\gamma=0$ ($\delta=1$); la serie es $I(1)$ o no estacionaria

Aquí el problema es definir el número de rezagos apropiado¹². Esto se puede determinar con alguno de los siguientes procedimientos (cuando el tamaño de la muestra no genere restricciones):

- Analizar el correlograma de los residuos de la ecuación DF y agregar los rezagos de aquellas autocorrelaciones que son significativas,
- Agregar rezagos a la ecuación y dejar aquellos que sean significativos,
- Agregar rezagos en forma gradual y elegir la ecuación que minimice el criterio de Akaike (o algún otro criterio de bondad de ajuste),
- Agregar rezagos hasta que los residuos sean ruido blanco.

Se puede notar que la prueba DF es un caso particular de la DFA, en la cual se asume que todas las variables independientes son iguales a cero ($\xi_i=0$).

¹²Este procedimiento asume que la correlación serial es de tipo AR.

C) Prueba Phillip-Perron

Otra forma de abordar el problema de la autocorrelación en los residuos es con la prueba de Phillips-Perron introducidas en 1988. Consiste en ajustar el valor *t-student* del estimador de δ para corregir por autocorrelación residual. La distribución asintótica del *t-student* modificado es la misma que la del DFA, de modo que los valores tabulares para realizar ambas pruebas de hipótesis coinciden. La principal ventaja de esta prueba respecto al DFA es que resulta más robusta en cuanto a heterocedasticidad y autocorrelación.

En esta prueba también se debe determinar la conveniencia de agregar variables exógenas como la tendencia lineal o la constante.

Tabla 1.3. Valores críticos para las pruebas de integración de Phillip-Perrón y Dickey-Fuller Aumentando¹³

Nivel de significancia	Parámetros determinísticos		
	C+Tendencia	con C	Ninguna
1%	-4.050509	-3.495677	-2.587831
5%	-3.454471	-2.890037	-1.944006
10%	-3.152909	-2.582041	-1.614656

Fuente: Programa econométrico E-Views, MacKinnon 1996 one side p-values

Nota: Si el valor del estadístico ADF es positivo, no se puede llegar a ninguna conclusión debido a que las tablas están construidas para someter a prueba la hipótesis de que hay raíz unitaria contra la alternativa de que el respectivo coeficientes es inferior a la unidad (tablas no simétricas).

1.5. Descomposición de series de tiempo

A) Conceptos

Una serie de tiempo se puede descomponer en cuatro componentes no observables: estacionalidad, tendencia, ciclo e irregular. Las técnicas que permiten esta estimación

¹³ Las tablas de Davidson y MacKinnon para las pruebas de raíces unitarias fueron desarrolladas para muestras grandes y en ese sentido el valor con el cual se contrasta la hipótesis no depende del tamaño de la muestra. No obstante, estas tablas toman en cuenta el número de variables explicativas consideradas en la ecuación: tendencia, constante y rezagos de la variable dependiente. Utilizando dos decimales, los valores tabulares se mantienen prácticamente inalterables para rezagos de 1 a 12.

reciben distintos nombres: extracción de señales, ajuste estacional o descomposición de series de tiempo.

En el campo de la economía se ha encontrado que el cálculo de estos componentes no observables enriquece los análisis de una serie de tiempo. De este modo, el conocimiento de las oscilaciones estacionales que se han presentado a través del tiempo, resulta de mucha utilidad para conocer si las variaciones actuales de una serie de tiempo obedecen efectivamente a un aumento (o disminución) del nivel medio de la serie o al efecto del fenómeno estacional. Adicionalmente, el análisis de la tendencia resulta fundamental para evaluar el crecimiento subyacente de una serie económica, aislado de otros movimientos erráticos o sistemáticos. En cuanto al fenómeno irregular, obtenido por diferencia, puede resultar muy útil en la identificación de aquellos fenómenos exógenos que habrían afectado a la serie de tiempo y en la estimación de la magnitud del impacto.

El análisis de series de tiempo supone la descomposición de las series en cuatro componentes no observables, descritos seguidamente:

- Tendencia (T): Es un movimiento de larga duración que se mantiene durante todo el período de observación.
- Variación estacional (E): Son los movimientos que se producen dentro del año y que se repiten de un año a otro. También se denominan ciclos cortos.
- Movimientos cíclicos (C): Son oscilaciones alrededor de la tendencia producidos por periodos alternativos de prosperidad y depresión, con la característica de que no son periódicos.
- Movimientos irregulares (I): Son las oscilaciones erráticas o accidentales que obedecen a variadas causas. No siguen ningún patrón específico de comportamiento y por tanto son impredecibles.

Existen dos modelos básicos que muestran de manera explícita la relación que guardan los componentes de una serie: el aditivo y el multiplicativo.

- Aditivo: $Y_t = T + C + E + I$; utilizado cuando los componentes son independientes entre sí o cuando se presentan valores negativos o ceros en la serie.
- Multiplicativo: $Y_t = T \times C \times E \times I$; utilizado cuando los componentes son dependientes entre sí o cuando el nivel de las series es muy cambiante.

¿Cuándo se utiliza una relación multiplicativa o una aditiva?

Intuitivamente, si se observa que la amplitud del componente estacional varía en forma proporcional al nivel medio de la tendencia anual, el modelo apropiado será el multiplicativo, ya que ante aumentos en la tendencia (T), la relación tendencia-estacionalidad (T*E) producirá valores mayores. Por otra parte, si el componente estacional permanece constante aún cuando existan cambios en el nivel de la tendencia, el modelo apropiado será el aditivo, ya que esto evidencia que la estacionalidad es independiente de la tendencia. Sin embargo, hay que mencionar que los métodos ponen restricciones en sí mismos, por ejemplo, uno multiplicativo no puede emplearse en datos que contengan ceros, en cuyo caso será necesario usar un modelo aditivo.

¿Para qué factores de estacionalidad?

La principal razón por la que interesa identificar el fenómeno estacional en una serie de tiempo, es para eliminarlo de la serie mediante un proceso conocido como desestacionalización. Esto permite hacer comparaciones de un mes con respecto a otro, aislando la variación que introduciría la presencia de la estacionalidad, lo que permite observar el crecimiento (o disminución) del nivel de la serie. Se ha estimado que aproximadamente un 70% de la variación que se observa al comparar dos cifras se debe a la estacionalidad.

Más aún, una serie desestacionalizada se compone de la tendencia, ciclo y del componente irregular ($T \times C \times I$); de ahí que el trabajar con tendencias es un paso adicional que incorpora la eliminación del componente estacional, el irregular y el ciclo.

B) Métodos de ajuste estacional

En la actualidad existen dos mecanismos para descomponer una serie de tiempo, aquellos basados en promedios móviles y los basados en modelos ARIMA.

Los métodos basados en promedios móviles fueron introducidos por Shiskin en 1967, quién pasó de métodos determinísticos al uso de filtros *ad hoc*, implementados en el programa X11 desarrollado por el *US Bureau of the Census*. El algoritmo X11 sufrió mejoras muy importantes como las introducidas por Estela Bee Dagum, en el año 1980, del *Statistics Canada*, quién desarrolló la versión X11-ARIMA, que calcula pronósticos (obtenidos con modelos ARIMA) para centrar los promedios al final de la serie. Posteriormente, en 1998 el *US Bureau of Census* introdujo el X12-ARIMA que significó una mejora muy importante para el manejo de variables de regresión.

Los métodos basados en modelos ARIMA fue introducidos en 1997 por Agustín Maraval y Víctor Gómez, mediante el programa denominado Tramo&Seats. Este mecanismo sustituye los filtros *ad hoc* por modelos estocásticos que permiten estimar por separado la tendencia y los movimientos estacionales, añadiendo dos importantes ventajas: la posibilidad de calcular un error estándar asociado a la estimación y la posibilidad de calcular pronósticos de cada uno de estos componentes (Maravall, 1999). En diciembre 2014 se divulgó una versión denominada TSW+, que tiene mejoras en el procedimiento de identificación del modelo ARIMA.

Ambos mecanismos representados por los paquetes estadísticos X12-ARIMA y Tramo&Seats son los más utilizados en la actualidad; ambos responden a recomendaciones internacionales para su uso y son aceptados como válidos.

En julio de 2012 el *US Census Bureau* en alianza con el Banco de España introdujo el X-13ARIMA-SEATS, una fusión del X12-ARIMA con el módulo SEATS del TSW. En esta fusión el usuario podrá elegir el uso de la rutina X11 o el procedimiento de SEATS para efectuar el ajuste estacional. Para quienes opten por la utilización del algoritmo X11, los resultados serán idénticos a los obtenidos con el X-12-ARIMA.

C) Recomendaciones internacionales de ajuste estacional

Tal como lo señala el Manual de CNT (2001), en la página 146, “*No existe una solución única para realizar el ajuste estacional*”. El analista debe estar atento a los nuevos desarrollos estadísticos, informáticos y metodológicos para evaluar el procedimiento que resulte mejor para sus datos. No hay procedimientos únicos; tanto el X11 como SEATS han demostrado ser procedimientos mundialmente aceptados aun cuando difieren en su conceptualización y en sus resultados.

En el proceso de construcción de indicadores adelantados de la OECD (2012) documenta los procedimientos estadísticos utilizados, y señala que el ajuste estacional de las series se realiza utilizando alguno de los métodos contenidos en X12 o en TRAMO&SEATS. Para identificar los valores extremos que afectan a las series, utilizan el módulo TRAMO. Esta rutina permite identificar: (i) *additive outliers*, causados por shocks temporales; (ii) *transitory changes*, causados también por shocks temporales pero cuando las observaciones retornan a la normalidad luego de varios periodos; (iii) *level shift*, consecuencia de shocks permanentes.

La Eurostat, en el ESS *guidelines on seasonal adjustment* (2015), recomienda el uso de los métodos de extracción de señales basados en modelos ARIMA y/o los métodos semiparamétricos basados en promedios móviles. La escogencia debe considerar investigaciones estadísticas y prácticas pasadas.

El FMI divulgó en 2013 los principales cambios en el Nuevo manual de Cuentas Nacionales Trimestrales (*Update of the Quarterly National Accounts Manual: An Outline, 2013*), entre los que señala:

- a) En el capítulo 7 de ajuste estacional se recomendará el uso de la modelación RegARIMA para la fase de preajuste, para determinar y ajustar cualquier efecto determinístico (incluido los efectos del calendario) previo a la aplicación de los filtros de ajuste estacional.
- b) El nuevo manual ilustrará el uso del X13-ARIMA-SEATS divulgado por el *US Census Bureau* en julio de 2012. La disponibilidad del X11 y de SEATS en un

programa común representa una gran ventaja para los compiladores, pues facilita la comparación de ambos métodos y decidir cuál ajusta de mejor forma las características de la serie.

Las recomendaciones internacionales sobre el ajuste estacional avalan el uso de los algoritmos contenidos en los paquetes Tramo&Seats, X12-ARIMA y X13-ARIMA-SEATS. Estos paquetes son gratuitos y tienen el respaldo de instituciones públicas.

Los modelos ARIMA univariantes descritos en este capítulo, incluyendo las variables de intervención adecuadas, resultan de mucha utilidad para el pronóstico de series de tiempo. Son además utilizados para descomponer las series en sus componentes: tendencia, estacionalidad, ciclo e irregular. Las pruebas de integración descritas, son una herramienta para formalizar la comprobación del supuesto de estacionariedad, el cual también se puede abordar mediante el análisis del correlograma y gráfico de la serie bajo análisis.

CAPÍTULO II: DESCRIPCIÓN DE LAS SERIES ANALIZADAS

2.1. Introducción

En este capítulo se realiza una descripción de las series que serán analizadas en este documento. Se describe cada serie de precios al consumidor del grupo alimentos y cada indicador de corto plazo de la producción agropecuaria. Se mencionan las fuentes primarias de datos, los años base, el periodo de datos disponible para cada serie, así como cualquier otro hecho relevante que deba ser conocido para lograr una buena comprensión de las series bajo análisis. Adicionalmente se describe el proceso de construcción de los indicadores regionales, tanto para el índice de precios al consumidor de alimentos como para la variable de producción agropecuaria.

2.2. Recolección de los datos

La información de las variables macroeconómicas utilizadas en este documento proviene de la base de datos de la Secretaría Ejecutiva del Consejo Monetario Centroamericano. Adicionalmente, la información fue verificada con la fuente primaria que las produce, la cual es oficial y de dominio público. Se compilaron series mensuales para el periodo más largo en el que están disponibles con fecha de corte a octubre de 2015.

Para la mayoría de los países incluidos en este informe, se compiló la serie mensual del índice de precios para el grupo de gasto de las familias en alimentos, denominado “Alimentos y bebidas no alcohólicas”. En el caso de Panamá, la serie es muy corta, inicia en octubre de 2014, razón por la que se tuvo que empalmar con la serie anterior que contiene el gasto de las familias en “Alimentos y bebidas”.

Adicionalmente se compiló la serie mensual de producción agropecuaria para los países centroamericanos, con definiciones que difieren ligeramente de un país a otro. En Panamá, la serie mensual de la actividad agropecuaria no está disponible al público, por lo cual se utiliza el PIB trimestral agropecuario.

Con la información por país, se construyó un indicador regional para los precios y para la producción, generado como un promedio ponderado de los índices por país convertidos todos a una base común. En el caso de la producción agropecuaria, se excluye a Panamá del cálculo regional ya que la información no está disponible en forma mensual. Los detalles metodológicos de los indicadores regionales se exponen más adelante, en la sección 2.5 de este capítulo.

Con el fin de que los resultados presentados en este documento puedan ser reproducidos, en el Anexo 2 se adjuntan los datos base utilizados.

2.3. El índice de precios al consumidor del grupo alimentos

El índice de precios al consumidor del grupo “Alimentos y bebidas no alcohólicas” (IPCA) es el resultado de la recopilación mensual de los precios al detalle de una canasta de alimentos y bebidas. La canasta de alimentos se define en cada país conforme a los patrones de consumo de la población, basados en encuestas de Ingresos y Gastos a los hogares. En la tabla 2.1 se resumen las principales características del IPCA para cada país.

Se destacan las siguientes características para algunos países:

Costa Rica: en julio de 2015 el INEC publicó un nuevo IPC con junio de 2015 como periodo base. Se aumentó la cobertura geográfica en la captura de precios mensuales y se modificó la canasta de alimentos conforme los patrones de consumo reportados en la Encuesta de Ingresos y Gastos de 2012-2013. De tal modo que la serie actual inicia en 2015. Debido al escaso número de observaciones, el Banco Central de Costa Rica enlazó la serie anterior (base julio de 2006) con este nuevo índice y generó una serie enlazada para el periodo julio de 2006-setiembre de 2015. No obstante, se advierte que se utilizará una serie que en realidad obedece a dos definiciones diferentes, aspecto que se debe tomar en cuenta al momento de identificar y evaluar los modelos.

Tabla 2.1 Características de los de índices de precios de alimentos por país

<i>País</i>	<i>Nombre del grupo de bienes y servicios</i>	<i>Periodo base</i>	<i>Peso en el IPC global</i>	<i>Periodo de datos disponibles</i>	<i>Calculado por</i>
Costa Rica	Alimentos y bebidas no alcohólicas	Junio 2015	21.4	Julio 2006- setiembre 2015	Instituto Nacional de Estadística y Censos INEC
El Salvador	Alimentos y bebidas no alcohólicas	Diciembre 2009	26.3	Enero 2009- setiembre 2015	Dirección General de Estadística y Censos DIGESTIC
Guatemala	Alimentos y bebidas no alcohólicas	Diciembre 2010	28.8	Abril 2011- setiembre 2015	Instituto Nacional de Estadística INE
Honduras	Alimentos y bebidas no alcohólicas	Diciembre 1999	31.8	Enero 1991- setiembre 2015	Banco Central de Honduras
Nicaragua	Alimentos y bebidas no alcohólicas	2006	30.9	Enero 2001- setiembre 2015	Banco Central de Nicaragua
Panamá	Alimentos y bebidas	2013	22.4	Octubre 2002- setiembre 2015	Instituto Nacional de Estadística y Censos INEC

Fuente: Elaboración propia basada en las metodologías de los países.

Guatemala: la serie más reciente del IPC de Guatemala corresponde a la base diciembre de 2010. Esta serie inicia en abril de 2011 y no fue posible enlazarla con la serie anterior debido a que no se definió un factor de enlace. De tal modo que solo se dispone de una serie corta que inicia en abril de 2011.

Panamá: Panamá publicó a partir de octubre de 2014 un nuevo IPC con base 2013=100, dentro del cual se dispone del grupo de consumo en “alimentos y bebidas no alcohólicas”. La serie anterior cuya base es octubre 2002=100, está disponible para el periodo octubre 2002 a octubre 2014; dentro del cual se dispone del grupo “alimentos y bebidas”. Debido a que la serie con la base más

reciente resulta muy corta, se procedió a empalmar ambas series. No obstante, se advierte que la serie resultante debe ser utilizada con cautela ya que la canasta de productos es diferente en ambas series.

En todos los países las series de índices de precios al consumidor tienen una fuerte tendencia positiva y un componente estacional que luce menos importante, según se aprecia en el Gráfico 2.1. En términos generales se observa un incremento en el nivel del IPC de alimentos en 2014 y una disminución hacia la segunda mitad de 2015.

Con frecuencia las tasas de variación que se derivan del IPC son las que resultan de interés para el seguimiento de la serie. Así por ejemplo, el pronóstico de la inflación (tasa interanual del IPC) a diciembre resulta fundamental para anticipar el cumplimiento de la meta del programa monetario. Si se analiza el IPC en tasas de variación, la forma y propiedades de esta nueva variable son diferentes a aquellas de la serie original. En el gráfico 2.2 se aprecia cómo la tendencia ya no es dominante y aparecen los ciclos de crecimiento.

Gráfico 2.1. Índices de precios al consumidor de Alimentos y Bebidas no Alcohóli, niveles 2011-2015

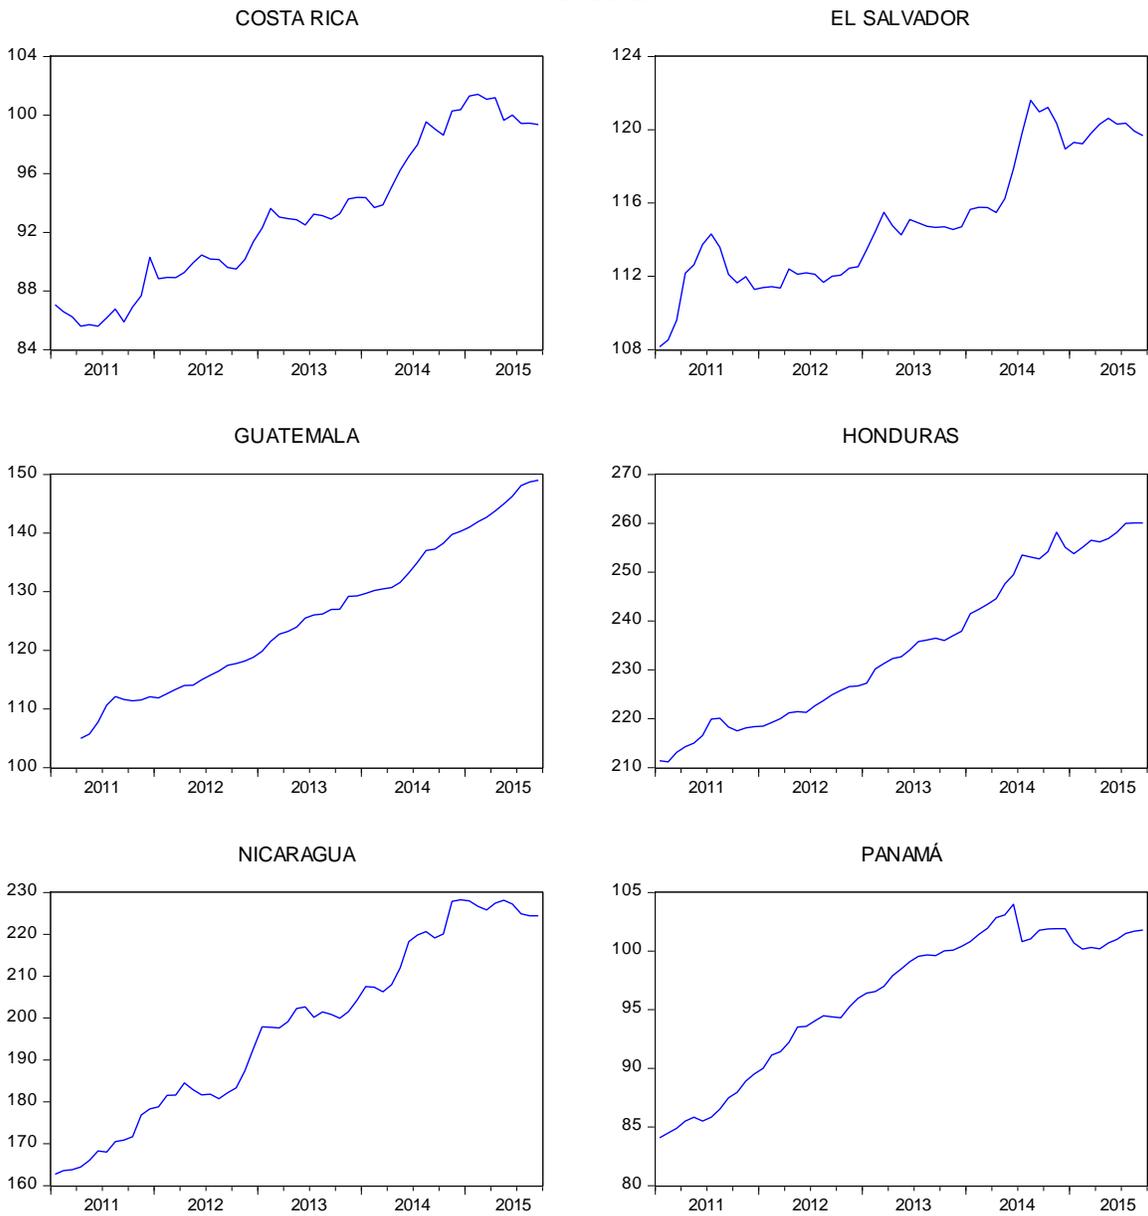
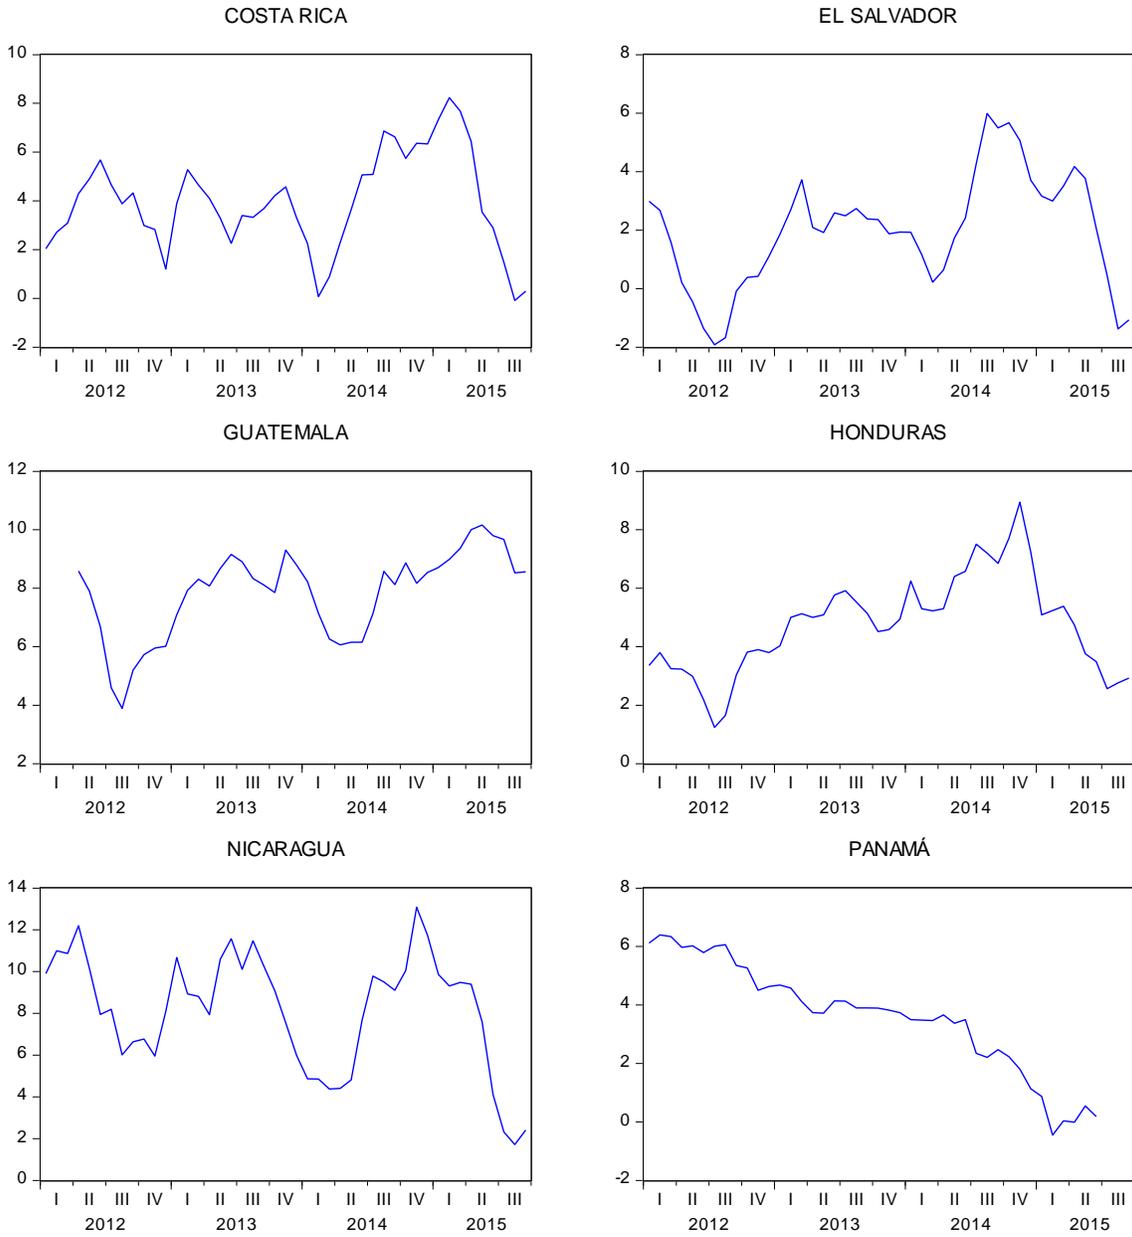


Gráfico 2.2 Tasas de variación interanuales del índices de precios al consumidor de Alimentos, 2011-2015



2.4. El indicador de corto plazo de la Actividad Agropecuaria

El Índice Mensual de la Actividad Económica (IMAE), elaborado por los bancos centrales de Centroamérica y por el INEC de Panamá, mide la evolución de las diferentes actividades económicas incluidas en el cálculo del Producto Interno Bruto. Es un indicador de coyuntura con disponibilidad mensual y un rezago corto para la obtención de sus datos, de aproximadamente 45 días, que permite extraer en forma frecuente señales relevantes del comportamiento de la actividad económica. No debe ser considerado como un sustituto del PIB anual o un indicador de su nivel, sino únicamente como un indicador de la tendencia y de las variaciones cíclicas seguida por la actividad económica.

El IMAE está dividido en actividades económicas conforme a las Cuentas Nacionales anuales y trimestrales. Para efectos de este estudio se seleccionó la actividad “Agropecuaria”, la cual se define de forma diferente para cada país. Las principales características de este indicador se resumen en la tabla 2.2.

En el caso de Panamá, aun cuando también dispone de un IMAE, no es posible obtener los índices específicos por cada categoría de actividad económica. Por esta razón, se utiliza el PIB trimestral de *Agricultura, ganadería, caza y silvicultura*, en medidas encadenadas de volumen, con año de referencia 2007.

A continuación se mencionan aspectos relevantes de algunos países:

Costa Rica: En Costa Rica el IMAE está en proceso de revisión metodológica en concordancia con el cambio de año base de las Cuentas Nacionales, que en diciembre de 2015 será publicado con el nuevo año base 2012.

El Salvador: corresponde al Índice de Volumen de la Actividad Económica (IVAE).

Tabla 2.2. Principales características de los indicadores de corto plazo de Producción de la Actividad Agropecuaria^{1/}

País	Nombre de la Actividad Económica	Periodo base o de referencia	Peso en el IMAE global	Periodo de datos disponibles	Calculado por	Última revisión metodológica
Costa Rica	Agricultura, silvicultura y pesca	1991	0.134	Enero 1991- julio 2015	Banco Central de Costa Rica	1996 Base fija
El Salvador	Agricultura, Caza, Silvicultura y Pesca	1990	0.165	Enero 1990- julio 2015	Banco Central de Reserva de El Salvador	Septiembre 2008 Base fija
Guatemala	Agricultura, ganadería, caza, silvicultura y pesca	2001	0.111	Enero 2001- junio 2015	Banco de Guatemala	Junio 2013 Base móvil
Honduras	Agricultura, Ganadería, Silvicultura y Pesca	2000	0.165	Enero 2000- julio 2015	Banco Central de Honduras	2007 Base fija
Nicaragua	Agricultura y pecuario ^{2/}	2006	0.175	Enero 2006- julio 2015	Banco Central de Nicaragua	Enero 2013 Base móvil
Panamá	Agricultura, ganadería, caza y silvicultura	2007	n.d.	I trimestre 2007- II trimestre 2015	Instituto Nacional de Estadística y Censos	Julio 2015 Base móvil

^{1/}Corresponde al IMAE en todos los países centroamericanos y al PIB trimestral en Panamá.

^{2/} Corresponde a un indicador compuesto construido para los efectos de este estudio. Agricultura tiene un peso de 0.092 y pecuario un 0.083, de modo que el indicador compuesto representa un 0.175.

Fuente: Metodologías de los países.

Guatemala: en junio de 2013 se presentó la serie del IMAE con periodo de referencia 2001, en concordancia con la revisión metodológica de las Cuentas Nacionales. El IMAE por ramas de actividad económica se divulga de forma trimestral, aun cuando los datos son mensuales. Esto es así porque se aplican

técnicas de *benchmarking* para ajustar las variaciones mensuales del IMAE al dato trimestral del PIB.

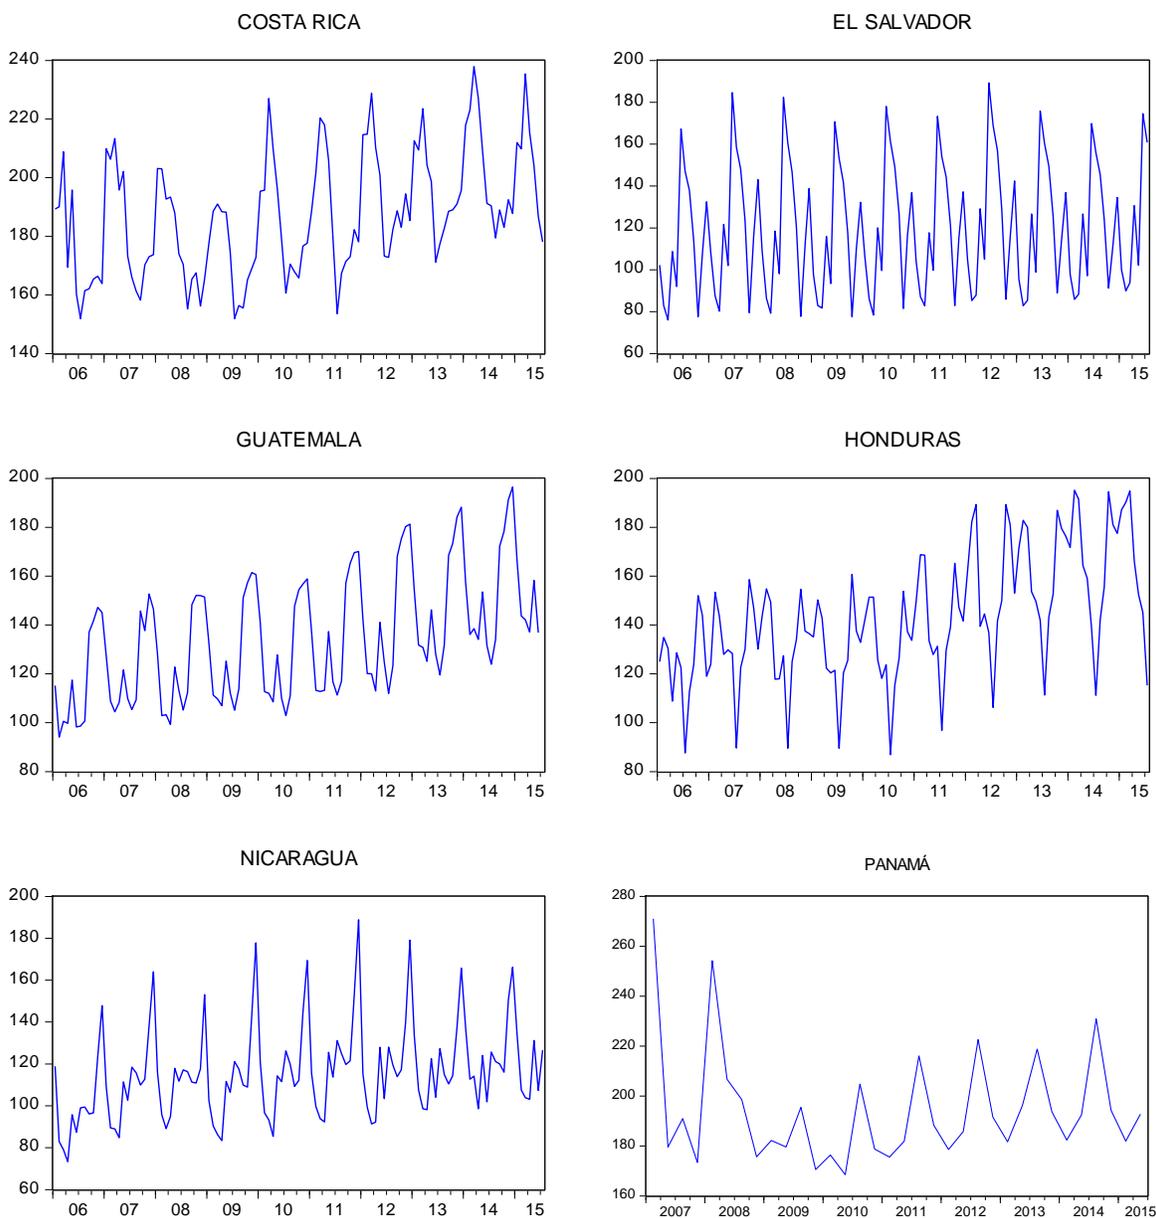
Nicaragua: en enero de 2013 se adecuó el IMAE al nuevo cálculo al sistema de cuentas nacionales, con año de referencia 2006. Con esta nueva metodología se divulga en forma separada índices para: “agricultura”, “pecuario” y “silvicultura, pesca y minas”. Para efectos de este estudio se combinaron los índices de agricultura y pecuario en un indicador que se denomina “agropecuario”, con el objetivo de representar las principales actividades agropecuarias y que de ese modo resulte comparable con los indicadores seleccionados para el resto de países. El grupo “silvicultura, pesca y minas” no se utiliza debido a la presencia del componente de minas, el cual podría tener un patrón estacional diferente a las actividades que interesan en este estudio.

Panamá: debido a la limitante de no disponer de la apertura del IMAE por actividades productivas, y por consiguiente del sector agropecuario, se utiliza el PIB trimestral a precios constantes, con año de referencia el 2007.

Como se aprecia en el Gráfico 2.3, en todos los países la actividad agropecuaria está fuertemente dominada por la parte estacional y en menor medida por el componente de tendencia.

Para la divulgación de los datos de la actividad agropecuaria, los países recurren al análisis de series de tiempo para extraer una señal que resulte clara para el lector. De este modo, adicional a la serie original, algunos países divulgan la serie desestacionalizada y la tendencia-ciclo. En la tabla 2.3 se resumen los criterios de divulgación de datos por país.

Gráfico 2.3. Índices de producción de la Actividad Agropecuaria^{1/},
Niveles 2006-2015



^{1/} Corresponde al IMAE para los países de Centroamérica y al PIB trimestral para Panamá.

Tabla 2.3. Resumen criterios de divulgación del indicador de corto plazo del sector Agropecuario

SERIE	COSTA RICA	EL SALVADOR	GUATEMALA	HONDURAS	NICARAGUA	PANAMÁ ^{2/}
SERIE ORIGINAL	variación interanual y variación promedio de lo que va del año	variación interanual	variación interanual	variación acumulada de lo que va del año	variación interanual y variación promedio 12 meses ^{1/}	variación interanual y variación acumulada en lo que va del año
SERIE DESESTACIONALIZADA	no	no	variación mensual	no	variación mensual, variación interanual y variación promedio 12 meses	no
SERIE TENDENCIA-CICLO	variación interanual y variación promedio de lo que va del año	variación interanual	variación interanual	no	variación interanual y variación promedio 12 meses ^{1/}	no
MÉTODO	TSW	TSW	X12-ARIMA	X-13ARIMA-SEATS	X-13ARIMA-SEATS	X12-ARIMA

1/ Promedio de las tasas de variación interanual de los últimos 12 meses.

2/ Corresponde al PIB trimestral del sector agropecuario.

Fuente: elaboración propia basado en los informes y cifras publicados en las páginas web de cada país.

2.5. Cálculos regionales

El análisis de la actividad agropecuaria y de los precios de alimentos que se realiza para cada país, se complementa con el cálculo de un indicador regional que permita resumir el comportamiento de la región en un solo indicador. Este indicador corresponde al promedio ponderado de los índices de cada país, todos ellos convertidos a una base común, con detalles que se brindan a continuación.

A) Ponderadores para cada país

Para determinar el ponderador que se asigna a cada país, se ha considerado aquel que permita medir la importancia de cada economía dentro de la región. Para ello se ha utilizado el Ingreso Nacional Bruto (INB) por Paridad del Poder Adquisitivo (PPA), que publica anualmente el Banco Mundial en forma gratuita.

Señala la página web del Banco Mundial¹⁴ que “El INB por paridad del poder adquisitivo (anteriormente PIB por PPA) es el ingreso nacional bruto convertido a dólares internacionales utilizando las tasas de paridad del poder adquisitivo. Un dólar internacional tiene el mismo poder adquisitivo sobre el INB que el que posee el dólar de los Estados Unidos en ese país. El ingreso nacional bruto (INB) es la suma del valor agregado por todos los productores residentes más todos los impuestos a los productos (menos los subsidios) no incluidos en la valuación del producto más las entradas netas de ingreso primario (remuneración de empleados e ingreso por propiedad) del exterior. Los datos se expresan en dólares internacionales corrientes”.

Ya que se dispone de una medición del INB para todos los años, los ponderadores se actualizan una vez al año, de tal modo que los pesos no son fijos para el periodo de análisis, sino que se dispone de ponderadores diferentes para cada año.

Para el año actual (2015 en este estudio) se utilizan los mismos ponderadores del año anterior (2014) hasta tanto el Banco Mundial divulgue el INB del presente año. Así por ejemplo, para el 2014 los ponderadores que se utilizan en este estudio son los que se muestran en la tabla 2.4. La serie completa de los ponderadores utilizados en este estudio se puede consultar en el anexo 3.

¹⁴ <http://datos.bancomundial.org/indicador/NY.GNP.MKTP.PP.CD>

Tabla 2.4. Ponderadores para el año 2014

País	INB por PPA (en billones US\$) en 2014	Ponderadores para CA	Ponderadores para CA y Panamá
Costa Rica	68.63	0.232	0.184
El Salvador	49.26	0.166	0.132
Guatemala	115.19	0.389	0.309
Honduras	34.00	0.115	0.091
Nicaragua	28.81	0.097	0.077
Panamá	77.08		0.207
Total	372.97	1.000	1.000

Fuente: elaboración propia a partir de los datos del INB del Banco Mundial (<http://datos.bancomundial.org/indicador/NY.GNP.MKTP.PP.CD>).

B) Índice regional de Precios de Alimentos

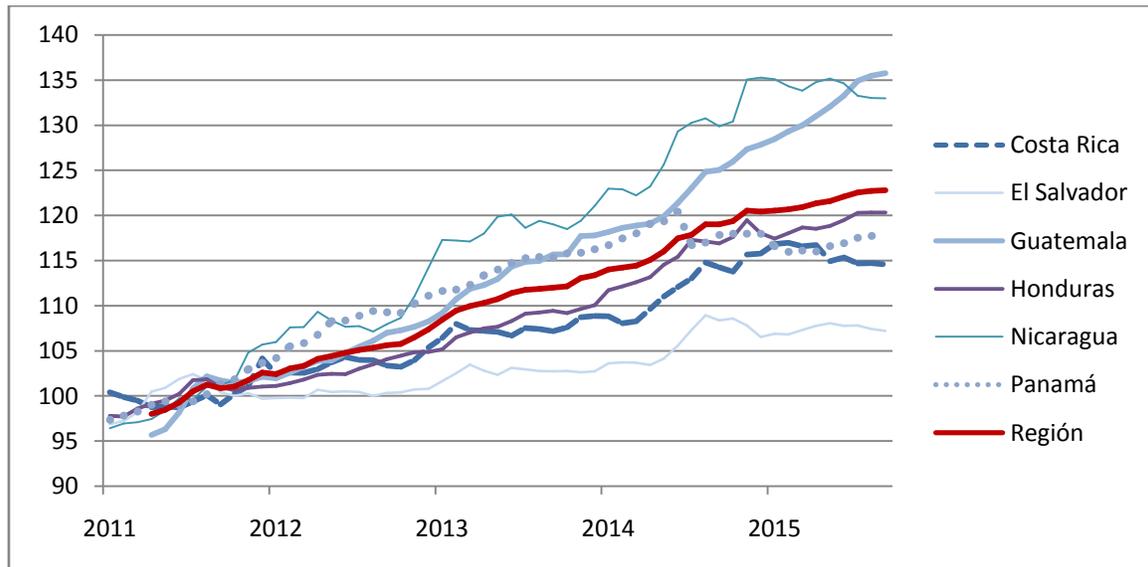
Para la elaboración de un índice de precios de alimentos regional se calcula un promedio ponderado de los niveles de los índices, utilizando como ponderadores el peso de cada economía, según se explica en la sección anterior. Previamente los índices por país han sido transformados a una base común 2011=100.

La utilización de este año base lo impone la serie más corta que corresponde al IPC de Guatemala, que inicia en abril de 2011. El cambio metodológico en ese país fue tan significativo que no fue posible realizar un empalme con los datos de la base anterior. Esto impone una restricción importante pues la serie resulta más corta de lo recomendado en la literatura, que son 5 años completos.

Es importante mencionar que el indicador regional no está armonizado, es decir, no se cuenta con una canasta común de alimentos para todos los países de la región que pueda dar como resultado un índice regional estandarizado. En el cálculo regional intervienen los IPC de la canasta de alimentos que cada país ha definido según los estudios base. No obstante, los IPC de alimentos así calculados, son un reflejo de la evolución de los precios de un grupo de bienes claves en la medición de la inflación de cada país.

El índice regional que se muestra en el gráfico 2.4, está dominado por los movimientos de los precios de Guatemala y en menor medida por Panamá y Costa Rica, países que tienen el mayor peso en este índice.

Gráfico 2.4. Índice regional y por país de precios de Alimentos, 2011-2015



C) Índice regional de producción agropecuaria

Para la elaboración de este índice se consideran únicamente los datos de los cinco países centroamericanos ya que no está disponible un indicador de la actividad agropecuaria para Panamá con periodicidad mensual. Se elabora un promedio ponderado de los niveles de los índices utilizando como ponderadores los descritos en la sección A). Previamente los índices por país han sido transformados a una base común, que en el caso del IMAE es 2006=100.

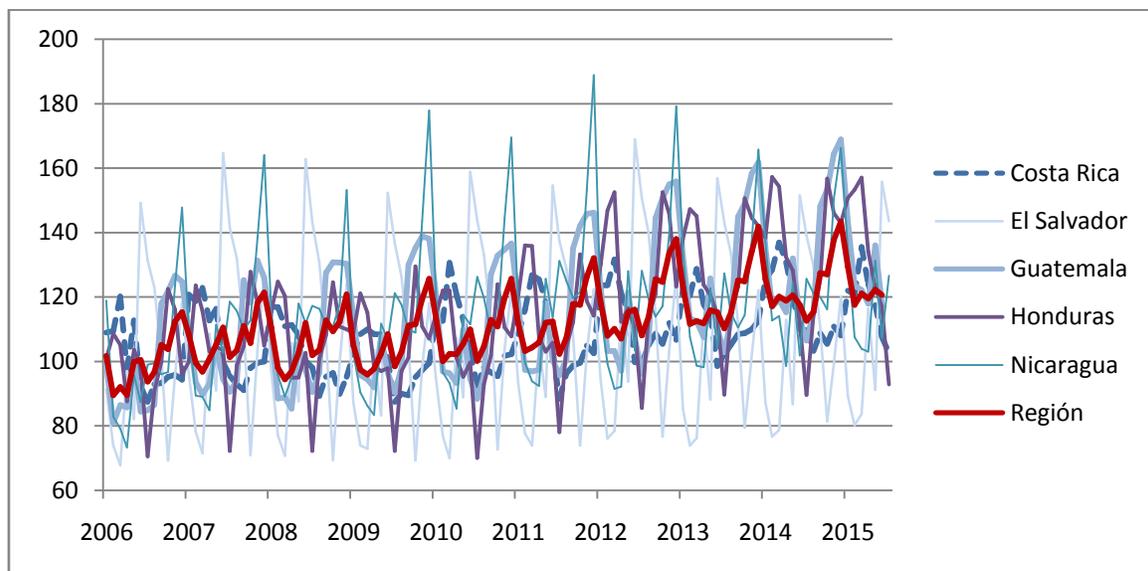
Se seleccionó el 2006 por ser el periodo en que inicia la serie más corta que corresponde al IMAE de Nicaragua. Con este año base, se disponen de más de 9 años de información mensual, longitud que resulta suficiente para un análisis de series de tiempo.

Es importante mencionar que el indicador regional no es un índice armonizado, es decir, no corresponde a una medición regional de las mismas actividades agropecuarias en cada

uno de los países. Al contrario, cada país define las actividades que se miden en el sector agropecuario y esa definición se adopta en este estudio.

El agregado regional, tal como se observa en el gráfico 2.5, es un indicador que está mayormente influenciado por los resultados de Guatemala y de Costa Rica, países que tienen el mayor peso en este índice.

Gráfico 2.5. Índice regional y por país de producción de la Actividad Agropecuaria^{1/}, niveles, 2006-2015



^{1/} No incluye a Panamá en el cálculo regional.

2.6. Paquetes estadísticos para el análisis de los datos

Para el análisis de los datos se utilizan dos paquetes estadísticos:

- **EViews:** Este paquete permite realizar un análisis inicial de los datos, análisis descriptivo y pruebas de raíces unitarias. Representa una buena herramienta para seleccionar el modelo ARIMA adecuado para cada serie. No se utiliza en el proceso

de estimación del modelo final debido a que no tiene facilidades para el análisis de variables de calendario, las cuales sí están presentes en TSW+.

- **TSW+** *Tramo and Seats for Windows*, versión diciembre de 2014: Este paquete tiene un algoritmo que permite ajustar en forma automática modelos ARIMA univariantes. También permite la especificación de modelos por parte del usuario así como una batería de pruebas estadísticas que permiten su evaluación. Incluye facilidades para la inclusión de variables de intervención, en especial las referidas a efectos del calendario. Adicionalmente permite estimar los componentes de las series de tiempo: tendencia, ciclo, estacional e irregular. Estos componentes se estiman mediante modelos ARIMA lo que permite obtener pronósticos de cada componente y el cálculo de los errores estándares asociados a la estimación.

Aun cuando este mecanismo se puede ejecutar desde el X-13ARIMA-SEATS, tal como se comentó en la sección 1.5 del capítulo 1, se opta por el uso de **TSW+** por las facilidades en su utilización.

En este capítulo se describieron las características más importantes de las series utilizadas en este estudio, destacando hechos relevantes por país. Se analizaron gráficamente las características básicas de las series, en particular la presencia de tendencia y estacionalidad, además de la presencia de valores atípicos. Se describió con detalle el proceso de cálculo de los indicadores regionales y se establece el uso de EViews y TSW+ como herramientas de análisis de datos.

CAPÍTULO III: ORDEN DE INTEGRACIÓN Y MODELOS ARIMA

3.1. Introducción

En este capítulo se describen los modelos ARIMA que fueron identificados para cada una de las series de producción agropecuaria y del índice de precios de alimentos, tanto a nivel de cada país como para el agregado regional. Se realiza un resumen de los principales hallazgos, se justifica cada modelo seleccionado y se describe la ecuación resultante. Como complemento, en los anexos 6 y 9 se incluye el detalle del ajuste de cada modelo, tomando los principales resultados que arroja TSW+. Adicionalmente, se incluye una sección de análisis previo, donde se resumen los resultados de las pruebas de integración y una prueba de igualdad de variancias. Este análisis es fundamental para validar el cumplimiento del supuesto de estacionariedad en las series. El detalle de estos resultados se incluye en los anexos 4, 5, 7, y 8.

3.2. Análisis previo

A) Variables de IPC de alimentos

Como parte del análisis previo se graficaron las series en sus niveles originales y se generaron los correlogramas simple y parcial de la serie original. Estas dos herramientas son muy útiles para analizar las propiedades de las series y su orden de integración. En el caso que las series no sean estacionarias, se procedió a graficar la serie diferenciada y su correspondiente correlograma. Estos cálculos fueron realizados en EViews, cuyo detalle se incluye en el anexo 4. Se observa como las series del IPC están dominadas por el componente tendencia, mientras que el componente estacional no se observa ni en el gráfico lineal ni en las correlaciones múltiples de 12.

Es interesante conocer que las series de precios al consumidor de alimentos no están caracterizadas por la presencia de estacionalidad, aun cuando los productos agrícolas sí lo están. Esto sugiere que en el agregado de precios de la canasta de alimentos y bebidas, el componente estacional que tengan algunos productos se diluye a causa de otros productos que no tienen estacionalidad. Habría también que investigar si algunos productos alimenticios están sujetos a regulación de precios en algunos países. Esto haría que aunque la producción sea estacional, el precio no lo es.

Tabla 3.1. Resultados de las pruebas Dickey-Fuller Aumentado del IPC de alimentos
Ho: la serie es I(1)

Variables por país	Parámetros determinísticos	t-Statistic DFA	Prob	Orden de integración resultante
COSTA RICA				
IPC CR	C y T	-1.948461	0.6223	I(1)
IPC CR diferenciada	ninguna	-6.003875	0.0000	I(0)
EL SALVADOR				
IPC SV	C y T	-3.081956	0.1178	I(1)
IPC SV diferenciada	ninguna	-6.285016	0.0000	I(0)
GUATEMALA				
IPC GT	C y T	-1.244537	0.8905	I(1)
IPC GT diferenciada	ninguna	-2.631248	0.0095	I(0)
HONDURAS				
IPC HN	C y T	-2.891291	0.1678	I(1)
IPC HN diferenciada	ninguna	-3.137961	0.0018	I(0)
NICARAGUA				
IPC NI	C y T	-2.717249	0.2310	I(1)
IPC NI diferenciada	ninguna	-7.619822	0.0000	I(0)
PANAMÁ				
IPC PA	C y T	-1.971116	0.6119	I(1)
IPC PA diferenciada	ninguna	-1.975626	0.0464	I(0)
REGIONAL				
IPC RE	C y T	-2.001539	0.5870	I(1)
IPC RE diferenciada	ninguna	2.355683	0.0192	I(0)

Fuente: elaboración propia.

Adicionalmente, se aplicaron las pruebas de integración de Dickey Fuller aumentado, tomando en consideración las variables determinísticas que resultan plausibles para cada serie. En la tabla 3.1 se resumen los resultados de las pruebas, y el detalle se presenta en el anexo 5. Este procedimiento fue también realizado con EViews. En todos los casos se determinó que las series no son estacionarias, pero que la estacionariedad se logra con la aplicación de una diferenciación.

Adicionalmente, se realizó un análisis exploratorio de la dispersión de los datos que sirviera de complemento al análisis visual del gráfico, mediante una prueba de igualdad de variancias, dividiendo el periodo bajo estudio en dos submuestras. Solamente el IPC de alimentos de Nicaragua muestra una variancia constante, mientras que el resto de las series sugieren la necesidad de una transformación de los datos. Los resultados se resumen en la tabla 3.2.

Tabla 3.2: Pruebas de igualdad de variancias del IPC de alimentos

H₀: variancias en ambos grupos son iguales

H₁: variancias en ambos grupos son diferentes

País	Grados de libertad	Valor F	Prob.	Significancia	Resultado
Costa Rica	F(23,32)	3.058743	0.0037	**	Variancias diferentes
El Salvador	F(23,32)	3.624862	0.0009	**	Variancias diferentes
Guatemala	F(59,53)	5.217628	0.0000	**	Variancias diferentes
Honduras	F(23,32)	5.722197	0.0000	**	Variancias diferentes
Nicaragua	F(23,32)	1.844262	0.1087	NS	Variancias iguales
Panamá	F(23,32)	5.012111	0.0002	**	Variancias diferentes
Región	F(20,32)	2.995776	0.0055	**	Variancias diferentes

Fuente: elaboración propia.

B) Variables de producción agropecuaria

También para las variables que miden la producción agropecuaria se graficaron las series en sus niveles originales y se generaron los correlogramas de la serie original. Estas dos herramientas son muy útiles para analizar las propiedades de las series y su orden de integración. El detalle de estos gráficos se incluye en el anexo 7. En todos los países estas series se caracterizan por un componente estacional bien definido, además de una tendencia con pendientes de distintos ángulos. En los gráficos lineales se observan patrones que se repiten de un año a otro y en los correlogramas se observan correlaciones muy fuertes en el rezagos 12.

Adicionalmente, se aplicaron las pruebas de integración de Dickey Fuller aumentado, tomando en consideración las variables determinísticas que resultan plausibles para cada serie. En la tabla 3.3 se resumen los resultados de las pruebas y el detalle se presenta en el anexo 6. En la mayoría de los casos las series no son estacionarias; la excepción se presenta con la serie de producción agropecuaria de Nicaragua y Panamá que parecen ser $I(0)$. No obstante, la diferenciación estacional se requiere en todas las series, debido a la presencia de un fuerte componente estacional.

Adicionalmente, en la tabla 3.4 se muestran los resultados de una prueba F de igualdad de variancias, $H_0: \sigma_1^2 = \sigma_2^2$, dividiendo el periodo de datos en dos secciones. En las series mensuales se dividió en los periodos que van de enero 2006 a diciembre 2010 y de enero 2011 a julio de 2015. En la serie del PIB trimestral de Panamá los periodos van del I trimestre de 2007 al IV trimestre de 2010 y del I trimestre de 2011 al II trimestre de 2015. Esta prueba indica que la variancia es homogénea en la mayoría de países, excepto en las series de Honduras y en Panamá, donde se prevé la necesidad de una transformación en los datos.

Dentro del análisis previo es importante incluir la inspección visual de la serie para determinar la presencia de posibles shocks producto de fenómenos externos. Esta

inspección se debe acompañar del criterio de experto, consultando a los especialistas del área en cada país, para tener una explicación a cada uno de estos fenómenos. Esta explicación es conveniente para la definición adecuada de la variable artificial que se deba construir. No obstante, en este documento la identificación de puntos extremos y la construcción de las variables artificiales de intervención están basadas únicamente en criterios estadísticos.

*Tabla 3.3. Resultados de las pruebas Dickey-Fuller Aumentado de la producción agropecuaria
Ho: la serie es I(1)*

Variables por país	Parámetros determinísticos	t-Statistic DFA	Prob	Orden de integración resultante
COSTA RICA				
IMAE CR	C y T	-2.036076	0.5745	I(1)
IMAE CR diferenciada	ninguna	-4.391748	0.0000	I(0)
EL SALVADOR				
IMAE SV	C	-2.643480	0.0877	I(1)
IMAE SV diferenciada	ninguna	-3.876525	0.0002	I(0)
GUATEMALA				
IMAE GT	ninguna	-1.230591	0.8984	I(1)
IMAE GT diferenciada	ninguna	-2.559230	0.0108	I(0)
HONDURAS				
IMAE HN	ninguna	-0.964499	0.9436	I(1)
IMAE HN diferenciada	ninguna	-3.198668	0.0016	I(0)
NICARAGUA				
IMAE NI	C y T	-3.474234	0.0476	I(0)
PANAMÁ				
PIB trimestral PA	C y T	-4.533370	0.0071	I(0)
REGIONAL				
IMAE RE	C y T	-1.537199	0.8102	I(1)
IMAE RE diferenciada	ninguna	-2.301674	0.0213	I(0)

Fuente: elaboración propia.

Tabla 3.4: Pruebas de igualdad de variancias de la producción agropecuaria

H_0 : variancias en ambos grupos son iguales
 H_1 : variancias en ambos grupos son diferentes

País	Grados de libertad	Valor F	Prob.	Significancia	Resultado
Costa Rica	F(59,54)	1.107768	0.7052	NS	Variancias iguales
El Salvador	F(54,59)	1.022164	0.9316	NS	Variancias iguales
Guatemala	F(59,53)	1.369697	0.2462	NS	Variancias iguales
Honduras	F(59,54)	1.995526	0.0110	**	Variancias diferentes
Nicaragua	F(54,59)	1.079363	0.7722	NS	Variancias iguales
Panamá	F(17,15)	3.225352	0.0274	**	Variancias diferentes
Región	F(59,53)	1.307132	0.3233	NS	Variancias iguales

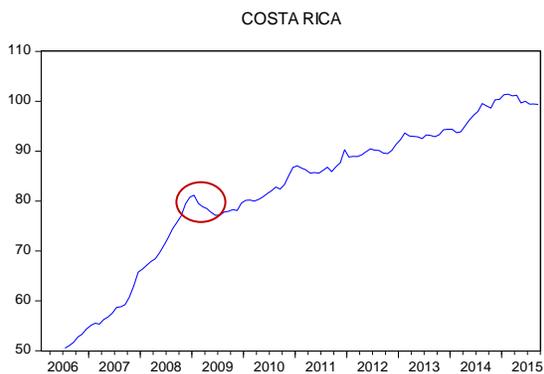
Fuente: elaboración propia.

3.3. Modelos ARIMA para el IPC del grupo alimentos

A) Modelo ARIMA para el IPC de alimentos de Costa Rica

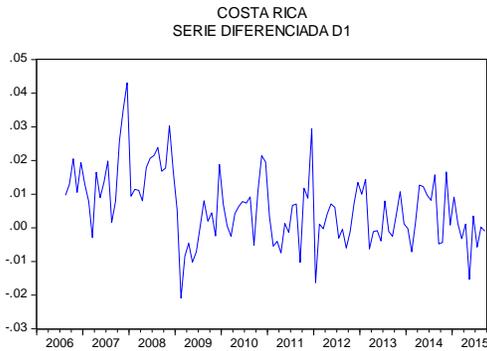
a) Estacionariedad

Gráfico 3.1: IPC alimentos de CR



La serie del IPC de alimentos para Costa Rica no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es I(1), es decir, se requiere una diferenciación para lograr estacionariedad en la media. Esto se complementa con el análisis visual del gráfico 3.1 y con el comportamiento del correlograma

Gráfico 3.2. Primera diferencia
IPC alimentos de CR

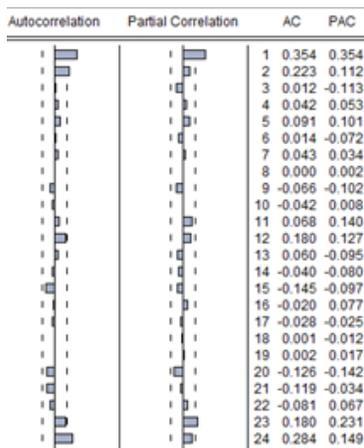


condiciones de estacionariedad es aquella con una diferencia y transformación logarítmica.

De la inspección visual de la serie se observan varios valores atípicos que podrían requerir de algún tipo de ajuste, de los cuales sobresale una fuerte caída del IPC a inicios del 2009.

b) Identificación del modelo

Gráfico 3.3: correlograma IPC alimentos de CR diferenciada



Comparando el correlograma de la serie transformada (Gráfico 3.3) con los patrones teóricos (Anexo 1), se concluye que es necesario incorporar un parámetro tipo AR en la parte regular, que recoja la autocorrelación entre observaciones adyacentes. Adicionalmente, debido a que la correlación de orden 12 está muy cerca de la banda de confianza es conveniente la inclusión de un parámetro estacional, el cual puede ser de tipo MA(12) o AR(12). Conforme lo anterior, los modelos propuestos son ARIMA

(110) (001) y ARIMA (110) (100).

de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que hay diferencias significativas en la dispersión de los datos (prob=0.0037), lo que sugiere la necesidad de una transformación logarítmica.

Por consiguiente, la serie que cumple con las

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (110)(100), cuyos principales estadísticos se resumen en la tabla 3.5. La formulación es la siguiente¹⁵:

$$(1 - \phi B)(1 - \phi_2 B^{12})(1 - B)IPCACR = C + w_1 Dummy1 + \frac{\omega 2}{(1 - \delta B)} Dummy2 + a_t \quad (1)$$

Este modelo se ajustó con los datos comprendidos en el periodo julio de 2006 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA. Se agregaron dos variables binarias tipo aditivo¹⁶ que recogen el impacto de fenómenos externos en los siguientes meses:

- Enero 2009: el nivel de la serie aumentó 1.26% y en meses posteriores el efecto fue disminuyendo hasta que la serie regresa a los niveles “normales”.
- Noviembre 2011: el nivel de la serie disminuyó 1.39%;

Es importante mencionar que conviene analizar estos valores extremos con los especialistas del área en cada país, para obtener una explicación a cada uno de estos fenómenos. Una explicación es conveniente para la definición adecuada de la variable artificial que se deba construir. En este documento, la construcción de estas variables está basada únicamente en criterios estadísticos. También es importante mencionar que estas variables de intervención no fueron identificadas en forma automática por el módulo Tramo de TSW+, sino que son el resultado de un análisis minucioso de la serie.

Tabla 3.5: Principales resultados modelo ARIMA para el IPCA de CR

Parámetros	valor	Error estándar	t-value
Parámetros estocásticos			
PH1	-0.49455	0.83388E-01	-5.93
BPH	-0.26869	0.92414E-01	-2.91
Parámetros determinísticos			
Constante	0.61684E-02	0.00220	2.80
(31) TC (1 2009)	0.12558E-01	(0.00675)	1.86
(65) AO (11 2011)	-0.13893E-01	(0.00464)	-3.00

¹⁵ El valor de δ lo asigna automáticamente TSW+ en 0.7.

¹⁶ Una variable binaria se define como un vector de ceros y un uno en el momento t donde el fenómeno tiene efecto sobre la serie Yt. El coeficiente de esta variable (w_i) recoge la magnitud de la discrepancia entre el valor observado y el estimado en la observación t. Este efecto se considera aditivo cuando modifica el nivel de la serie en una sola observación o cuando afecta varias observaciones pero en magnitudes diferentes.

d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 0.895%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de estacionariedad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=0.27). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=-0.63$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la $\text{Prob}(Q_{12})=0.97$, $\text{Prob}(Q_{24})=0.96$ y $\text{Prob}(Q_{36})=0.52$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual. Los valores $\text{Prob}(Q_{12})=0.89$, $\text{Prob}(Q_{24})=0.91$ y $\text{Prob}(Q_{36})=0.30$ indican que no hay problema de heterocedasticidad.

Las pruebas para determinar la presencia de estacionalidad indican que hay estacionalidad en la serie y que es identificable; también señalan que no hay estacionalidad en los residuos. Este resultado es importante porque indica que el modelo en la parte estacional recoge adecuadamente este componente. Llama la atención que Costa Rica es el único país en que el IPC de alimentos tiene una estacionalidad significativa.

B) Modelo ARIMA para el IPC de alimentos de El Salvador

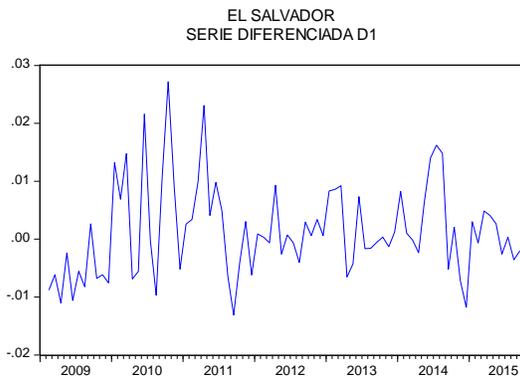
a) Estacionariedad

Gráfico 3.4: IPC alimentos de SV



La serie del IPC de alimentos para El Salvador no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad. Esto se complementa con el análisis visual del gráfico 3.4 y con el comportamiento del correlograma de la serie

Gráfico 3.5. Primera diferencia IPC alimentos de SV



original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

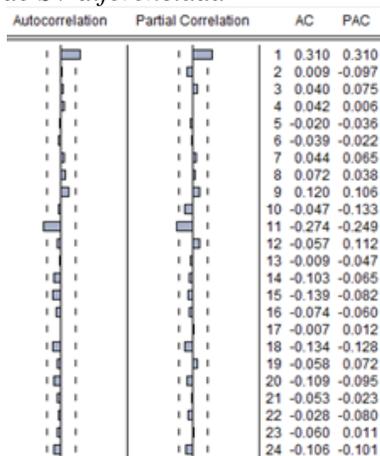
Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que hay diferencias significativas en la dispersión de los datos ($prob=0.0009$), lo que sugiere la necesidad de una transformación logarítmica. Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con

una diferencia y transformación logarítmica.

De la inspección visual de la serie se observan varios valores atípicos que podrían requerir de algún tipo de ajuste, de los cuales sobresale una fuerte caída del IPC a finales del 2009 y otra en 2015, así como valores muy altos a mitad de 2011.

b) Identificación del modelo

Gráfico 3.6: correlograma IPC alimentos de SV diferenciada



El correlograma de la serie transformada (Gráfico 3.6) evidencia la necesidad de incorporar un parámetro en la parte regular que recoja la autocorrelación entre observaciones adyacentes. Comparando el correlograma con los patrones teóricos del anexo 1, es difícil distinguir entre la conveniencia de un MA(1) o un AR(1), de modo que inicialmente se probaron ambas alternativas. No se observa correlación significativa en rezagos estacionales (12, 24), por lo cual el modelo no tendría componente

estacional. Conforme lo anterior, los modelos propuestos son ARIMA (110) (000) y ARIMA (011) (000).

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (011)(000), cuyos principales estadísticos se resumen en la tabla 3.6. La formulación es la siguiente:

$$(1 - B)IPCASV = w_1 Dummy1 + w_2 Dummy2 + (1 - \theta B)a_t \quad (2)$$

Este modelo se ajustó con los datos comprendidos en el periodo enero de 2009 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA. Se agregaron dos variables binarias tipo aditivo que recogen el impacto de fenómenos externos en los siguientes meses:

- Junio 2010: el nivel de la serie aumentó 0.90% en ese mes.
- Abril 2011: el nivel de la serie aumentó 0.91% en ese mes.

Nuevamente, una explicación es conveniente para la definición adecuada de la variable artificial que se debe construir. En este documento, la construcción de estas variables está basada únicamente en criterios estadísticos.

Tabla 3.6: Principales resultados modelo ARIMA para el IPCA de SV

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	0.39166	0.10287	3.81
Parámetros determinísticos			
(18) AO (6 2010)	0.89666E-02	(0.00404)	2.22
(28) AO (4 2011)	0.91480E-02	(0.00404)	2.26

d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 0.733%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. El parámetro MA es significativamente distinto de cero y cumple con la condición de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=1.876). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ (t=1.42). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la Prob(Q12)=0.82, Prob(Q24)=0.98 y Prob(Q36)=0.97. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia

residual. Los valores $\text{Prob}(Q_{12})=0.09$, $\text{Prob}(Q_{24})=0.53$ y $\text{Prob}(Q_{36})=0.83$ indican que no hay problema de heterocedasticidad, aun cuando se observan correlaciones un poco altas en los primeros rezagos. Las pruebas para determinar la presencia de estacionalidad indican que no hay estacionalidad identificable en la serie y tampoco en los residuos.

C) Modelo ARIMA para el IPC de alimentos de Guatemala

a) Estacionariedad

Gráfico 3.7: IPC alimentos de GT

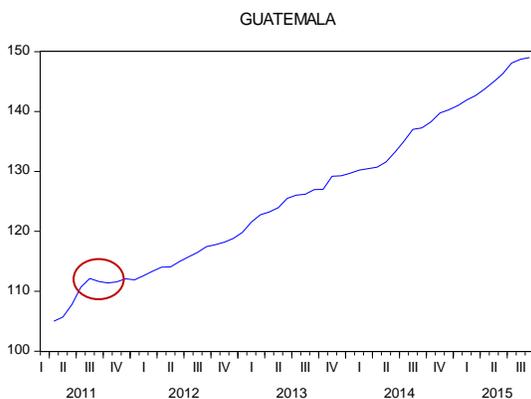
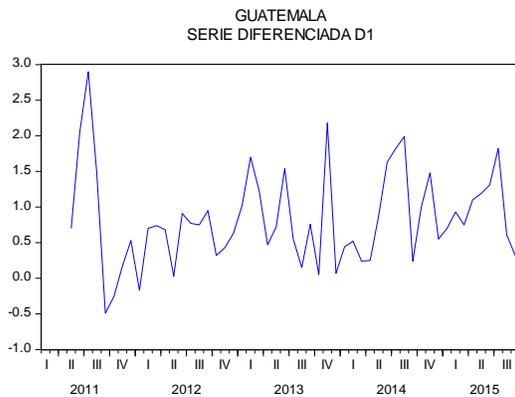


Gráfico 3.8. Primera diferencia
IPC alimentos de GT



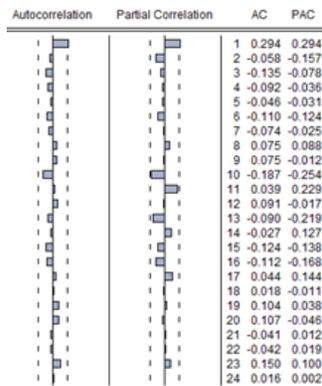
La serie del IPC de alimentos para Guatemala no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad. Esto se complementa con el análisis visual del gráfico 3.7 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.0000$), lo que sugiere la necesidad de una transformación logarítmica. Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una diferencia y con transformación logarítmica.

De la inspección visual de la serie se observa un cambio importante en la mitad de 2011, que se refleja en la serie diferenciada (gráfico 3.8) como un valor extremo.

b) Identificación del modelo

Gráfico 3.9: correlograma IPC alimentos de GT diferenciada



Comparando el correlograma de la serie transformada (Gráfico 3.9) con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro en la parte regular que recoja la autocorrelación entre observaciones adyacentes. No obstante, no es claro distinguir entre la conveniencia de un MA(1) o un AR(1), de modo que inicialmente se probaron ambas alternativas. No se observa correlación significativa en rezagos estacionales (12, 24), por lo cual el modelo no

tendría componente estacional. Conforme lo anterior, los modelos propuestos son ARIMA (110) (000) y ARIMA (011) (000).

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (011)(000), cuyos principales estadísticos se resumen en la tabla 3.7. La formulación es la siguiente:

$$(1 - B)IPCAGT = C + \frac{\omega_1}{(1 - \delta B)} Dummy1 + \frac{\omega_2}{(1 - \delta B)} Dummy2 + (1 - \theta B)a_t \quad (3)$$

Este modelo se ajustó con los datos comprendidos en el periodo abril de 2011 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA. Se agregaron dos variables binarias tipo aditivo que recogen el impacto de fenómenos externos en los siguientes meses:

- Julio 2011: el nivel de la serie aumentó 1.42% en ese mes y en meses posteriores el efecto disminuye hasta que la serie regresa a los niveles “normales”.
- Noviembre 2013: el nivel de la serie aumentó 1.29% en ese mes y en meses posteriores el efecto disminuye hasta que la serie regresa a los niveles “normales”.

Una explicación es conveniente para la definición adecuada de la variable artificial que se deba construir. En este documento, la construcción de estas variables está basada únicamente en criterios estadísticos.

Tabla 3.7: Principales resultados modelo ARIMA para el IPCA de GT

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	0.21160	0.13425	1.58
Parámetros determinísticos			
constante	0.65809E-02	0.00074	8.84
(32) TC (11 2013)	0.12883E-01	(0.00394)	3.27
(4) TC (7 2011)	0.14201E-01	(0.00394)	3.61

d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 0.449%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. El parámetro MA cumple con la condición de invertibilidad y es distinto de cero si se realiza la prueba con un nivel de confianza del 89% (y no del 95% que es lo usual). Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=0.945). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=-0.455$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la $Prob(Q12)=0.92$, $Prob(Q24)=0.98$ y $Prob(Q36)=0.93$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual. Los valores $Prob(Q12)=0.03$, $Prob(Q24)=0.06$ y $Prob(Q36)=0.00$ indican que hay problema de heterocedasticidad. En efecto la correlación de orden 1 y la de orden 27 son tan altas, que invalidan la prueba Q para todos los rezagos k. Aunque este resultado sugiere el uso de transformaciones en los datos y debido a que el logaritmo ya fue aplicado, es poco lo que se puede hacer por las dificultades en la interpretación que generan otras operaciones algebraicas. No obstante, se decide utilizar este modelo porque la serie de Guatemala es muy corta, tiene menos de 5 años de observaciones. Se conoce que las series cortas generan inestabilidad en la variancia, la cual se podría estabilizar cuando se cuente con un mayor número de datos.

Las pruebas para determinar la presencia de estacionalidad indican que no hay estacionalidad identificable en la serie y tampoco en los residuos.

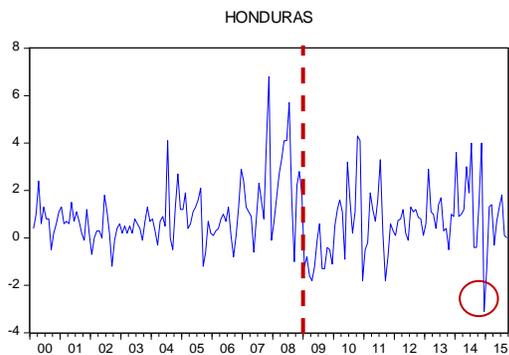
D) Modelo ARIMA para el IPC de alimentos de Honduras

a) Estacionariedad

Gráfico 3.10: IPC alimentos de HN



Gráfico 3.11. Primera diferencia IPC alimentos de HN



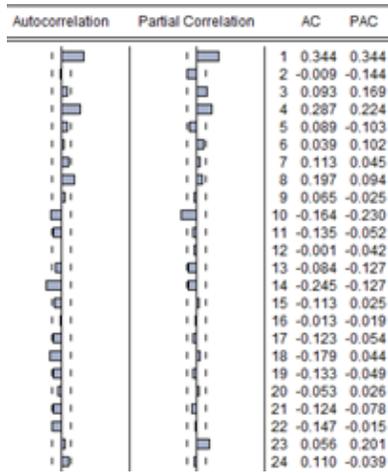
La serie del IPC de alimentos para Honduras no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad en la media. Esto se complementa con el análisis visual del gráfico 3.10 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.0000$), lo que sugiere la necesidad de una transformación logarítmica. Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una diferencia y con transformación logarítmica.

De la inspección visual de la serie se observa un cambio importante entre el 2007 y 2009 que se traduce en una gran cantidad de valores extremos en la serie diferenciada (gráfico 3.11). Por esta razón, se valora la posibilidad de reducir el tamaño de la serie como una forma de evitar el efecto de las observaciones de ese periodo. El año 2009 parece ser conveniente para iniciar la serie, ya que se tendrían casi 7 años completos de información.

b) Identificación del modelo

Gráfico 3.12: correlograma IPC alimentos de HN diferenciada



Comparando el correlograma de la serie transformada (Gráfico 3.12) con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro en la parte regular que recoja la autocorrelación entre observaciones adyacentes. No obstante, es difícil distinguir entre la conveniencia de un MA(1) o un AR(1), de modo que inicialmente se probaron ambas alternativas. No se observa correlación significativa en rezagos estacionales (12, 24), por lo cual el modelo no tendría componente estacional. Conforme lo anterior, los modelos propuestos son ARIMA (110) (000) y ARIMA (011) (000).

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (011)(000), cuyos principales estadísticos se resumen en la tabla 3.7. La formulación es la siguiente:

$$(1 - B)IPCAHN = C + w_1 Dummy1 + w_2 Dummy2 + w_3 Dummy3 + w_4 Dummy4 + \frac{\omega_5}{(1 - \delta B)} Dummy5 + (1 - \theta B)a_t \quad (4)$$

Este modelo se ajustó con una serie más corta que comprende de enero de 2009 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA. Se agregaron cinco variables binarias que recogen el impacto de fenómenos externos en los siguientes meses:

- Junio 2010: el nivel de la serie aumentó 1.45% a partir de junio de 2010. En este caso el efecto permanece en la serie con la misma magnitud.
- Diciembre 2010: el nivel de la serie disminuyó 1.38% y posteriormente el efecto se va diluyendo hasta que la serie regresa a los niveles “normales”.
- Febrero 2014: el nivel de la serie disminuyó 0.58% en ese mes.
- Junio 2014: el nivel de la serie disminuyó 0.80% en ese mes.
- Diciembre 2014: el nivel de la serie disminuyó 0.78% en ese mes.

De nuevo, es importante mencionar que conviene analizar con los especialistas del área para tener una explicación a cada uno de estos fenómenos.

Tabla 3.8: Principales resultados modelo ARIMA para el IPCA de HN

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	0.74135	0.75033E-01	9.88
Parámetros determinísticos			
constante	0.27584E-02	0.00103	2.67
(62) AO (2 2014)	-0.58153E-02	(0.00205)	-2.84
(66) AO (6 2014)	-0.80156E-02	(0.00209)	-3.84
(72) AO (12 2014)	-0.78146E-02	(0.00196)	-3.99
(24) TC (12 2010)	-0.13823E-01	(0.00312)	-4.43
(18) LS (6 2010)	0.14503E-01	(0.00363)	4.00

d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 0.533%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico. El parámetro MA es significativamente distinto de cero y cumple con la condición de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=1.529). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=1.398$).

La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la $\text{Prob}(Q_{12})=0.08$, $\text{Prob}(Q_{24})=0.32$ y $\text{Prob}(Q_{36})=0.76$. No obstante existe una correlación significativa en los rezagos 5 y 6, las cuales son evidencia de que permanecen valores extremos en los residuos que se podrían ajustar. Sin embargo, en un modelo con 5 variables artificiales no resulta conveniente continuar ajustando otros valores extremos. De hecho, en la evaluación final que realiza TSW+ al modelo seleccionado se señala la inconveniencia de tener 5 variables artificiales. De todos modos, tampoco se ve afectada la normalidad en los residuos.

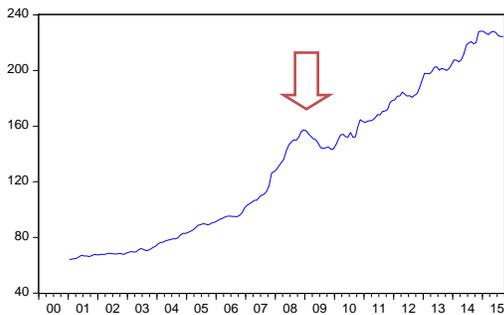
La prueba Q aplicada a los residuos al cuadrado permite evaluar el comportamiento de la variancia residual. Los valores $\text{Prob}(Q_{12})=0.78$, $\text{Prob}(Q_{24})=0.95$ y $\text{Prob}(Q_{36})=0.99$ indican que no hay problema de heterocedasticidad.

Las pruebas para determinar la presencia de estacionalidad indican que no hay estacionalidad identificable en la serie y tampoco en los residuos.

E) Modelo ARIMA para el IPC de alimentos de Nicaragua

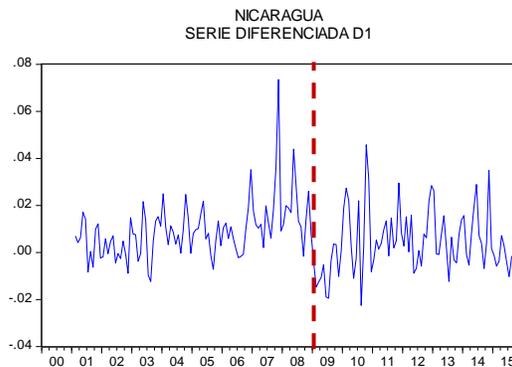
a) Estacionariedad

Gráfico 3.13: IPC alimentos de NI
NICARAGUA



La serie del IPC de alimentos para Nicaragua no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad. Esto se complementa con el análisis visual del gráfico 3.13 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

Gráfico 3.14. Primera diferencia
IPC alimentos de NI



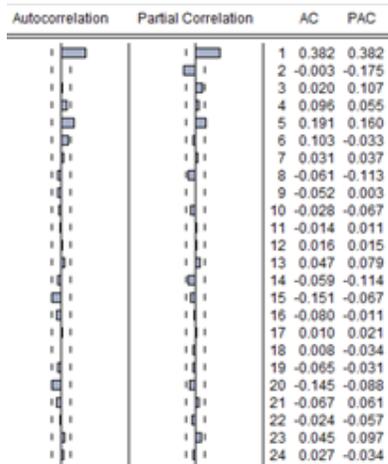
Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que no hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.1087$), lo que sugiere que no hay necesidad de una transformación logarítmica. No obstante, hay que tener señal que la hipótesis no se rechaza al 89% de confianza, de modo que habría que evaluar en la etapa de ajuste la conveniencia de dicha transformación. Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una diferencia.

De la inspección visual de la serie se observa un cambio importante entre 2008 y 2009 que se traduce en una gran cantidad de valores extremos en la serie diferenciada (gráfico

3.14). Por esta razón, se valora la posibilidad de reducir el tamaño de la serie como una forma de evitar el efecto de esas observaciones. El año 2009 parece ser conveniente para iniciar la serie, ya que coincide con un aparente cambio estructural en la serie y se tendrían casi 7 años completos de información.

b) Identificación del modelo

Gráfico 3.15: correlograma IPC alimentos de NI diferenciada



Comparando el correlograma de la serie transformada (Gráfico 3.15) con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro en la parte regular que recoja la autocorrelación entre observaciones adyacentes. No obstante, es difícil distinguir entre la conveniencia de un MA(1) o un AR(1), de modo que inicialmente se probaron ambas alternativas. No se observa correlación significativa en rezagos estacionales (12, 24), por lo cual el modelo no tendría componente

estacional. Conforme lo anterior, los modelos propuestos son ARIMA (110) (000) y ARIMA (011) (000).

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (011)(000), cuyos principales estadísticos se resumen en la tabla 3.9. La formulación es la siguiente:

$$(1 - B)IPCANI = C + (1 - \theta B)a_t \quad (5)$$

Este modelo se ajustó con un rango de datos más corto que va de enero de 2009 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA y tampoco se requiere la inclusión de variables binarias. A pesar de los resultados obtenidos en las pruebas iniciales, la transformación logarítmica ayudó a lograr un mejor ajuste de este modelo.

Tabla 3.9: Principales resultados modelo ARIMA para el IPCA de NI

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	0.51125	0.96088E-01	5.32
Parámetros determinísticos			
constante	0.27584E-02	0.00103	2.67

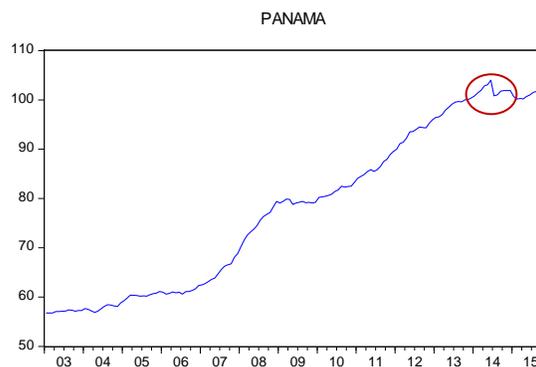
d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 1.21%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico. El parámetro MA es significativamente distinto de cero y cumple con la condición de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=0.564). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=1.45$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la $\text{Prob}(Q_{12})=0.98$, $\text{Prob}(Q_{24})=0.89$ y $\text{Prob}(Q_{36})=0.84$. La prueba Q aplicada a los residuos al cuadrado permite evaluar el comportamiento de la variancia residual. Los valores $\text{Prob}(Q_{12})=0.16$, $\text{Prob}(Q_{24})=0.70$ y $\text{Prob}(Q_{36})=0.95$ indican que no hay problema de heterocedasticidad. Las pruebas para determinar la presencia de estacionalidad indican que no hay estacionalidad identificable en la serie y tampoco en los residuos.

F) Modelo ARIMA para el IPC de alimentos de Panamá

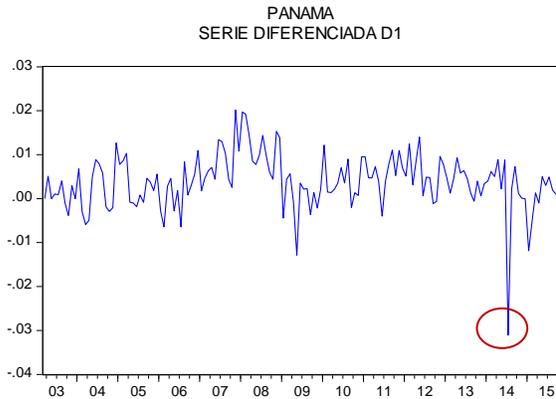
a) Estacionariedad

Gráfico 3.16: IPC alimentos de PA



La serie del IPC de alimentos para Panamá no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad. Esto se complementa con el análisis visual

Gráfico 3.17. Primera diferencia
IPC alimentos de PA



del gráfico 3.16 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4). Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que hay diferencias significativas en la dispersión de los datos ($prob=0.0002$), lo que sugiere la necesidad de una transformación logarítmica. Por

consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una diferencia y transformación logarítmica.

De la inspección visual de la serie se observa un cambio importante en 2014 que se traduce en un pico hacia abajo en la serie diferenciada (gráfico 3.17). Por esta razón, se procedió a analizar si ese periodo coincide con el empalme que se realizó entre las series del IPC con base 2013=100 y octubre 2002=100. Sin embargo, se descarta esta posibilidad pues el empalme se realizó en el mes de octubre y el cambio de nivel se observa en julio de 2014.

b) Identificación del modelo

Gráfico 3.18: correlograma IPC alimentos de PA diferenciada

Autocorrelation	Partial Correlation	AC	PAC
1	0.240	0.240	0.240
2	0.145	0.093	0.145
3	0.146	0.099	0.146
4	0.160	0.103	0.160
5	0.117	0.044	0.117
6	0.267	0.219	0.267
7	0.227	0.114	0.227
8	0.158	0.044	0.158
9	0.078	-0.034	0.078
10	0.009	-0.101	0.009
11	0.055	-0.003	0.055
12	0.004	-0.097	0.004
13	0.038	-0.029	0.038
14	0.011	-0.053	0.011
15	-0.036	-0.072	-0.036
16	-0.013	0.028	-0.013
17	-0.017	0.001	-0.017
18	-0.104	-0.071	-0.104
19	-0.114	-0.069	-0.114
20	-0.099	-0.050	-0.099
21	-0.062	0.025	-0.062
22	-0.070	-0.010	-0.070
23	-0.048	0.020	-0.048
24	-0.093	-0.029	-0.093

Comparando el correlograma de la serie transformada (Gráfico 3.18) con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro en la parte regular que recoja la autocorrelación entre observaciones adyacentes. Este parámetro podría ser de tipo AR o ARMA, por la estructura de correlaciones que se observa en el correlograma simple y en el parcial. No se observa correlación significativa en rezagos estacionales (12, 24), por lo cual el modelo no tendría componente estacional.

Conforme lo anterior, los modelos propuestos son ARIMA (110) (000) y ARIMA (111) (000).

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (011)(000), cuyos principales estadísticos se resumen en la tabla 3.10. La formulación es la siguiente:

$$(1 - \phi B)(1 - B)IPCAPA = C + w_1 Dummy1 + w_2 Dummy2 + a_t \quad (6)$$

Este modelo se ajustó con los datos comprendidos en el periodo enero de 2003 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA.

Tabla 3.10: Principales resultados modelo ARIMA para el IPCA de PA

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
PHI1	-0.44670	0.72568E-01	-6.16
Parámetros determinísticos			
Constante	0.40425E-02	0.00073	5.56
(139) LS (7 2014)	-0.36259E-01	(0.00455)	-7.97
(59) AO (11 2007)	0.70432E-02	(0.00275)	2.57

Se agregaron 2 variables binarias que recogen el impacto de fenómenos externos en los siguientes meses:

- Noviembre 2007: el nivel de la serie aumentó 0.70% en ese mes.
- Julio 2014: el nivel de la serie disminuyó en 0.36% a partir de julio de 2014. En este tipo de variables artificiales el efecto permanece en la serie con la misma magnitud.

d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 0.498%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico. El parámetro AR es significativamente distinto de cero y cumple con la condición de estacionariedad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=0.89). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=0.72$). La prueba Q de Box-Pierce

muestra que no hay autocorrelación residual significativa; la $Prob(Q12)=0.31$, $Prob(Q24)=0.50$ y $Prob(Q36)=0.36$. La prueba Q aplicada a los residuos al cuadrado permite evaluar el comportamiento de la variancia residual. Los valores $Prob(Q12)=0.52$, $Prob(Q24)=0.37$ y $Prob(Q36)=0.62$ indican que no hay problema de heterocedasticidad. Las pruebas para determinar la presencia de estacionalidad indican que no hay estacionalidad identificable en la serie y tampoco en los residuos.

G) Modelo ARIMA para el IPC de alimentos Regional

a) Estacionariedad

La serie del IPC de alimentos para la Región no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad. Esto se complementa con el análisis visual del gráfico 3.19 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

Gráfico 3.19: IPC alimentos de RE

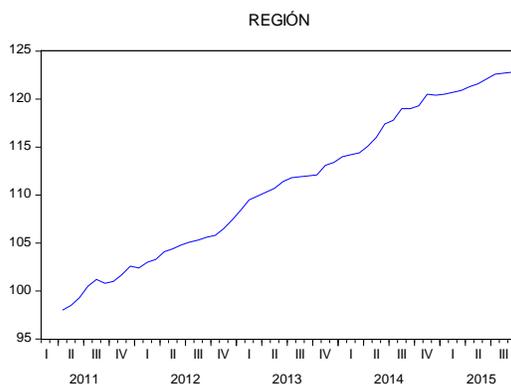
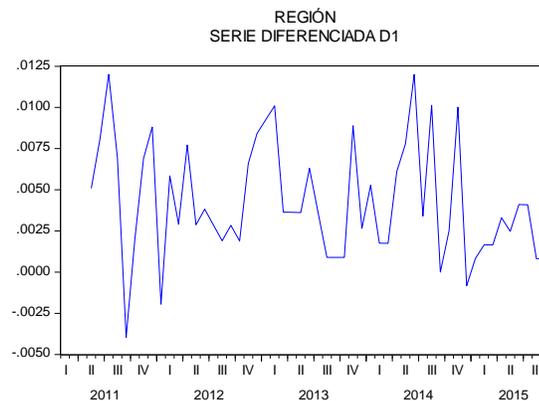


Gráfico 3.20: Primera diferencia IPC alimentos de RE



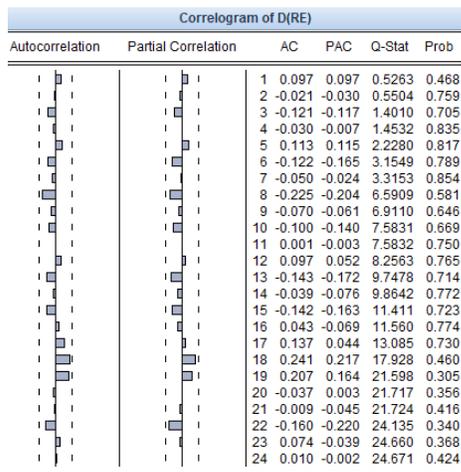
De la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que no hay diferencias significativas en la dispersión de los datos ($prob=0.0055$), lo que sugiere la necesidad de una transformación logarítmica. Por consiguiente, la serie que cumple

con las condiciones de estacionariedad es aquella con una diferencia y transformación logarítmica.

De la inspección visual de la serie no se observa un algún cambio importante que deba ser considerado a priori.

b) Identificación del modelo

Gráfico 3.21: correlograma IPC alimentos de RE diferenciada



Del correlograma de la serie transformada (Gráfico 3.21) no se observa la necesidad de agregar ningún parámetro estocástico. No obstante se realizarán pruebas con un parámetro tipo AR y MA; en caso de no resultar significativas no es posible definir un modelo univariante. De este modo, los modelos propuestos son ARIMA (110) (000) y ARIMA (011) (000).

c) Resultados

Luego de varios ajustes el modelo seleccionado es un ARIMA (011)(000), cuyos principales estadísticos se resumen en la tabla 3.11. La formulación es la siguiente:

$$(1 - B)IPCAPA = C + (1 - \theta B)a_t \quad (7)$$

Este modelo se ajustó con los datos comprendidos en el periodo abril de 2011 a setiembre de 2015. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IPCA.

Tabla 3.11: Principales resultados modelo ARIMA para el IPCA de RE

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	0.15436	0.13571	1.14
Parámetros determinísticos			
constante	0.42409E-02	0.00056	7.58

d) Verificación

En el anexo 6 se incluye el detalle de las pruebas utilizadas en la etapa de verificación. El error estándar residual es de 0.354%, valor que es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. El parámetro MA cumple con la condición de invertibilidad pero no es significativo. El valor $t=1.14$ indica que el valor es distinto de cero si la prueba se realizara al 75% de confianza (y no al 95% que es lo usual). Sin embargo, si se elimina este parámetro resulta en una autocorrelación residual significativa en $k=1$. De modo que el modelo se mantiene con un parámetro poco significativo pero con la esperanza de que al contar con más datos se eleve su significancia.

Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque ($BJ=0.51$). No se rechaza la hipótesis de que la media de los residuos es cero $H_0:\mu=0$ ($t=-0.116$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la $\text{Prob}(Q_{12})=0.82$, $\text{Prob}(Q_{24})=0.62$ y $\text{Prob}(Q_{36})=0.45$. La prueba Q aplicada a los residuos al cuadrado permite evaluar el comportamiento de la variancia residual. Los valores $\text{Prob}(Q_{12})=0.50$, $\text{Prob}(Q_{24})=0.89$ y $\text{Prob}(Q_{36})=0.14$ indican que no hay problema de heterocedasticidad. Las pruebas para determinar la presencia de estacionalidad indican que no hay estacionalidad identificable en la serie y tampoco en los residuos.

H) Resumen modelos ARIMA para los IPC del grupo alimentos

En la tabla 3.12 se resumen las principales características de los modelos ARIMA identificados para los índices de precios al consumidor del grupo alimentos. Se destaca lo siguiente:

- En casi todos los modelos la constante es significativa. Únicamente en el IPC de Nicaragua no lo fue.
- Ninguna serie tiene estacionalidad.
- Los efectos de calendario no son significativos en ninguna serie.
- El error estándar residual oscila en un rango de 0.35% a un 1.21%.

Tabla 3.12. Resumen modelos ARIMA para el IPC de alimentos

País	Periodo de datos	modelo	Cons tante	log arit mo	TD R	SS	Estaci onalidad? ^{1/}	OUTLIERS	Error residual
Costa Rica	Jul 2006- set. 2015	(110)(100)	si	si	no	no	si	TC enero 2009 AO nov.2011	0.895%
El Salvador	Ene.2009- set.2015	(011)(000)	no	si	no	no	no	AO junio 2010 AO abril 2011	0.733%
Guatemala	Abril 2011- set.2015	(011)(000)	si	si	no	no	no	TC julio 2011 TC nov.2013	0.449%
Honduras	Ene.2009- set.2015	(011)(000)	si	si	no	no	no	LS junio 2010 TC dic.2010 AO feb.2014 AO jun.2014 AO dic. 2014	0.533%
Nicaragua	Ene.2009- set.2015	(011)(000)	si	si	no	no	no	No hay	1.210%
Panamá	Ene.2003- set.2015	(110)(000)	si	si	no	no	no	AO nov.2007 LS jul.2014	0.498%
Región	Abril 2011- set.2015	(011)(000)	si	si	no	no	no	No hay	0.354%

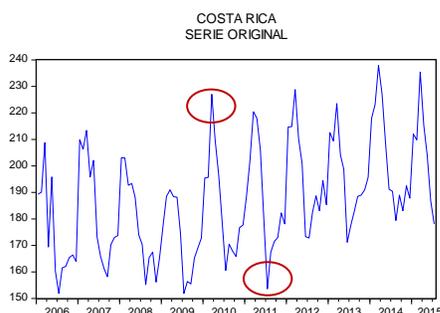
1/ corresponde a la prueba “overall test for identifiable seasonality” que aplica TSW+ a la serie original.
Fuente: elaboración propia.

3.4. Modelos ARIMA para la producción agropecuaria

A) Modelo ARIMA para el IMAE agropecuario de Costa Rica

a) Estacionariedad

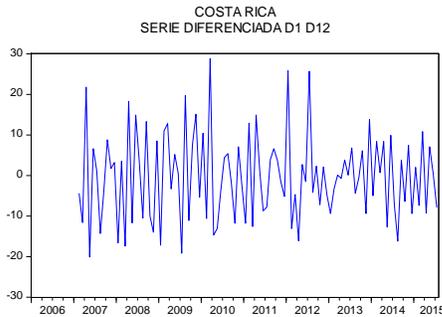
Gráfico 3.22: IMAE agropecuario de CR



La serie del IMAE agropecuario para Costa Rica no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es I(1), es decir, se requiere una diferenciación para lograr estacionariedad en la media. Esto se complementa con el análisis visual

del gráfico 3.22 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4).

Gráfico 3.23: *DID12 IMAE agropecuario de CR*



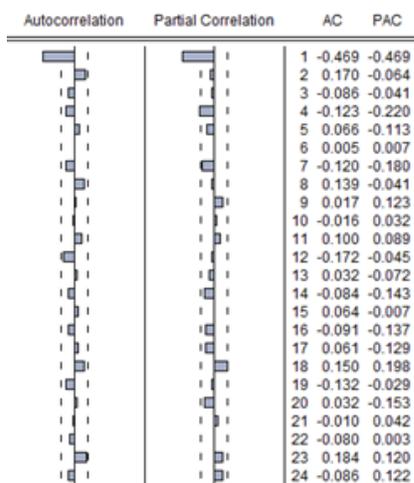
Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que no hay diferencias significativas en la dispersión de los datos (prob=0.70), por lo que a priori no se observa la necesidad de una transformación en los datos.

Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una primera diferencia y una diferencia estacional.

De la inspección visual de la serie se observan varios valores atípicos que podrían requerir de algún tipo de ajuste. Se notan valores altos en marzo de 2010 y en julio 2011.

b) Identificación del modelo

Gráfico 3.24: *correlograma de DID12 IMAEA de CR*



Comparando el correlograma (Gráfico 3.24) de la serie transformada con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro de tipo en la parte regular que recoja la autocorrelación de entre observaciones adyacentes. No obstante, no es claro distinguir entre la conveniencia de un MA(1) o un AR(1), de modo que inicialmente se probaron ambas alternativas.

Adicionalmente, debido a que la correlación de orden 12 es también importante (AC=-0.172) es conveniente la inclusión de un parámetro estacional. De todos modos la importancia del componente estacional había quedado claro en la inspección visual de la serie. Esta correlación será

capturada inicialmente con un parámetro MA(12). Conforme lo anterior, los modelos propuestos son ARIMA (110) (011) y ARIMA (011) (011). En la etapa de verificación hay que determinar si el componente estacional requiere de diferenciación.

c) Resultados

Luego de varios ajustes el modelo seleccionado para el IMAE es un ARIMA (011)(011), cuyos principales estadísticos se resumen en la tabla 3.13. La formulación es la siguiente:

$$(1-B)(1-B^{12})IMAECR = w_1 Dummy1 + \frac{\omega_2}{(1-\delta B)} Dummy2 + \frac{(1-\theta_{12}B^{12})}{(1-\phi_1 B)} a_t \quad (8)$$

Se debe mencionar que persiste una autocorrelación de orden 2 que si bien no es significativa, es más grande de lo deseado. Incluso se intentó capturar agregando un parámetro MA(2) pero no resultó significativo.

La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IMAE. Tampoco lo fue la constante en la ecuación. En este caso era de esperar pues la serie diferenciada oscila alrededor de una media que es cero. Sin embargo, se agregaron dos variables binarias tipo aditivo que recogen el impacto de fenómenos externos en los siguientes meses:

- Marzo 2010: el nivel de la serie aumentó 17 puntos del índice.
- Julio 2011: el nivel de la serie disminuyó 18 puntos del índice; en meses posteriores el efecto fue disminuyendo hasta que la serie regresa a los niveles “normales”.

Es importante mencionar que conviene analizar con los especialistas del área para tener una explicación a cada uno de estos fenómenos. Una explicación es conveniente para la definición adecuada de la variable artificial que se deba construir. En este documento, la construcción de estas variables está basada únicamente en criterios estadísticos.

Es importante mencionar que estas variables de intervención no fueron identificadas en forma automática por el módulo Tramo de TSW+, sino que son el resultado de un análisis minucioso de la serie.

Tabla 3.13. Principales resultados modelo para el IMAEA de CR

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	-0.60615	0.80355E-01	-7.54
BTH	-0.46530	0.89428E-01	-5.20
Parámetros determinísticos			
(67) TC (7 2011)	-18.418	(6.17805)	-2.98
(51) AO (3 2010)	17.384	(6.28749)	2.76

d) Verificación

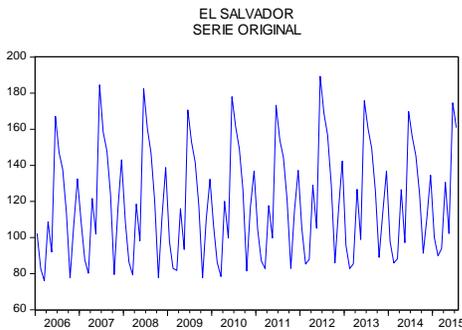
El error estándar residual es de 8.193 puntos del índice, lo que representa un error del 4.6% si se le compara con la última observación de la serie, o de un 3.9% si se compara con el nivel promedio de lo que va del 2015. Este error es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra.

Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad y estacionariedad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=1.9). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=-0.66$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa; la $\text{Prob}(Q_{12})=0.67$, $\text{Prob}(Q_{24})=0.21$ y $\text{Prob}(Q_{36})=0.20$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual. Los valores $\text{Prob}(Q_{12})=0.07$, $\text{Prob}(Q_{24})=0.17$ y $\text{Prob}(Q_{36})=0.47$ indican que no hay problema de heterocedasticidad. Llama la atención del valor en Q12, pues es relativamente bajo. Efectivamente la correlación en $k=10$ es de 0.3347 que sobrepasa el límite de confianza de ± 0.20 . Esto significa que persiste algún shock que aumentó la variancia en un punto específico de la serie, sin embargo, no es tan fuerte como para invalidar las pruebas.

B) Modelo ARIMA para el IMAE agropecuario de El Salvador

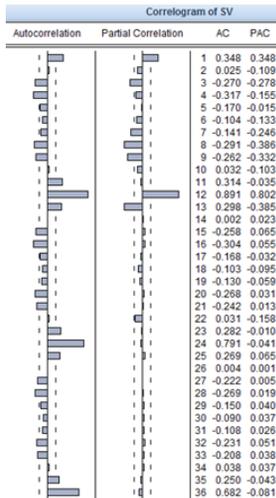
a) Estacionariedad

Gráfico 3.25: IMAE agropecuario de SV



La serie del IMAE agropecuario para El Salvador no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$ alrededor de una media distinta de cero, sin tendencia. La necesidad de una diferenciación estacional es evidente en el gráfico 3.25 por la fuerte presencia de estacionalidad, pero la necesidad de una diferencia regular ($t - t-1$) no es tan clara.

Gráfico 3.26: Correlograma serie original IMAE agropecuario de SV



El correlograma de la serie original confirma esta situación; se observa un patrón tipo AR en los múltiplos de 12, lo que sugiere la necesidad de una diferenciación de orden 12, pero no se observa un patrón AR en las primeras autocorrelaciones. De tal modo que se puede ensayar un modelo con $d=1$ y otro con $d=0$. Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que no hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.93$), por lo que a priori no se observa la necesidad de una transformación en los datos.

Gráfico 3.27: D1D12 IMAE agropecuario SV

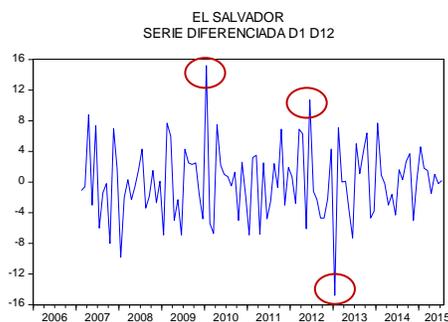
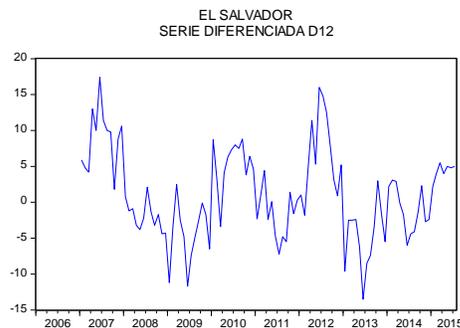


Gráfico 3.28: D12 IMAE agropecuario SV

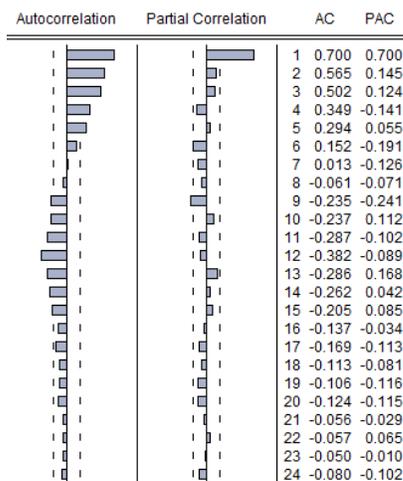


De la inspección visual de la serie se observan varios valores atípicos que podrían requerir de algún tipo de ajuste. Se notan valores muy bajos en enero de 2009 y en enero de 2013 y un valor alto en septiembre de 2012. Estos puntos se señalan en la serie diferenciada (gráfico 3.27) porque son difíciles de apreciar en la serie original.

b) Identificación del modelo

Inicialmente se identifica el modelo utilizando el correlograma de la serie con diferenciación estacional. Como se aprecia en el gráfico 3.29, se requiere un modelo (1,0,0) en la parte regular. En caso que la diferenciación regular sea necesaria, ocurrirá que el parámetro ϕ_1 será muy cercano a 1. En ese caso se procedería a aplicar la diferenciación y calcular de nuevo el correlograma. En caso ϕ_1 tenga valores aceptables, se considera como una cuasi-diferenciación. En cuanto al modelo en la parte estacional, no es factible distinguir entre un AR(1) y un MA(1), por lo cual se probó con un MA(1) y luego con un AR(1).

Gráfico 3.29: correlograma de D12 IMAEA de SV



Conforme lo anterior, los modelos inicialmente propuestos son ARIMA (100) (011) y ARIMA (100) (110). En la etapa de verificación se definirá la necesidad de una diferenciación regular $d=1$.

c) Resultados

Luego de varios ajustes el modelo seleccionado para el IMAE es un ARIMA (100)(011), cuyos principales estadísticos se resumen en la tabla 3.14. La formulación es la siguiente:

$$(1 - \phi_1 B)(1 - B^{12})IMAESV = \frac{\omega_1}{(1 - \delta B)} Dummy1 + \frac{\omega_2}{(1 - \delta B)} Dummy2 + \frac{\omega_3}{(1 - \delta B)} Dummy3 + (1 - \theta_{12} B^{12})a_t \quad (9)$$

La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IMAE. Tampoco lo fue la constante en la ecuación. Sin embargo, se agregaron tres variables binarias tipo aditivo que recogen el impacto de fenómenos externos en los siguientes meses:

- Enero 2009: el nivel de la serie disminuyó 10.5 puntos del índice.
- Junio 2012: el nivel de la serie aumentó 10.6 puntos del índice.
- Enero 2013: el nivel de la serie disminuyó 10.6 puntos del índice.

En todos los casos el ajuste fue de tipo “cambio transitorio” (TC), es decir, en meses posteriores al impacto, el efecto fue disminuyendo hasta que la serie regresa a los niveles “normales”. Es importante mencionar que conviene analizar con los especialistas del área para tener una explicación a cada uno de estos fenómenos. Una explicación es conveniente para la definición adecuada de la variable artificial que se deba construir. En este documento, la construcción de estas variables está basada únicamente en criterios estadísticos.

Tabla 3.14. Principales resultados modelo IMAEA para El Salvador

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
PHI1	-0.70358	0.71250E-01	-9.87
BTH	-0.40204	0.91806E-01	-4.38
Parámetros determinísticos			
(37) TC (1 2009)	-10.502	(2.89470)	-3.63
(85) TC (1 2013)	-10.589	(2.89957)	-3.65
(78) TC (6 2012)	10.614	(2.88948)	3.67

d) Verificación

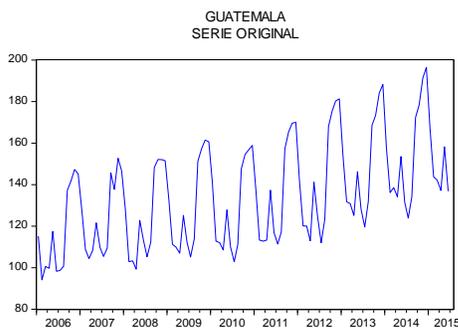
El error estándar residual es de 3.449 puntos del índice, lo que representa un error del 2.14% si se le compara con la última observación de la serie, o de un 2.83% si se compara con el nivel promedio de lo que va del 2015. Este error es utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra.

Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad y estacionariedad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=1.1). No se rechaza la hipótesis de que la media de los residuos es cero $H_0:\mu=0$ ($t=1.37$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual; la $\text{Prob}(Q_{12})=0.19$, $\text{Prob}(Q_{24})=0.64$ y $\text{Prob}(Q_{36})=0.68$. Con la misma prueba aplicada a los residuos al cuadrado se analiza la heterocedasticidad de los residuos. Los valores $\text{Prob}(Q_{12})=0.56$, $\text{Prob}(Q_{24})=0.92$ y $\text{Prob}(Q_{36})=0.98$ indican que los residuos tienen una variancia constante.

C) Modelo ARIMA para el IMAE agropecuario de Guatemala

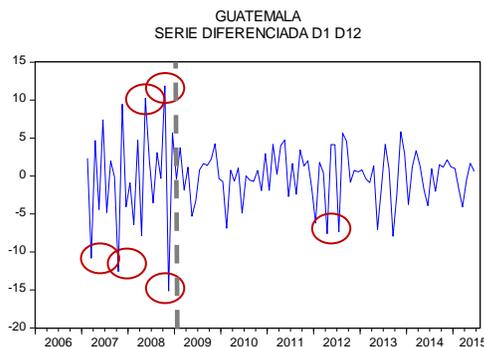
a) Estacionariedad

Gráfico 3.30: IMAE agropecuario GT



La serie del IMAE agropecuario para Guatemala no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad en la media. Esto se complementa con el análisis visual del gráfico y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte.

Gráfico 3.31: D1D12 IMAE agropecuario GT



Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que no hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.246$), por lo que a priori no se observa la necesidad de una transformación en los datos.

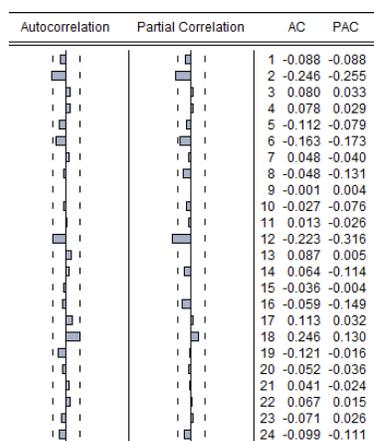
Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una primera diferencia y una diferencia estacional.

No obstante, de la inspección visual de la serie se observan una gran cantidad de valores atípicos al inicio de la misma, que incluso sugieren la existencia de un patrón para los años anteriores a 2009 y otro diferente a partir de ese año. Por esta razón, para la identificación del modelo ARIMA se selecciona el periodo 2009-2015 que resulta mucho más homogéneo.

Si se observa cuidadosamente el gráfico 3.30 se observa que los datos de 2009 a 2015 presentan una dispersión que aumenta conforme aumenta el nivel de la serie. Este es un caso donde la transformación logarítmica resulta muy conveniente. Por esta razón, se evaluará el desempeño del modelo ARIMA con transformación logarítmica y sin ella.

b) Identificación del modelo

Gráfico 3.32: correlograma de DID12IMAE de GT



Comparando el correlograma (Gráfico 3.32) de la serie transformada con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro de tipo en la parte regular que recoja la autocorrelación de entre observaciones adyacentes. No obstante, no es posible distinguir entre la conveniencia de un MA(1) o un MA(2), de modo que inicialmente se probaron ambas alternativas. Adicionalmente, debido a que la correlación de orden 12 es también importante (AC=-0.223) es conveniente la

inclusión de un parámetro estacional que será capturada inicialmente con un parámetro MA(12). Conforme lo anterior, los modelos propuestos son ARIMA (011) (011) y ARIMA (012) (011).

c) Resultados

Luego de varios ajustes el modelo seleccionado para el IMAE es un ARIMA (011)(011), cuyos principales estadísticos se resumen en la tabla 3.15. La formulación final es la

siguiente:

$$(1 - B)(1 - B^{12}) \log(\text{IMAEGT}) = w_1 \text{Dummy1} + (1 - \theta_1 B)(1 - \theta_{12} B^{12}) a_t \quad (10)$$

Se debe mencionar que persiste una autocorrelación de orden 3 que si bien no es significativa, es más grande de lo deseado. La *semana santa* y el *efecto de calendario* no resultaron significativos en ninguno de los modelos ensayados para el IMAE. Tampoco lo fue la constante en la ecuación. La transformación logarítmica fue seleccionada pues ayuda a conseguir estacionariedad en la variancia.

Se agregó una variable binaria que recoge el impacto de un fenómeno externo que afectó el mes de abril de 2012, produciendo una caída en el nivel de la serie de 4.8%. Este efecto fue de tipo aditivo, es decir, únicamente el nivel de la serie en abril de 2012 se vio afectado.

Tabla 3.15. Principales resultados modelo IMAEA para Guatemala

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	-0.23852	0.12090	-1.97
BTH	-0.40219	0.11398	-3.53
Parámetros determinísticos			
(40) AO (4 2012)	-0.48196E-01	(0.01372)	-3.51

d) Verificación

El error estándar residual es de 2.08%, valor utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. Este error residual se interpreta en porcentajes debido a que la serie fue transformada a logaritmos.

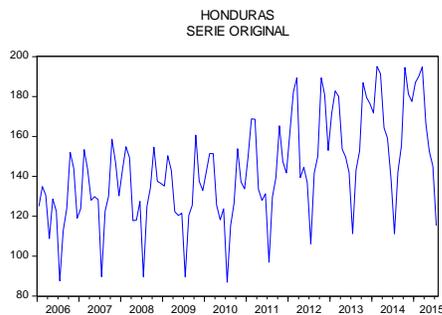
Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=3.57). No se rechaza la hipótesis de que la media de los

residuos es cero $H_0:\mu=0$ ($t=0.09$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa: la $\text{Prob}(Q_{12})=0.19$, $\text{Prob}(Q_{24})=0.62$ y $\text{Prob}(Q_{36})=0.71$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual e indican que no hay problema de heterocedasticidad: $\text{Prob}(Q_{12})=0.86$, $\text{Prob}(Q_{24})=0.29$ y $\text{Prob}(Q_{36})=0.31$.

D) Modelo ARIMA para el IMAE agropecuario de Honduras

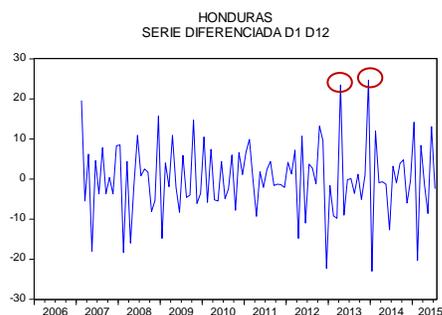
a) Estacionariedad

Gráfico 3.33: IMAE agropecuario HN



La serie del IMAE agropecuario para Honduras no es estacionaria en la media. Las pruebas de raíces unitarias de la Sección 3.2 confirman esta condición e indican que la serie es $I(1)$, es decir, se requiere una diferenciación para lograr estacionariedad en la media. Esto se complementa con el análisis visual del gráfico 3.33 y con el comportamiento del correlograma de la serie original, que tiene una estructura de autocorrelaciones muy fuerte (anexo 4). En ese correlograma también se observa la necesidad de una diferenciación múltiplo de 12.

Gráfico 3.34: DID12 IMAE agropecuario HN



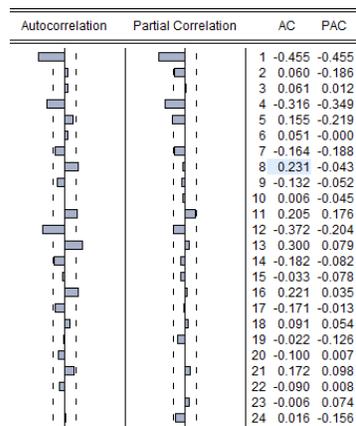
Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.011$), por lo que a priori se observa la necesidad de una transformación logarítmica en los datos.

Por consiguiente, la serie que cumple con las condiciones de estacionariedad es aquella con una primera diferencia y una diferencia estacional.

b) Identificación del modelo

Comparando el correlograma (Gráfico 3.35) de la serie transformada con los patrones teóricos (Anexo 1), se nota que es necesario incorporar un parámetro de tipo MA que recoja la autocorrelación entre observaciones adyacentes. Asimismo, se requiere un parámetro para recoger la autocorrelación de orden 12, que será capturada inicialmente con un parámetro tipo MA. Conforme lo anterior, el modelo inicialmente propuesto es un ARIMA (011) (011).

Gráfico 3.35: correlograma de DID12 IMAEA de HN



c) Resultados

El modelo inicialmente seleccionado resultó apropiado para la serie del IMAE de Honduras. Se selecciona un ARIMA (011)(011), cuyos principales estadísticos se resumen en la tabla 3.16. La formulación es la siguiente:

$$(1 - B)(1 - B^{12}) \log(\text{IMAEHN}) = w_1 \text{Dummy1} + w_2 \text{Dummy2} + (1 - \theta_1 B)(1 - \theta_{12} B^{12}) a_t \quad (11)$$

Se agregaron dos variables binarias para recoger dos valores muy altos observados en noviembre de 2012 y en diciembre de 2013. El primero de ellos aumenta el nivel de la serie en un 8.68% y el segundo en 6.55%. Estas variables tienen además la bondad de eliminar una correlación residual r_4 que resultaba significativa antes de realizar el análisis de intervención.

d) Verificación

El error estándar residual es de este modelo es de 4.59%, valor utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. Este error residual se interpreta en porcentajes debido a que la serie fue transformada a logaritmos.

Tabla 3.16. Principales resultados modelo IMAEA para Honduras

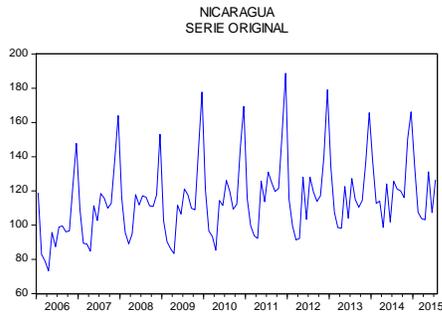
Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	-0.66376	0.75239E-01	-8.82
BTH	-0.38399	0.92882E-01	-4.13
Parámetros determinísticos			
(83) AO (11 2012)	0.86869E-01	(0.03496)	2.49
(96) AO (12 2013)	0.65544E-01	(0.03565)	1.84

Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=0.33). No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=-0.47$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa: la $\text{Prob}(Q12)=0.70$, $\text{Prob}(Q24)=0.74$ y $\text{Prob}(Q36)=0.89$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual e indican que no hay problema de heterocedasticidad: $\text{Prob}(Q12)=0.16$, $\text{Prob}(Q24)=0.62$ y $\text{Prob}(Q36)=0.16$.

E) Modelo ARIMA para el IMAE agropecuario de Nicaragua

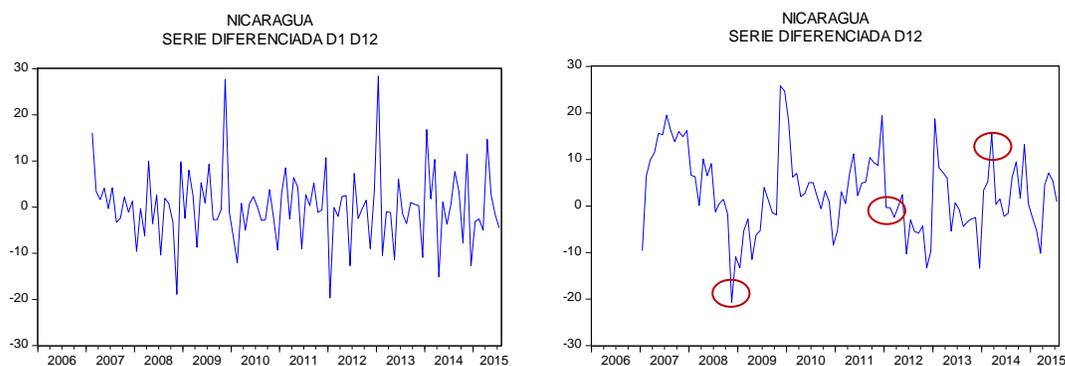
a) Estacionariedad

Gráfico 3.36: IMAE agropecuario NI



La serie del IMAE agropecuario para Nicaragua luce casi estacionaria en la media (gráfico 3.36). Las pruebas de raíces unitarias de la Sección 3.2 indican que la serie es estacionaria alrededor de una tendencia determinística. De tal modo que podría pensarse que la diferenciación estacional pueda generar una serie que sea estacionaria sin necesidad de tomar diferenciaciones con los meses adyacentes. En el gráfico 3.37 se ensayan dos opciones de diferenciaciones: la primera con $d=1$ y $D=1$ y la segunda con $d=0$ y $D=1$. Analizando los correlogramas del gráfico 3.38 como complemento a la prueba DFA, existe la posibilidad de que el IMAE agropecuario de Nicaragua requiera de una cuasidiferenciación para conseguir estacionariedad, en el sentido de que una diferenciación $(y_t - y_{t-1})$ es innecesaria, pero una transformación como $(y_t - \phi y_{t-1})$, con ϕ digamos 0.8, sería suficiente para conseguir estacionariedad. Este último caso corresponde a un modelo AR(1).

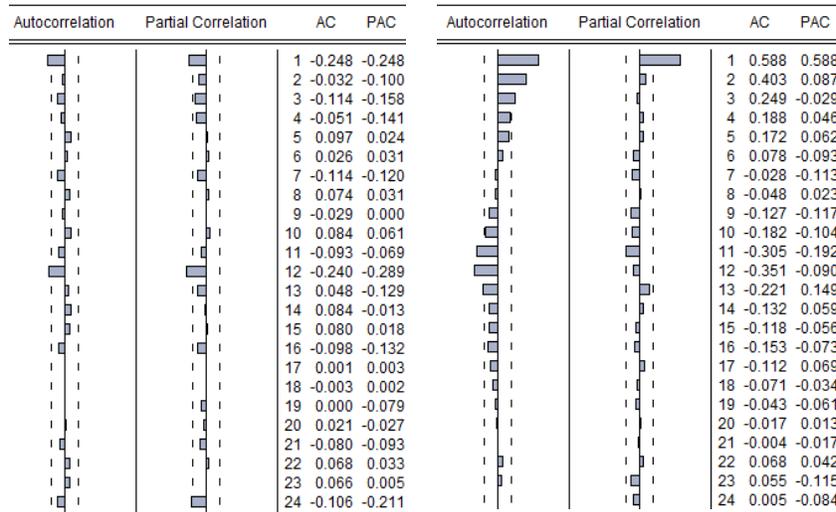
Gráfico 3.37. Diferenciaciones del IMAE de Nicaragua



Además, de la prueba de hipótesis de igualdad de variancias de la tabla 3.2 se desprende que no hay diferencias significativas en la dispersión de los datos ($\text{prob}=0.7722$), por lo que a priori no se observa la necesidad de una transformación logarítmica.

b) Identificación del modelo

Gráfico 3.38: correlogramas DID12 IMAEA y D12 IMAEA de NI



Comparando los correlogramas (gráfico 3.38) con los patrones teóricos (Anexo 1), se proponen dos modelos que podrían resultar apropiados para esta serie: ARIMA (011)(011) siguiendo el primer correlograma y un ARIMA (100)(011) a partir del segundo correlograma.

c) Resultados

El modelo ARIMA (100)(011) requirió un parámetro adicional y tuvo un buen ajuste luego de agregar una MA(1), es decir (101)(011). Tanto este modelo como el ARIMA (011)(011) resultaron satisfactorios y pasaron los criterios de verificación. No obstante, se selecciona un ARIMA (101)(011), porque tiene un error estándar residual menor y criterios de bondad de ajuste como AIC o BIC que confirman que, a pesar de tener un parámetro adicional, el ajuste resulta mejor. Los principales estadísticos se resumen en la tabla 3.17. La formulación es la siguiente:

$$(1 - \phi B)(1 - B^{12}) \log(IMAENI) = w_1 Dummy1 + \frac{\omega_2}{(1 - \delta B)} Dummy2 + \frac{\omega_3}{(1 - \delta B)} Dummy3 + (1 - \theta_2 B^{12}) a_t \tag{12}$$

La transformación logarítmica fue necesaria para mejorar el ajuste del modelo y los criterios de normalidad. Se agregaron tres variables binarias para recoger dos valores muy altos observados en:

- noviembre de 2008: presenta una caída en el nivel de la serie de un 17.4%, cuyo efecto se sigue sintiendo en meses subsiguientes con menor medida.
- enero de 2012: presenta una caída en el nivel de la serie de un 14.5%, cuyo efecto se sigue sintiendo en meses subsiguientes con menor medida.
- marzo de 2014: presenta una subida de 9.3% cuyo efecto se da únicamente en este mes.

Adicionalmente, el efecto de semana santa es significativo en esta serie. Cuando la semana santa se presenta, la actividad agropecuaria desciende un 3.1%. Vale mencionar que esta es la única serie en la cual la semana santa presenta un efecto significativo.

Tabla 3.17: Principales resultados modelo IMAEA para Nicaragua

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
PHI1	-0.85659	0.66149E-01	-12.95
TH1	-0.25232	0.12369	-2.04
BTH	-0.20009	0.96936E-01	-2.06
Parámetros determinísticos			
EAST	-0.30956E-01	0.01264	-2.45
(35) TC (11 2008)	-0.17453	(0.03295)	-5.30
(73) TC (1 2012)	-0.14451	(0.03294)	-4.39
(99) AO (3 2014)	0.92696E-01	(0.02999)	3.09

d) Verificación

El error estándar residual es de este modelo es de 4.34%, valor utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. Este error residual se interpreta en porcentajes debido a que la serie fue transformada a logaritmos.

Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad y estacionariedad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=0.359). No se rechaza la hipótesis de que la media de los residuos es cero $H_0:\mu=0$ ($t=1.047$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa: la $\text{Prob}(Q_{12})=0.68$, $\text{Prob}(Q_{24})=0.53$ y $\text{Prob}(Q_{36})=0.63$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual e indican que no hay problema de heterocedasticidad: $\text{Prob}(Q_{12})=0.35$, $\text{Prob}(Q_{24})=0.43$ y $\text{Prob}(Q_{36})=0.57$.

F) Modelo ARIMA para el PIB trimestral agropecuario de Panamá

a) Estacionariedad

Gráfico 3.39: PIBT agropecuario de PA

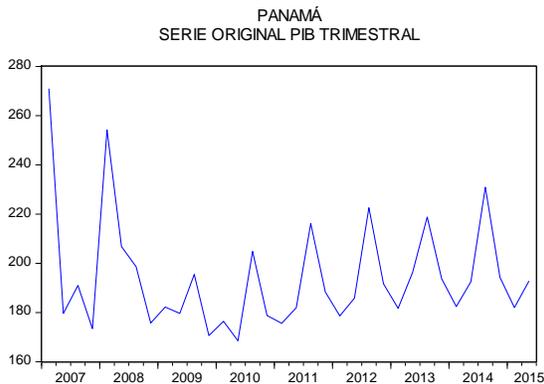
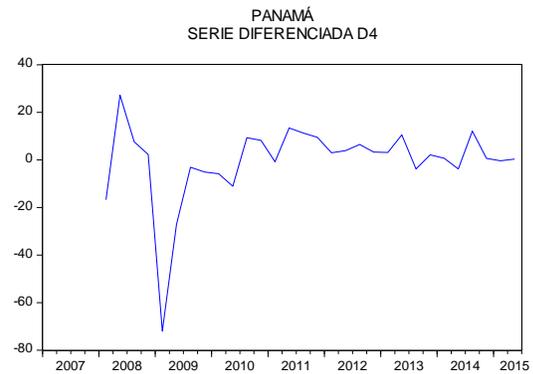


Gráfico 3.40: D4 PIBT agropecuario de PA



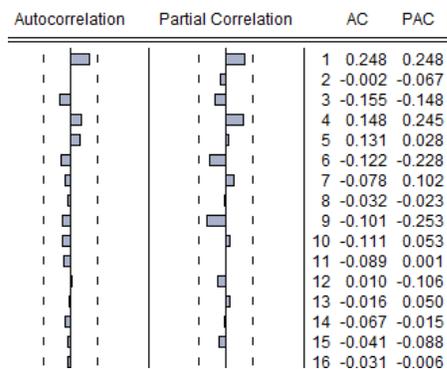
La serie del PIB trimestral del sector agropecuario de Panamá presenta un fuerte componente estacional pero no muestra una tendencia marcada. De hecho, las pruebas de raíces unitarias de la Sección 3.2 indican que la serie es estacionaria. Si se mira el correlograma de la serie original (anexo 4), se ratifica que la serie es estacionaria. Esto quiere decir que se requiere únicamente de una diferenciación en el componente estacional y no de diferenciaciones con los trimestres adyacentes. La serie diferenciada $D=4$ se muestra en el gráfico 3.40, en el cual se observa que la serie oscila alrededor de una media cercana a cero. También se observa en este gráfico la presencia de valores extremos al inicio de la serie, que son el reflejo del valor tan alto del primer trimestre de

2007. La prueba de igualdad de variancias de la tabla 3.2 indica la necesidad de una transformación en los datos para lograr una variancia más homogénea, ya que se rechaza la hipótesis de igualdad de variancias (prob=0.0274).

b) Identificación del modelo

La comparación de un correlograma de una serie trimestral con los patrones teóricos es mucho más complicada que para series mensuales. Se tienen únicamente 4 correlaciones para determinar el modelo de la parte regular. De tal modo, que para esta serie, se realizará una estimación inicial con un modelo muy preliminar, para luego ir realizando los ajustes. El modelo inicialmente propuesto es ARIMA(001)(011).

Gráfico 3.41: correlograma de D4 PIBT de PA



c) Resultados

El modelo ARIMA (001)(011) tuvo resultados satisfactorios superando la mayoría de los criterios de verificación. Los principales estadísticos se resumen en la tabla 3.18. La formulación final es la siguiente:

$$(1 - B^{12}) \log(PIBTPA) = wDummy1 + (1 - \theta_1 B^1)(1 - \theta_{12} B^{12})a_t \quad (13)$$

Un factor que resultó determinante para el buen ajuste del modelo, fue la incorporación de una variable artificial tipo “aditivo” en el I trimestre de 2009. Antes de la incorporación de esta variable, ningún modelo generaba resultados satisfactorios. El impacto es de una disminución de 13.6% en el nivel de la serie.

Tabla 3.18: Principales resultados modelo para PIBT de Panamá

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	0.34874	0.17253	2.02
BTH	0.43907	0.16540	2.65
Parámetros determinísticos			
(9) AO (1 2009)	-0.13637	(0.03248)	-4.20

d) Verificación

El error estándar residual es de este modelo es de 6.35%, valor utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. Este error residual se interpreta en porcentajes debido a que la serie fue transformada a logaritmos. Este valor es relativamente alto, debido a la alta variabilidad residual que se comenta más adelante.

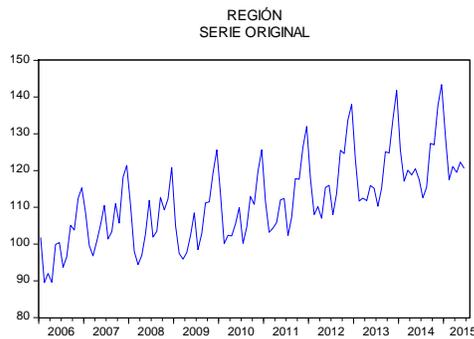
Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (BJ=3.75); sin embargo es el valor más alto de todos los modelos utilizados en este informe. No se rechaza la hipótesis de que la media de los residuos es cero $H_0: \mu=0$ ($t=0.229$). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa: la $\text{Prob}(Q_{12})=0.37$, $\text{Prob}(Q_{24})=0.29$ y $\text{Prob}(Q_{36})=0.64$. De forma inversa, la prueba Q aplicada a los residuos al cuadrado indica que no se cumple con el supuesto de homocedasticidad en los residuos. Los valores resultantes son: $\text{Prob}(Q_{12})=0.00$, $\text{Prob}(Q_{24})=0.01$ y $\text{Prob}(Q_{36})=0.05$. Sin duda, este modelo tiene como principal debilidad la alta variabilidad residual. Sin bien al inicio de la serie se observan los valores más extremos, no se optó por reducir el tamaño de la serie, debido a que la periodicidad trimestral ofrece muchas menos observaciones que cuando se trabaja con una serie mensual. Sin duda, una labor a futuro es eliminar algunos años al inicio de la serie cuando se cuente con un mayor número de observaciones.

G) Modelo ARIMA para el IMAE agropecuario Regional

a) Estacionariedad

La serie del IMAE agropecuario regional presenta un fuerte componente estacional y una marcada tendencia. Las pruebas de raíces unitarias de la Sección 3.2 indican que la serie es no estacionaria, de tal modo que será necesaria una diferenciación regular y una estacional. La prueba de igualdad de variancias de la tabla 3.2 indica que no hay diferencias significativas en la dispersión de los datos (prob=0.3233), por lo que a priori no se observa la necesidad de una transformación logarítmica.

Gráfico 3.42: IMAE agropecuario Regional



b) Identificación del modelo

Gráfico 3.43: correlograma de DID12 IMAE agropecuario RE

Autocorrelation	Partial Correlation	AC	PAC	
		1	-0.307	-0.307
		2	0.100	0.007
		3	-0.003	0.033
		4	-0.083	-0.083
		5	-0.054	-0.118
		6	-0.056	-0.108
		7	-0.076	-0.126
		8	0.201	0.163
		9	-0.074	0.037
		10	-0.035	-0.110
		11	0.102	0.030
		12	-0.324	-0.313
		13	0.173	0.004
		14	-0.120	-0.023
		15	-0.000	-0.043
		16	0.058	-0.039
		17	0.054	0.023
		18	0.113	0.146
		19	0.028	0.047
		20	-0.175	-0.102
		21	0.076	-0.071
		22	-0.125	-0.125
		23	-0.001	0.033
		24	0.016	-0.059

Comparando los correlogramas (gráfico 3.43) con los patrones teóricos (Anexo 1) es difícil identificar el modelo apropiado tanto para la parte regular como la estacional. En estos casos se recomienda primero probar con un modelo de medias móviles y luego con uno autoregresivo. Con esto, los modelos propuestos son ARIMA (011) (011) y ARIMA (110)(011).

c) Resultados

El ARIMA (011)(011) tuvo resultados satisfactorios superando la etapa de verificación. Los principales estadísticos se resumen en la tabla 3.19. La formulación es la siguiente:

$$(1 - B)(1 - B^{12}) \log(IMAERE) = \frac{\omega 1}{(1 - \delta B)} Dummy1 + (1 - \theta_1 B^1)(1 - \theta_{12} B^{12}) a_t \quad (14)$$

La transformación logarítmica fue necesaria para mejorar el ajuste del modelo y los criterios de normalidad. Un factor que resultó determinante para el buen ajuste del modelo, fue la incorporación de una variable artificial tipo “cambio transitorio”, que inicia en febrero de 2014. El impacto inicial de ese fenómeno fue de un incremento de 2.85%, para luego ir disminuyendo durante varios meses. Antes de la incorporación de esta variable artificial, prevalecían correlaciones significativas en los primeros rezagos del correlograma de los residuos.

Tabla 3.19. Principales resultados modelo IMAE Región

Parámetro	valor	Error estándar	t-value
Parámetros estocásticos			
TH1	-0.38522	0.11526	-3.34
BTH	-0.35254	0.11688	-3.02
Parámetros determinísticos			
(62) TC (2 2014)	0.28544E-01	(0.01274)	2.24

d) Verificación

El error estándar residual es de este modelo es de 1.63%, valor utilizado en el cálculo de las bandas de confianza alrededor del pronóstico fuera de la muestra. Este error residual se interpreta en porcentajes debido a que la serie fue transformada a logaritmos.

Los parámetros del modelo son significativamente distintos de cero y cumplen con las condiciones de invertibilidad. Los residuos se distribuyen normalmente, según el estadístico Bera-Jarque (1.023). No se rechaza la hipótesis de que la media de los residuos es cero $H_0:\mu=0$ (-0.53). La prueba Q de Box-Pierce muestra que no hay autocorrelación residual significativa: la $\text{Prob}(Q_{12})=0.58$, $\text{Prob}(Q_{24})=0.74$ y $\text{Prob}(Q_{36})=0.36$. De modo similar, la prueba Q aplicada a los residuos al cuadrado permiten evaluar el comportamiento de la variancia residual e indican que no hay problema de heterocedasticidad: $\text{Prob}(Q_{12})=0.34$, $\text{Prob}(Q_{24})=0.32$ y $\text{Prob}(Q_{36})=0.14$.

H) Resumen modelos ARIMA para las variables de producción agropecuaria

En la tabla 3.20 se resumen las principales características de los modelos ARIMA identificados para las variables de producción agropecuaria. Se destaca lo siguiente:

- En todos los modelos la constante no es significativa.
- Todas las series tienen estacionalidad y en todos los modelos se captura mediante un esquema del tipo (0,1,1).
- La semana santa es significativa únicamente para la serie de Nicaragua. Si bien la semana santa es importante en las variables de producción nacional, no lo es en la mayoría de las series de producción agropecuaria.
- Los días hábiles no resultaron significativos para ninguna serie.
- El error estándar residual oscila en un rango de 1.63% a 6.35%. Si se comparan únicamente los indicadores mensuales el rango va de 1.63% a 4.59%.

Tabla 3.20.: Resumen modelos ARIMA para la producción agropecuaria

País	Periodo de datos	modelo	Constan- te	log arit- mo	TD R	SS	Estaci- onalid- ad? ^{1/}	OUTLIERS	Error residual
Costa Rica	Ene.2006 jul.2015	(011)(011)	no	no	no	no	si	AO mar.2010 TC jul.2011	8.19 ^{2/}
El Salvador	Ene.2006 jul.2015	(100)(011)	no	no	no	no	si	TC ene.2009 TC jun.2012 TC ene.2013	3.45 ^{3/}
Guatemala	Ene.2009 jun.2015	(011)(011)	no	si	no	no	si	AO abr.2012	2.08%
Honduras	Ene.2006 jul.2015	(011)(011)	no	si	no	no	si	AO nov.2012 AO dic.2013	4.59%
Nicaragua	Ene.2006 jul.2015	(101)(011)	no	si	no	si	si	TC nov.2008 TC ene.2012 AO mar.2014	4.34%
Panamá	I trim.2007 II trim.2015	(001)(011)	no	si	no	no	si	AO 2009Q1	6.35%
Región	Ene.2009 jun.2015	(011)(011)	no	si	no	no	si	TC feb.2014	1.63%

1/ Corresponde a la prueba “overall test for identifiable seasonality” que aplica TSW+ a la serie original.

2/ El error residual para Costa Rica corresponde a un 4.16% si se le compara con la última observación, o a un 3.9% si se le compara con el promedio 2015.

3/ El error residual para El Salvador corresponde a un 2.14% si se le compara con la última observación, o a un 2.83% si se le compara con el promedio 2015

Fuente: elaboración propia.

En este capítulo se presentaron los modelos ARIMA identificados para cada serie. Estos modelos serán utilizados en los capítulos siguientes para el pronóstico y para la extracción de los componentes tendencia, ciclo y estacional. Para llegar a estos modelos fue necesario un análisis previo que incluye el gráfico lineal, los correlogramas, las pruebas de integración y las pruebas de igualdad de variancias. Todo ello se presentó en forma resumida en este capítulo y en forma detallada en los anexos 4 a 9.

CAPÍTULO IV: ANÁLISIS DEL COMPONENTE ESTACIONAL

4.1 Introducción

Siguiendo a Maravall (1999), el tratamiento estadístico de series de tiempo tiene como propósito responder a dos preguntas: *¿dónde estamos?* y *¿hacia dónde vamos?*.

La primera pregunta (*¿dónde estamos?*) sugiere la aplicación de técnicas de ajuste estacional y de estimación de la tendencia, que permiten aislar el ruido que existe al interior del año y extraer una señal clara (subyacente) que indique si la variable está en un periodo de expansión, contracción o en un punto de inflexión. Así por ejemplo, aun cuando se observen tasas de variación intermensuales negativas en los últimos meses, no necesariamente se está ante una desaceleración de una variable económica; ese comportamiento podría estar explicado por el hecho de que hay un componente estacional¹⁷ que produce las bajas en el nivel de la serie en esos meses, aun cuando haya una senda positiva de crecimiento. De hecho, en series macroeconómicas mensuales es frecuente que el componente estacional domine la variabilidad de la serie.

Los análisis con series ajustadas o desestacionalizadas dieron inicio con el cálculo de indicadores de alta frecuencia. En tanto que en las series anuales la estacionalidad no existe (debido a que es un ciclo que se cancela durante el año), este tema es muy relevante en una serie trimestral o mensual de la misma variable. Por consiguiente, resulta de sumo interés para el análisis económico de coyuntura y sus aplicaciones, ya que a partir de la lectura de series desestacionalizadas de indicadores como la inflación y la producción, pueden llegar a desprenderse importantes decisiones en materia de política macroeconómica y sectorial.

¹⁷ La estacionalidad es el movimiento que se produce dentro del año y que se repite de un año a otro. Está presente en la gran mayoría de series de periodicidad subanual y en un inicio estuvo asociado casi exclusivamente a los fenómenos naturales climáticos. De ahí derivó su nombre.

Bajo ese espíritu, en este capítulo se estima el componente estacional de las series utilizadas en este estudio; se interpreta el componente estacional del último año completo y se presenta y analiza la serie desestacionalizada, tanto en niveles como en tasas de variación.

En la sección 4.1 se explica que la mayoría de los índices de precios al consumidor del grupo alimentos no presentan estacionalidad y están dominados por la tendencia; se exceptúa el IPC de alimentos de Costa Rica que muestra una leve estacionalidad. En la sección 4.2 se muestra el componente estacional de los indicadores de corto plazo de la producción agropecuaria, el cual resulta muy fuerte y claramente identificable. En ambas secciones se utilizó TSW+ para extraer los componentes de la serie, utilizando a la vez los modelos ARIMA que fueron identificados en el capítulo III.

4.2. El componente estacional del índice de precios de alimentos

En el análisis económico de variables mensuales es frecuente el uso de técnicas de ajuste estacional para estimar los componentes de una serie de tiempo: estacionalidad, tendencia, ciclo e irregular. Sin embargo, algunos de esos componentes podrían resultar poco relevantes para una determinada variable. En efecto, tal como se indicó en el capítulo III, los modelos ARIMA ajustados a los índices de precios de alimentos únicamente encontraron evidencia de estacionalidad para el caso de Costa Rica (ver tabla 3.12); para el resto de países la estacionalidad no fue identificable.

Esto significa que el ajuste estacional no aplica para series que no tienen un componente estacional significativo.

A) IPC de alimentos de Costa Rica

Tal como se observó en la etapa de análisis previo de las series, sección 3.2, el IPC de alimentos de Costa Rica tiene un componente estacional significativo (ver tabla 3.5). Esto se observa en el gráfico 4.1, donde se agrupan los datos por mes y se confirma con los factores estacionales obtenidos para la serie. En efecto, en el gráfico 4.2 se muestran

los índices estacionales de 2014¹⁸, donde se observa que el IPC de alimentos se incrementa en la última parte del año, principalmente en agosto, y disminuye a inicios de año.

Estos índices se pueden interpretar como porcentajes, de modo que valores por arriba de 100 señalan los meses donde los precios suben por el efecto estacional, y los valores debajo de 100 corresponden a meses donde los precios disminuyen por la misma razón. De éstos, marzo representa la mayor disminución de los precios de alimentos (99.2) representando una caída de 0.8%. Por otro lado, agosto es el mes con mayor aumento de precios (100.6) que representa un aumento de 0.6% respecto al nivel medio de la serie. En junio (100) no hay efecto estacional en la serie.

Gráfico 4.1: Análisis previo del IPCA de CR

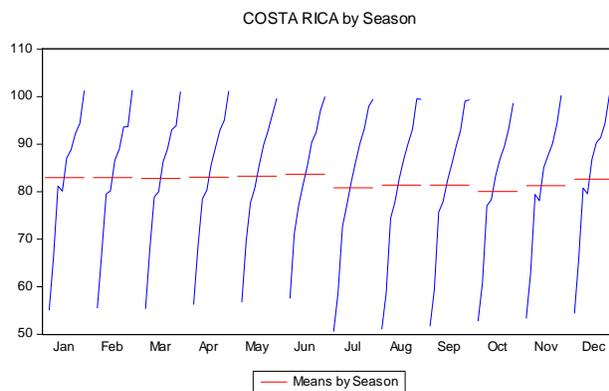


Gráfico 4.2: Factores estacionales de 2014

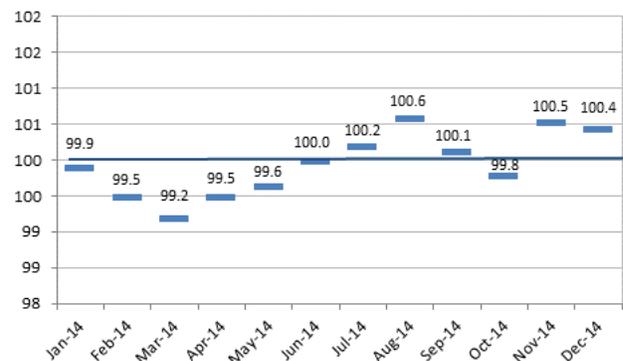


Gráfico 4.3: Componentes del IPCA de CR en niveles

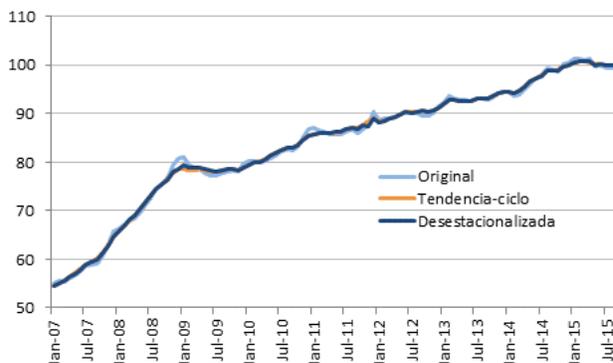
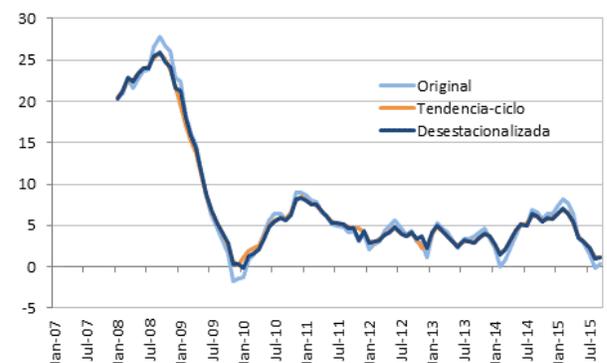


Gráfico 4.4: Componentes del IPCA de CR tasas de variación interanual



¹⁸ Se escoge 2014 por ser el último año completo. Debido a que la estacionalidad es móvil en el tiempo, se acostumbra utilizar el último año para analizar el comportamiento estacional más reciente.

El componente estacional es pequeño; esto resulta claro en el gráfico 4.3, donde la serie original y la serie desestacionalizada son prácticamente iguales. Lo mismo ocurre con la serie en tendencia-ciclo.

Debido a que el interés se centra no en el nivel del índice de precios, sino en su variación interanual (ritmo inflacionario), en el gráfico 4.4 se muestra esta tasa. De nuevo, las tres series son muy parecidas, pero en este caso se revelan los **ciclos de crecimiento** donde se aprecia que a finales de 2009 se da una caída drástica de los precios de alimentos, posiblemente provocada por la crisis mundial que inició en 2008. Más recientemente, a finales de 2015 se nota que la caída de los precios está alcanzando su mínimo, poniendo fin al ciclo corto que inició en 2014.

B) IPC de alimentos del resto de países

Tal como se observó en la etapa de análisis previo de las series de la sección 3.2, y que se resume en la tabla 3.12, el IPC de alimentos del resto de países no tiene estacionalidad. Las pruebas de evidencia de estacionalidad rechazaron la existencia de este componente y no se identificó ningún parámetro estocástico en la parte estacional de los modelos ARIMA. En el gráfico 4.5 se muestran los datos del IPC de alimentos de cada país agrupados por mes para evidenciar que el promedio no muestra diferencias importantes de un mes a otro.

Dado lo anterior, en estos casos no se puede hablar de series desestacionalizadas toda vez que las series no tienen estacionalidad. No obstante, se puede estimar la tendencia-ciclo con el único fin de aislar el componente irregular de la serie. En el gráfico 4.6 se muestra la tasa de variación interanual de la serie original y de la tendencia-ciclo (ritmo inflacionario).

La tasa de variación interanual sobre la tendencia-ciclo se puede interpretar como **ciclos de crecimiento**, que se miden de mínimo a mínimo; de hecho, la mayoría de países evidencian que a septiembre 2015 se está llegando al final de un ciclo que inició en los

primeros meses de 2014. Llama la atención el comportamiento de la serie de Panamá, que tiene un patrón diferente al del resto de países; en el periodo analizado no se observan ciclos de crecimiento y pareciera que solamente se observa la parte de desaceleración de un ciclo que es más amplio que el periodo de datos analizado. A nivel regional se aprecian dos ciclos completos, cada uno de aproximadamente un año y medio de duración. De tal modo que para responder a la pregunta *a dónde estamos?*, se puede decir que, a septiembre de 2015, la región está al final de un ciclo, que parece haber alcanzado su mínimo y que ya da muestras de aceleración en los precios al consumidor del grupo alimentos en algunos países.

Gráfico 4.5: Análisis previo del IPC alimentos, por país

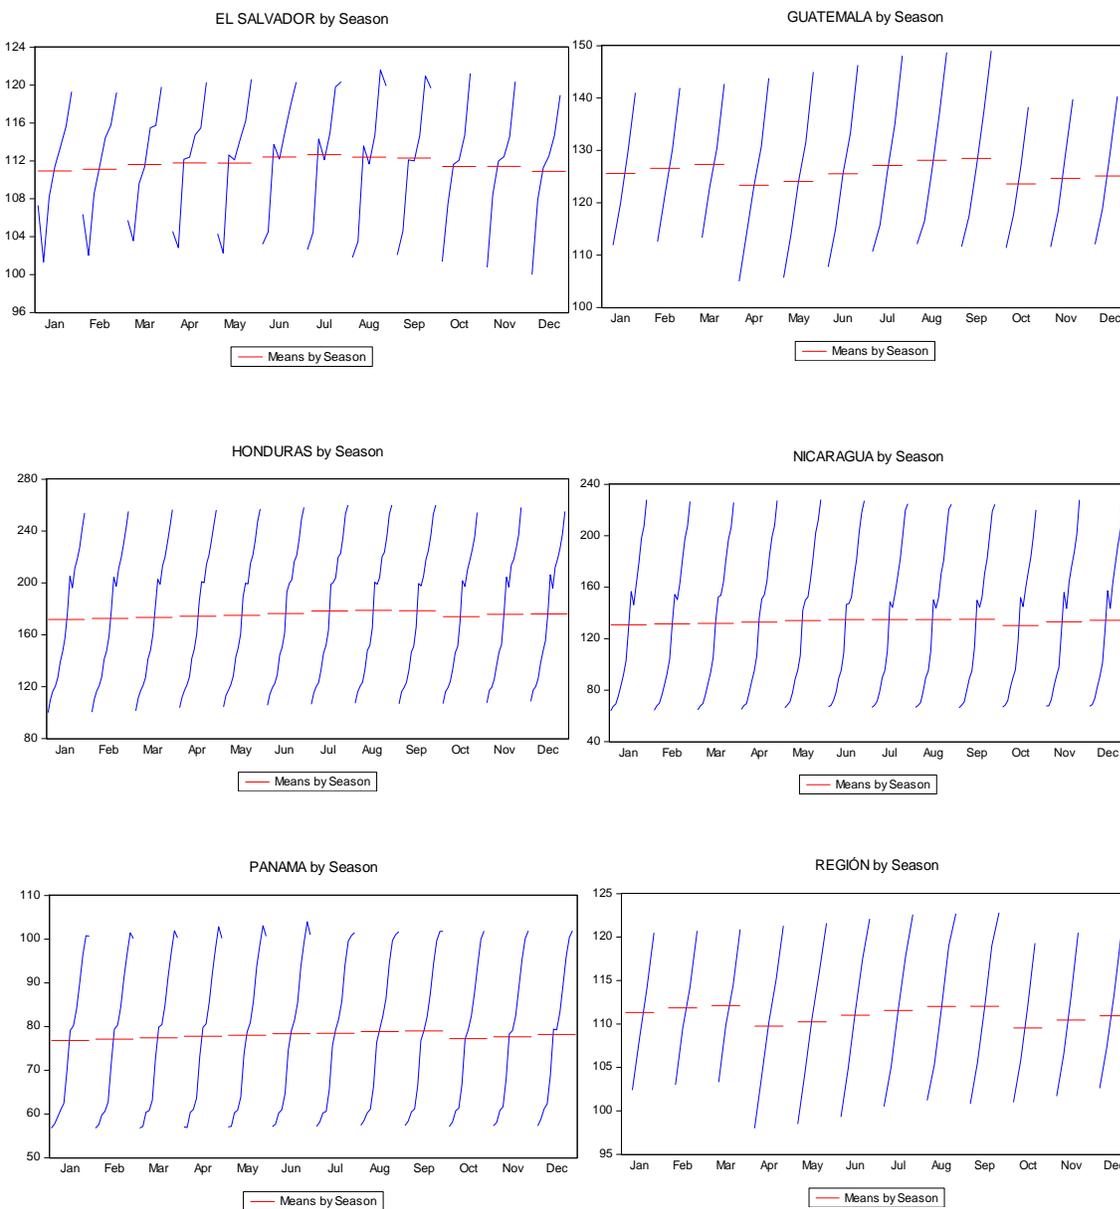
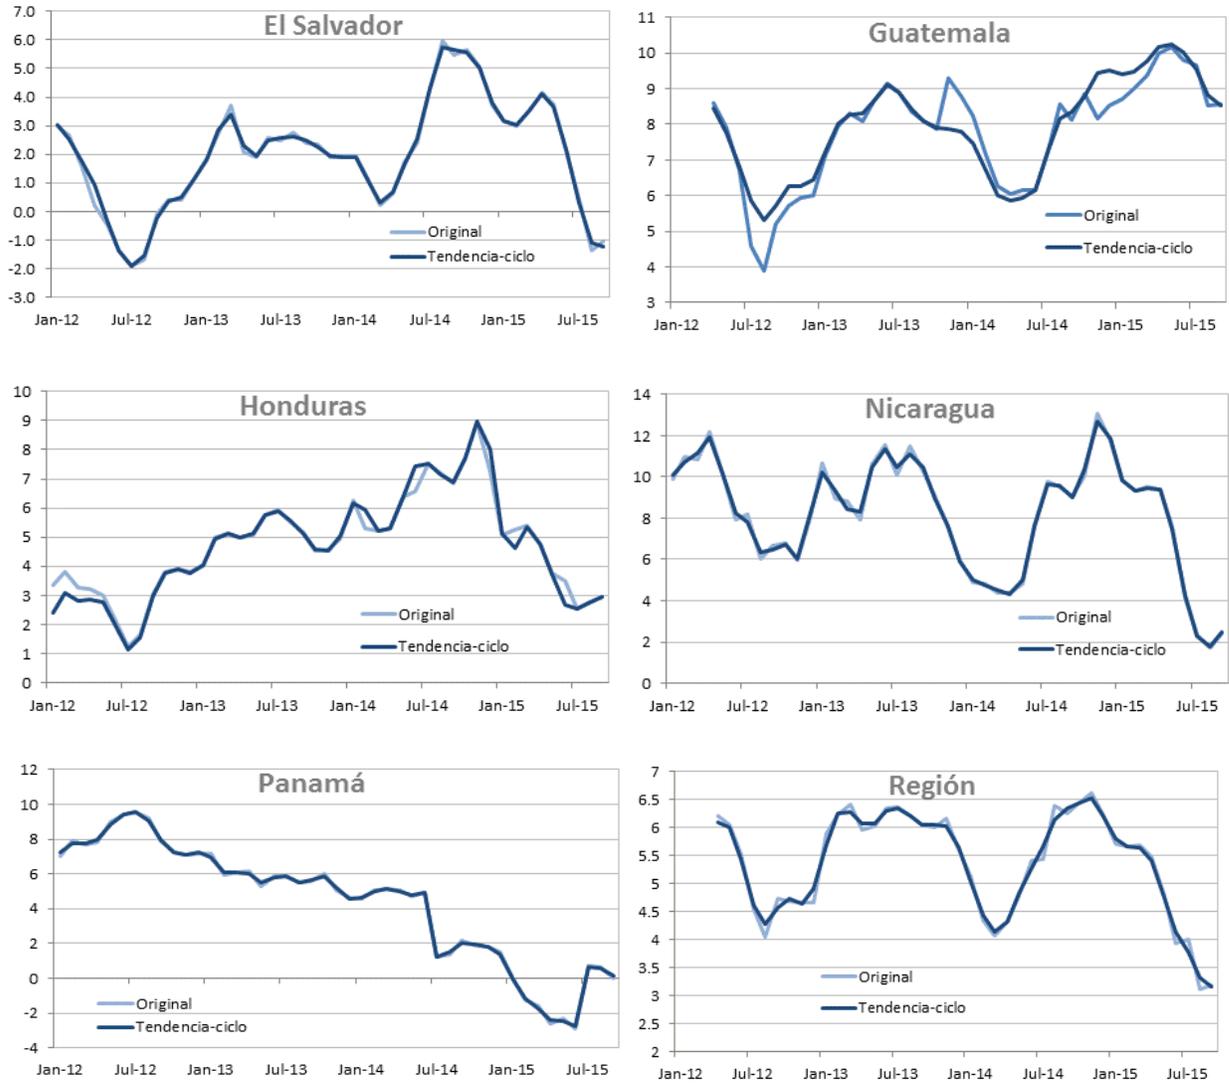


Gráfico 4.6: Componentes del IPC de alimentos, por país
 Tasa de variación interanual
 enero 2012 a septiembre de 2015



4.3. El componente estacional de la actividad agropecuaria

Como se ha mencionado anteriormente, resulta de gran interés estimar los componentes de una serie para luego aislarlos de los valores originales y de ese modo realizar los análisis no sobre la serie original, sino sobre series que no incluyen el componente irregular, el estacional o ambos. En la actividad agropecuaria este procedimiento es especialmente importante debido a la importancia del componente estacional, derivado principalmente del impacto que tienen las estaciones climáticas en el sector agropecuario.

A continuación se presentan componentes obtenidos para el IMAE del sector agropecuario de los países centroamericanos y para el PIB trimestral agropecuario de Panamá. También se realiza este cálculo para el indicador regional agropecuario.

A) IMAE agropecuario de Costa Rica

Tal como se observó en la etapa de análisis previo de las series, sección 3.2, el IMAE agropecuario de Costa Rica tiene un componente estacional que es muy importante (ver tabla 3.20). Esto se observa claramente en el gráfico 4.7, donde se agrupan los datos por meses y se confirma con los factores estacionales obtenidos para la serie. En efecto, en el gráfico 4.8 se muestran los factores estacionales de 2014¹⁹, donde se aprecia que la actividad agropecuaria se incrementa en los cinco primeros meses del año y disminuye en los siete meses restantes, por efectos estacionales. De éstos, marzo representa el mayor aumento en la producción agropecuaria con 34 puntos (que representa un aumento de 16.8% con respecto al nivel medio de 2014) y agosto muestra la mayor disminución en casi 18 puntos (que representa una disminución de -8.9% con respecto al nivel medio de 2014).

Esto significa que si se le da un seguimiento mensual a la producción agropecuaria, los valores altos que se observen en marzo no necesariamente van a representar un incremento en la producción, ya que en ese mes se espera un crecimiento importante

¹⁹ Se escoge 2014 por ser el último año completo. Debido a que la estacionalidad es móvil en el tiempo, se acostumbra utilizar el último año para analizar el comportamiento estacional reciente.

debido a razones estacionales. Este mismo cuidado hay que tenerlo para todos los meses del año. De tal modo que la evolución subyacente solamente se observará si se analiza la serie desestacionalizada o la tendencia-ciclo.

Es importante mencionar que los factores estacionales para el IMAE agropecuario de Costa Rica fueron construidos con un modelo aditivo, de tal forma que el factor estacional está medido como puntos del índice. Estos factores no se pueden interpretar como porcentajes porque no fueron construidos con un modelo multiplicativo. Sin embargo, se puede realizar un análisis porcentual si cada factor estacional se compara con el valor promedio del IMAE del año al que corresponden.

Gráfico 4.7: Análisis previo del IMAEA de CR

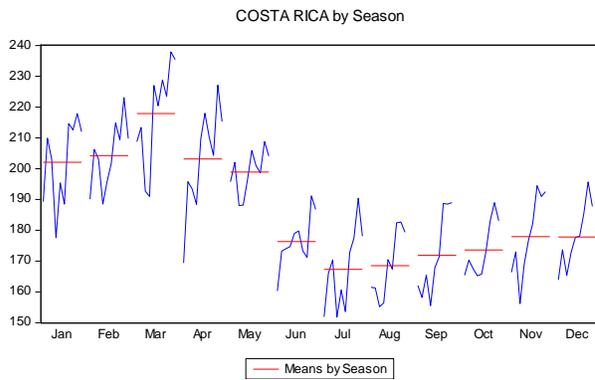


Gráfico 4.8: Factores estacionales de 2014

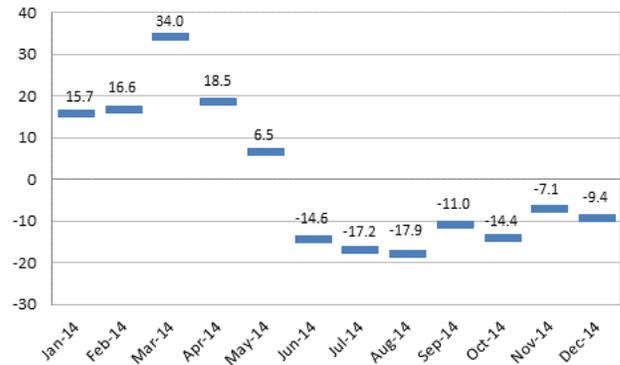


Gráfico 4.9: Componentes del IMAEA de CR en niveles

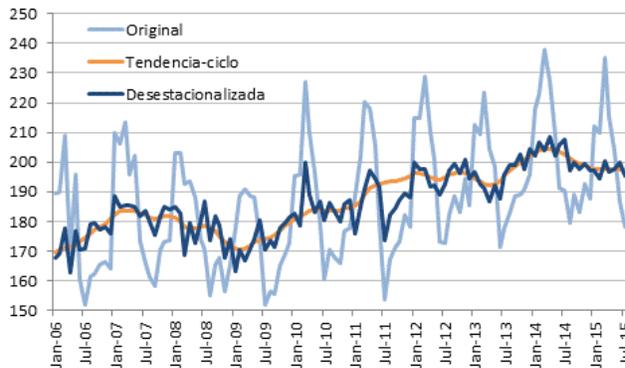
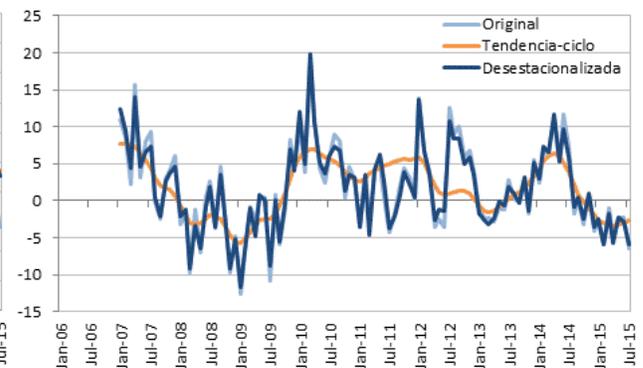


Gráfico 4.10: Componentes del IMAEA de CR tasas de variación interanual



En el gráfico 4.9 se observa como la serie desestacionalizada ha aislado los fenómenos estacionales para mostrar la tendencia-ciclo más el componente irregular. Como un paso adicional, la serie en tendencia-ciclo aísla además los movimientos irregulares, permitiendo observar la verdadera evolución de la serie.

En este tipo de indicadores, más que el nivel de la serie, interesa su tasa de crecimiento. En el gráfico 4.10 se presenta la tasa de variación interanual sobre la tendencia-ciclo, la cual se puede interpretar como **ciclos de crecimiento**, que se miden de mínimo a mínimo. Analizando el gráfico se observa una caída en la actividad productiva a finales de 2008, una recuperación que da lugar a un nuevo ciclo a inicios de 2009 y que termina a inicios de 2013, y finalmente, un ciclo corto que va de 2013 y que termina en el primer semestre de 2015, a partir de donde se empieza a observar una recuperación de la actividad agropecuaria.

B) IMAE agropecuario de El Salvador

El IMAE agropecuario de El Salvador también tiene un componente estacional que es importante, tal como se mostró en el análisis previo de la serie (tabla 3.20). Esto se observa claramente en el gráfico 4.11, donde se agrupan los datos por mes para mostrar que el promedio varía de un mes a otro. Los factores estacionales obtenidos para la serie confirman lo observado; para ilustrarlo, en el gráfico 4.12 se muestran los factores estacionales (aditivos) de 2014. Estos factores indican que la actividad agropecuaria está influenciada por movimientos estacionales durante todo el año; se incrementa mucho durante el tercer trimestre del año y disminuye a inicios de año. Junio es el mes con el mayor incremento por estacionalidad, aumentando el nivel de la serie en casi 53 puntos (lo que representa un incremento de 44% respecto del valor medio de 2014) y febrero es el mes con la mayor disminución, pues el nivel medio de la serie disminuye 33 puntos (que representa un -28%).

Los factores estacionales para el IMAE agropecuario de El Salvador fueron construidos con un modelo aditivo, de tal forma que el factor es un valor absoluto, medido como puntos del índice. Para realizar un análisis porcentual se ha comparado el factor estacional con el valor promedio del IMAE del año al que corresponden.

Gráfico 4.11: Análisis previo del IMAEA de SV

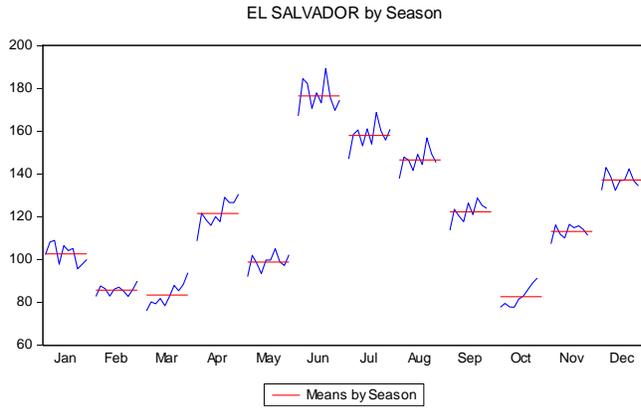


Gráfico 4.12: Factores estacionales de 2014

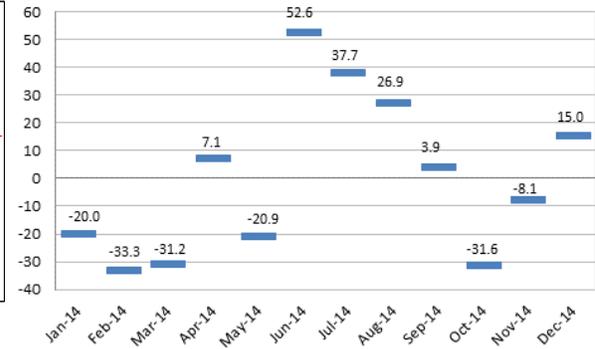


Gráfico 4.13: Componentes del IMAEA de SV en niveles

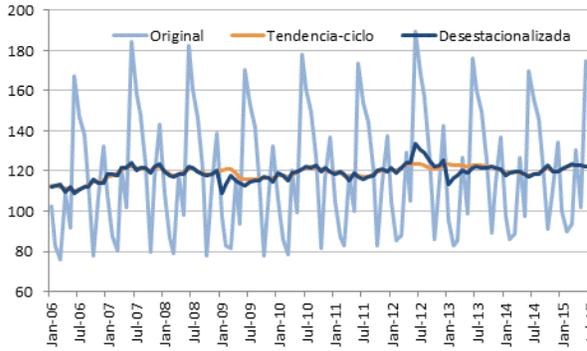
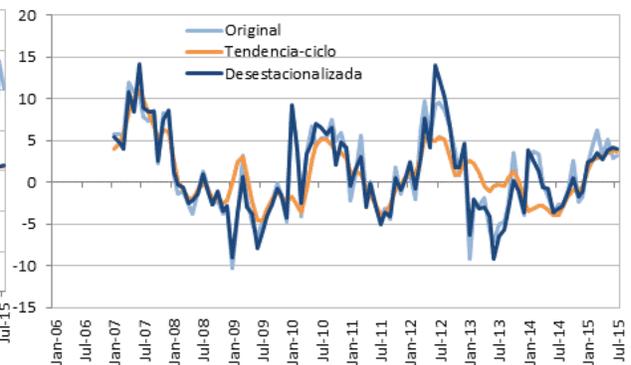


Gráfico 4.14: Componentes del IMAEA de SV tasas de variación interanual



En el gráfico 4.13 se observa como la serie desestacionalizada aísla los fuertes movimientos estacionales para mostrar la tendencia-ciclo más el componente irregular. Como un paso adicional, la serie en tendencia-ciclo, aísla los movimientos irregulares, permitiendo observar la verdadera evolución de la serie. Es interesante notar como la mayor parte de los movimientos se deben a la estacionalidad.

En este tipo de indicadores, más que el nivel de la serie, interesa su tasa de crecimiento. La tasa de variación interanual sobre la tendencia-ciclo se puede interpretar como **ciclos de crecimiento**, que se miden de mínimo a mínimo; es así como en el gráfico 4.14 se observan varios ciclos de crecimiento, el último de ellos que va de la mitad de 2011 a la mitad de 2014. A julio de 2015 la serie de producción agropecuaria de El Salvador se encuentra en una fase de aceleración y presenta indicios de acercarse al máximo de un ciclo que recién inició a mitad de 2014.

C) IMAE agropecuario de Guatemala

Tal como se observó en la etapa de análisis previo de las series, el IMAE agropecuario de Guatemala tiene un componente estacional que es importante (tabla 3.20). Esto se observa claramente en el gráfico 4.15, donde se agrupan los datos por mes para mostrar que los promedios difieren significativamente de un mes a otro. Al calcular los factores estacionales (multiplicativos) se comprueba la importancia del componente estacional. En efecto, en el gráfico 4.16 se muestran los factores estacionales de 2014, donde la actividad agropecuaria se incrementa en enero y en los últimos cuatro meses del año y disminuye en el resto del año. Diciembre es el mes con mayor aumento en la producción agropecuaria, aumentando un 24.8% por efectos estacionales, mientras que julio muestra la mayor disminución en casi -20%.

Estos factores estacionales pueden interpretarse en porcentajes respecto al nivel medio de la serie del año correspondiente, debido a que fueron construidos con un modelo multiplicativo.

Gráfico 4.15: Análisis previo del IMAEA de GT

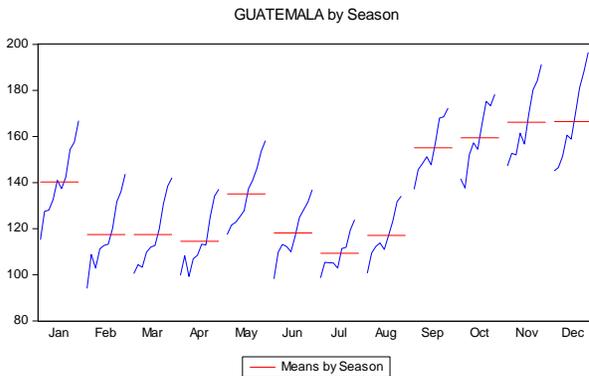


Gráfico 4.16: Factores estacionales de 2014

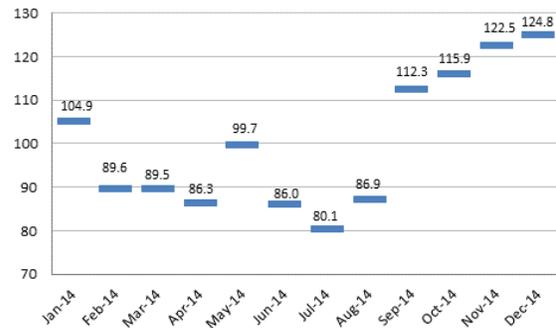


Gráfico 4.17: Componentes del IMAEA de GT en niveles

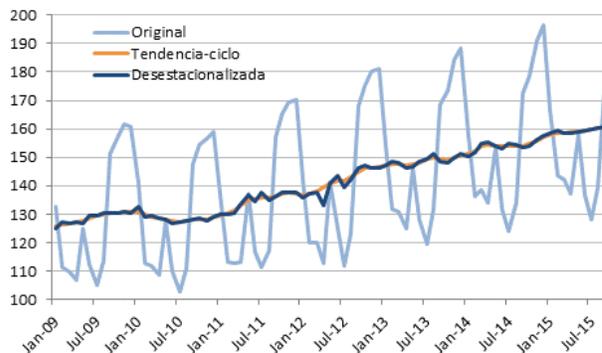
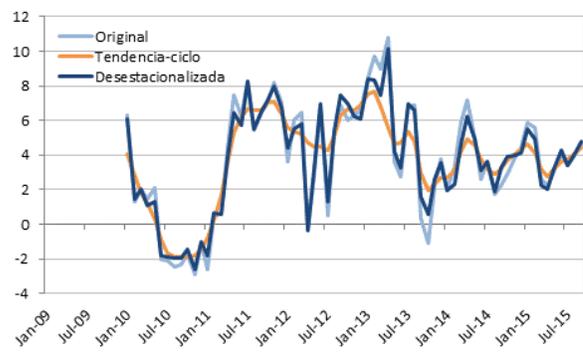


Gráfico 4.18: Componentes del IMAEA de GT tasas de variación interanual



En el gráfico 4.17 se muestra como la serie desestacionalizada aísla los movimientos estacionales para mostrar la tendencia-ciclo más el componente irregular. Como un paso adicional, la serie en tendencia-ciclo, aísla los movimientos irregulares, permitiendo observar la verdadera evolución de la serie. Al igual que en los casos anteriores de Costa Rica y El Salvador, la mayor parte de los movimientos de IMAE de Guatemala se deben a fenómenos estacionales.

En el caso de un índice de producción el interés está enfocado en la tasa de variación y no en el nivel mismo del índice. Además, la tasa de variación interanual sobre la tendencia-ciclo se puede interpretar como **ciclos de crecimiento**, que se miden de mínimo a mínimo, y que se muestran en el gráfico 4.18. Se observa un ciclo largo que va de finales de 2010 a finales de 2013; luego, un ciclo que inicia a finales de 2013 y que no termina de concretarse. A junio de 2015 la actividad agropecuaria se encuentra en una fase de aceleración.

D) IMAE agropecuario de Honduras

Tal como se observó en la etapa de análisis previo de las series, el IMAE agropecuario de Honduras tiene un componente estacional que es importante (tabla 3.20). Esto se observa claramente en el gráfico 4.19, donde se agrupan los datos por mes y se nota que los promedios difieren notablemente de un mes a otro. Ese comportamiento se confirma con los factores estacionales que luego fueron obtenidos para la serie. En efecto, en el gráfico 4.20 se muestran los factores estacionales de 2014, donde se observa que la actividad agropecuaria se incrementa en los tres primeros y en los tres últimos meses del año y disminuye de abril a septiembre, por fenómenos que son estacionales. De éstos, febrero representa el mayor aumento en la producción agropecuaria con un 17.4% y julio muestra la mayor disminución con -31.7%. Estos factores estacionales se pueden interpretar como porcentajes porque fueron construidos con un modelo multiplicativo (oscilan alrededor del 100).

Gráfico 4.19: Análisis previo del IMAEA de HN

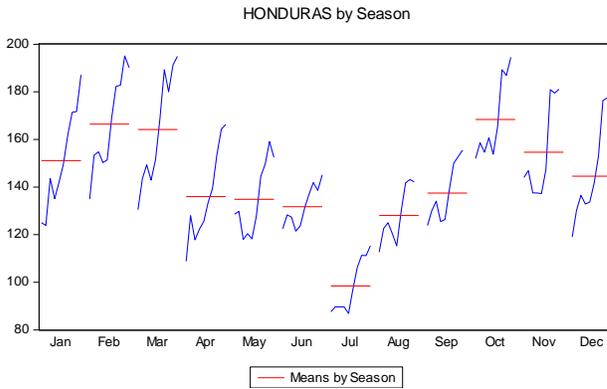


Gráfico 4.20: Factores estacionales de 2014

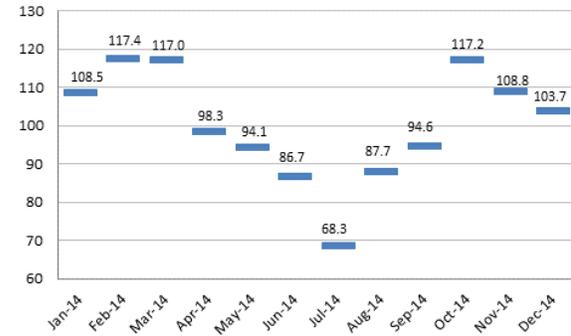


Gráfico 4.21: Componentes del IMAEA de HN en niveles

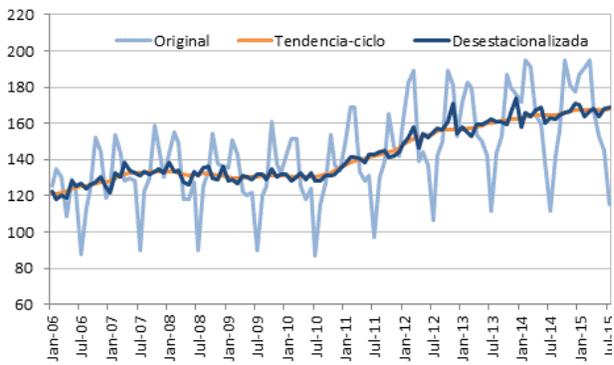
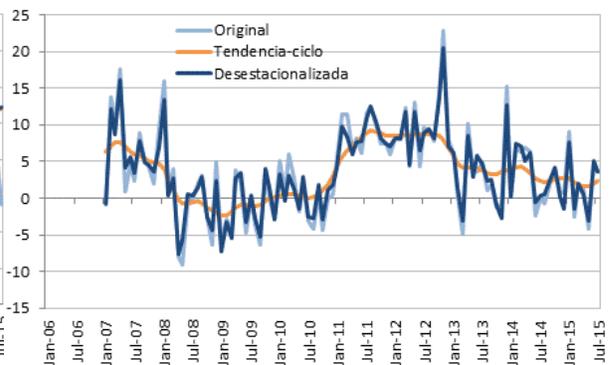


Gráfico 4.22: Componentes del IMAEA de HN tasas de variación interanual



En el gráfico 4.21 se observa como la serie desestacionalizada aísla los fenómenos estacionales para mostrar la tendencia-ciclo más el componente irregular. Como un paso adicional, la serie en tendencia-ciclo, aísla los movimientos irregulares, permitiendo observar la verdadera evolución de la serie. También para Honduras se observa que la mayor parte de la variabilidad de los datos se explica por el efecto de la estacionalidad.

De nuevo, interesa analizar la tasa de variación del IMAE más que su nivel, ya que la tasa de variación interanual sobre la tendencia-ciclo se puede interpretar como **ciclos de crecimiento**. Este cálculo se muestra en el gráfico 4.22 donde se observa que la actividad agropecuaria en Honduras inició un ciclo a inicios de 2009 que parece haber finalizado a mitad de 2015. A julio de 2015 la serie se encuentra en una etapa de aceleración.

E) IMAE agropecuario de Nicaragua

También el IMAE agropecuario de Nicaragua tiene un componente estacional que es importante, tal como se observó en la etapa de análisis previo de las series, (tabla 3.20). En el gráfico 4.23 se agrupan los datos por mes para mostrar que el promedio difiere considerablemente de un mes a otro. Los factores estacionales calculados confirman este comportamiento. En el gráfico 4.8 se muestran los factores estacionales de 2014, donde se aprecia que la actividad agropecuaria se incrementa principalmente en los meses de noviembre, diciembre y enero. En diciembre se da el mayor aumento en la actividad agropecuaria, 35.6% respecto al promedio de 2014, mientras que en abril se da la mayor disminución de -19.4%. Estos factores estacionales fueron construidos con un modelo multiplicativo, de tal forma que se pueden interpretar como porcentajes.

Gráfico 4.23: Análisis previo del IMAEA de NI

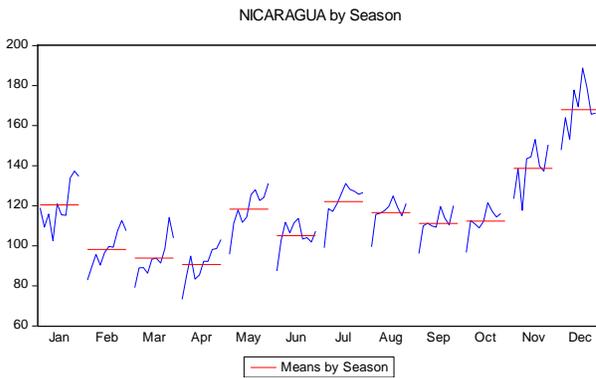


Gráfico 4.24: Factores estacionales de 2014

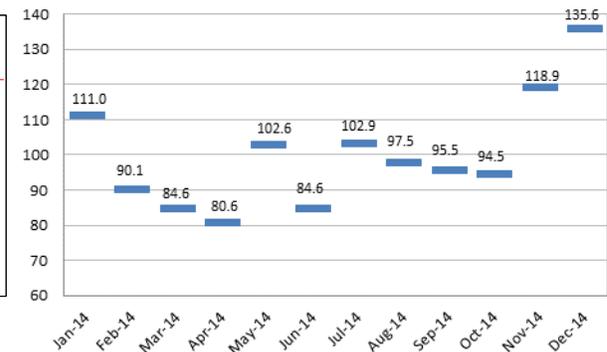


Gráfico 4.25: Componentes del IMAEA de NI en niveles

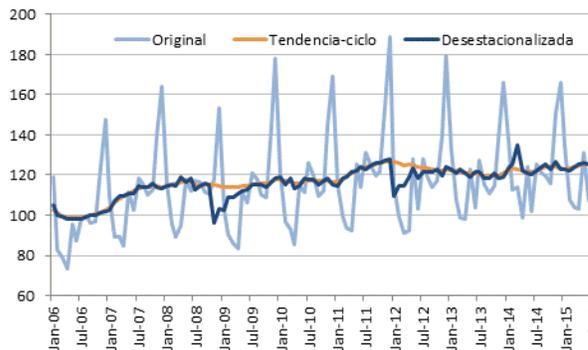


Gráfico 4.26: Componentes del IMAEA de NI tasas de variación interanual



En el gráfico 4.25 se observa como la serie desestacionalizada ha aislado los fenómenos estacionales para mostrar lo tendencia-ciclo más el componente irregular. De hecho, en la construcción del modelo ARIMA se identificaron tres fenómenos exógenos, en noviembre 2008, enero 2012 y marzo 2014, que se observan claramente en la serie desestacionalizada. Como un paso adicional, la serie en tendencia-ciclo, aísla esos movimientos irregulares, permitiendo observar la verdadera evolución de la serie.

El gráfico 4.26 presenta la tasa de variación interanual de la serie original, desestacionalizada y tendencia-ciclo; se observa el inicio de un ciclo a finales de 2012 que podría haber alcanzado el máximo a finales de 2014. A julio de 2015 la serie muestra señales de desaceleración.

F) PIB trimestral agropecuario de Panamá

En el caso de Panamá, se analiza el componente estacional del PIB trimestral del sector agropecuario, componente que también es muy significativo en esta serie (tabla 3.20). En el análisis previo, al graficar los datos agrupados por trimestre, se observan diferencias importantes entre las medias de los cuatro trimestres (gráfico 4.27). Posteriormente, al calcular los factores de estacionalidad, se ratifica el ciclo estacional en esta serie. En el gráfico 4.28 se muestran los factores estacionales de 2014, mostrando que la actividad productiva del sector agropecuario se incrementa en el tercer trimestre del año en un 13.6%. En el resto del año la actividad productiva está por debajo del promedio anual, especialmente en el primer trimestre que disminuye un 8.9% por fenómenos que son estacionales. Estos factores estacionales fueron construidos con un modelo multiplicativo, oscilan alrededor del 100, de modo que pueden ser interpretados como porcentajes respecto al nivel medio de la serie de ese año.

Gráfico 4.27: Análisis previo del IMAEA de PA

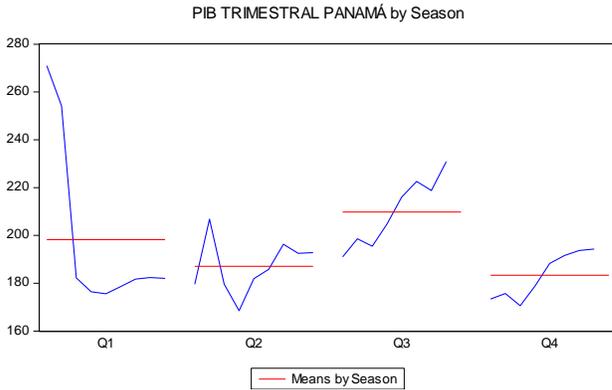


Gráfico 4.28: Factores estacionales de 2014

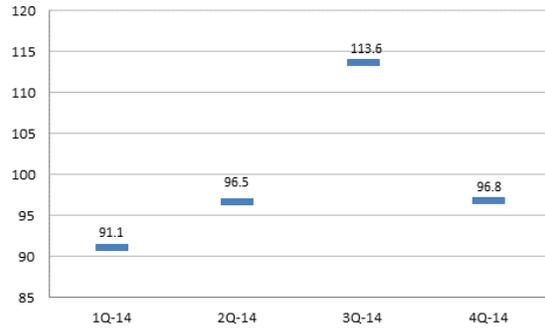


Gráfico 4.29: Componentes del IMAEA de PA en niveles

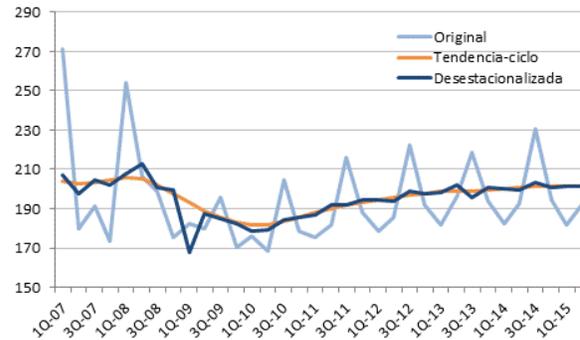
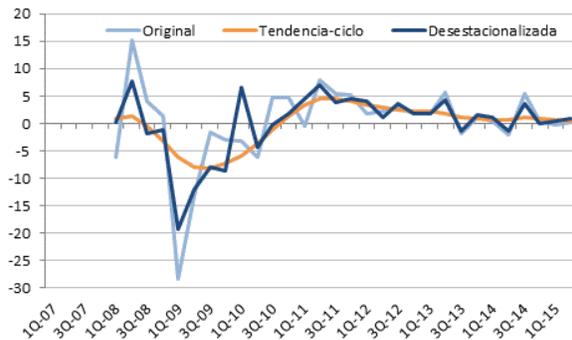


Gráfico 4.30: Componentes del IMAEA de PA tasas de variación interanual



En el gráfico 4.29 se observa como la serie desestacionalizada ha aislado los fenómenos estacionales para mostrar lo tendencia-ciclo más el componente irregular. De hecho, en la etapa de construcción del modelo ARIMA se determinó la presencia de un valor extremo en el primer trimestre de 2009; la serie desestacionalizada muestra un pico hacia abajo pues no elimina el componente irregular. La serie en tendencia-ciclo elimina la estacionalidad y los movimientos irregulares por lo que muestra una serie más suave.

También en el PIB trimestral el interés se centra en la tasa de variación interanual, además del valor de la producción. La tasa de variación interanual sobre la tendencia-ciclo se puede interpretar como **ciclos de crecimiento**, que se miden de mínimo a mínimo; es así como en el gráfico 4.30 se observa que luego de la caída de 2008, se inició un nuevo ciclo que no termina de definirse, pero que da señales de desaceleración y de alcanzar un mínimo pronto.

G) IMAE agropecuario de la Región

En el caso del IMAE agropecuario de la Región, calculado como un promedio ponderado de los índices de los países centroamericanos, persiste un componente estacional muy importante (analizado en la sección 3.4 y resumido en la tabla 3.20). En el gráfico 4.31 se agrupan los datos por mes para mostrar que el valor promedio difiere de un mes a otro. Además, en el gráfico 4.32 se muestran los factores estacionales de 2014, donde se observa que la actividad agropecuaria en la región se incrementa en enero y en los últimos cuatro meses del año, mientras que de febrero a agosto se mantiene por debajo del nivel medio del año (debajo del 100). Estos factores estacionales fueron construidos con un modelo multiplicativo, oscilan alrededor del 100, de modo que pueden ser interpretados como porcentajes respecto al nivel medio de la serie de ese año. De este modo se puede afirmar que en diciembre se da el mayor aumento de la producción agropecuaria, representando un 15.8% para el año 2014; mientras que en julio se da la mayor disminución del orden del -8.7%.

En el gráfico 4.33 se observa como la serie desestacionalizada aísla los fenómenos estacionales para mostrar la tendencia-ciclo más el componente irregular. Como un paso adicional, la serie en tendencia-ciclo, aísla los movimientos irregulares, permitiendo observar la verdadera evolución de la serie.

En el caso del PIB trimestral el interés está enfocado en la tasa de variación interanual, ya que se puede interpretar como **ciclos de crecimiento**. Estos cálculos se muestran en el gráfico 4.34, donde se aprecia que a nivel regional hay un ciclo bien definido que va de inicios de 2011 a finales de 2013. Desde ese punto se inicia un nuevo ciclo que pareciera no alcanzar aún el máximo, ya que a junio de 2015 aún se encuentra en la fase de aceleración.

Gráfico 4.31: Análisis previo del IMAEA de RE

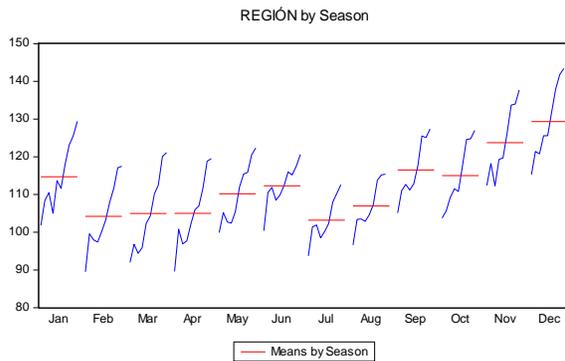


Gráfico 4.32: Factores estacionales de 2014

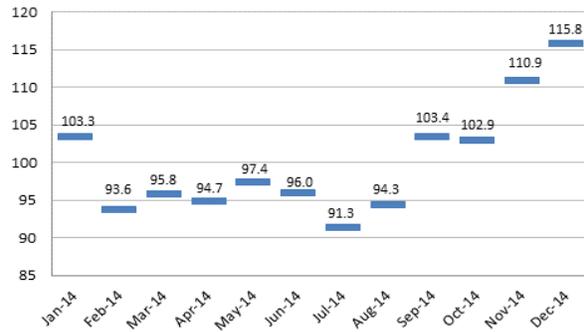


Gráfico 4.33: Componentes del IMAEA de RE en niveles

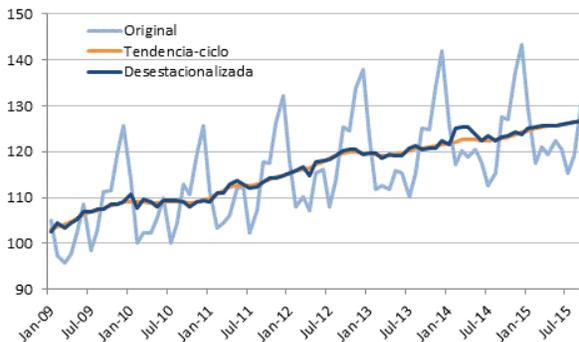
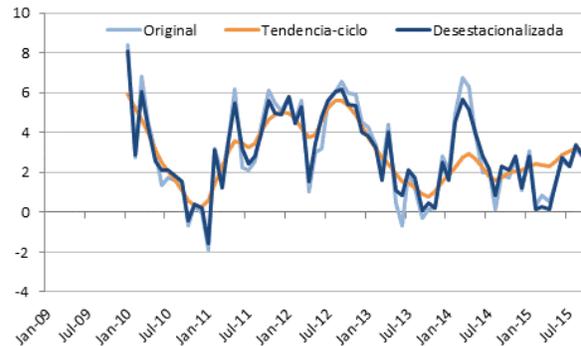


Gráfico 4.34: Componentes del IMAEA de RE tasas de variación interanual



4.4. Recomendaciones internacionales sobre el ajuste estacional

A continuación se presenta un resumen de las recomendaciones internacionales sobre el ajuste estacional de series de tiempo, provenientes de los manuales internacionales de referencia mundial. Se hace referencia a la política de revisiones cada vez que llega un nuevo dato, a la conveniencia de divulgar la serie desestacionalizada o la tendencia-ciclo y a los cuidados con los valores extremos detectados al final de la serie.

A) Sobre la política de revisiones

Cuando se utilizan o publican series desestacionalizadas surge la duda sobre la política de revisiones de los resultados anteriores cada vez que llega un nuevo dato.

Esta duda surge porque los métodos de estimación de los componentes de las series de tiempo hacen que varíen las estimaciones para t y para meses anteriores, cada vez que llegan nuevos datos. Las recomendaciones internacionales son las siguientes:

- El FMI (2013) recomienda el uso de revisiones concurrentes parciales como estrategia de ajuste estacional, con el fin de balancear las ventajas de incorporar nueva información al proceso de ajuste estacional y limitar la frecuencia y tamaño de las revisiones. Las revisiones concurrentes parciales sugieren que las opciones y modelos del componente estacional se re-especifiquen una vez al año, mientras que los parámetros son estimados cada vez que se tiene nueva información (concurrentemente).
- La Eurostat (2015) indica que la forma en que el ajuste estacional se lleva a cabo trae implicaciones sobre las revisiones de la serie desestacionalizada. Por tanto, cuando llega nueva información o los datos se revisaron por no más de dos años, se prefiere el ajuste parcial concurrente²⁰ para tomar en cuenta la nueva información y minimizar el tamaño de las revisiones. Cuando los datos se revisan por periodos mayores a dos años, el modelo, los filtros, los *outliers* y los parámetros de regresión deben ser re-identificados y re-estimados.
- Maravall (2009) sugiere la rutina de uso de Tramo-Seats para reducir la inestabilidad que se produce por las revisiones de la serie desestacionalizada.
 - i. Una vez al año el modelo completo es re-identificado (el cual con frecuencia no cambia). Se debe almacenar la información del orden del modelo p, d, q, BP, BD, BQ , la constante y la transformación logarítmica. Los valores extremos se deben fijar y se almacenan los parámetros de los ajustes por calendario.
 - ii. Para el resto del año solamente los coeficientes son re-estimados cada vez que se tiene nueva información.

²⁰ Se refiere a la estimación de los parámetros estocásticos y determinísticos del modelo cada vez que se tiene nueva información, pero sin cambiar la especificación del modelo.

- La re-estimación de los coeficientes siempre va a generar algunas revisiones en las estimaciones anteriores, pero estas revisiones son por lo general pequeñas. En todo caso, se puede siempre aplicar la regla de fijar los factores estacionales después de 3 años de revisiones y cambiar los valores únicamente hacia el final de la serie.

B) Sobre la publicación de la serie desestacionalizada y de la tendencia-ciclo

Al momento de extraer las señales de una serie de tiempo surge la duda sobre cuáles series se deberían presentar al usuario. Los manuales internacionales tienen recomendaciones sobre este particular.

- La Euroestad (2015) señala que las series desestacionalizadas son las más apropiadas para ser presentadas en las notas de prensa. Los usuarios deben tener acceso además a la serie original, la serie con ajustes de calendario y a la tendencia-ciclo.
 - i. Cuando se presenta la tendencia-ciclo, los valores más recientes no deben ser presentados por el *problema de cola*²¹, o al menos ser acompañados con una nota que indique este problema.
 - ii. Se debe incluir información sobre los errores de revisión de la serie desestacionalizada.
 - iii. Las tasas de crecimiento de periodos sucesivos se deben calcular sobre la serie desestacionalizada; las tasas de crecimiento interanuales deben ser calculadas sobre la serie original o sobre la serie ajustada de efectos de calendario.

²¹ Utilizando métodos de la familia X11, las estimaciones de la tendencia-ciclo de los segmentos más recientes pueden ser objeto de revisiones relativamente grandes cuando se efectúan las primeras actualizaciones, sin embargo, los estudios teóricos y empíricos indican que la tendencia-ciclo converge hacia el valor final mucho más rápidamente que las series ajustadas estacionalmente. En cambio, las series ajustadas estacionalmente pueden ser objeto de revisiones de menor orden, cuando se efectúan las primeras actualizaciones, pero exigir revisiones significativas incluso uno o dos años después. Esto se denomina el “**efecto de cola**”. Pág. 156, FMI (2001).

- iv. Es aceptable presentar la serie desestacionalizada y la tendencia-ciclo en un gráfico, indicando el *problema de cola*.
 - v. La tasa de variación interanual sobre la serie desestacionalizada puede ser presentada en caso sea demandada por los usuarios.
- El FMI (2001) señala que el ajuste estacional elimina la fluctuación estacional para poner de relieve las tendencias subyacentes y los movimientos de corto plazo de la serie. El propósito no es suavizar la serie, que es el objetivo de la tendencia-ciclo. Una serie ajustada estacionalmente consiste en la tendencia-ciclo más el componente irregular, por lo cual, si el componente irregular es fuerte, puede no representar una serie suavizada fácilmente identificable.

C) Variables artificiales al final de la serie

Los manuales internacionales también realizan advertencias sobre el problema que representa en la extracción de señales la presencia de valores extremos al final de la serie.

- La Eurostat (2015) hace las siguientes recomendaciones sobre el tratamiento de *outliers* al final de la serie:
 - i. Los valores extremos al final de la serie presentan la dificultad de una identificación adecuada. Un escalón al final de la serie no se puede distinguir de un impulso (AO). Esto representa un problema para la estimación de la tendencia-ciclo y el componente irregular porque un escalón puede ser tratado como un impulso y por consiguiente asignado erróneamente al componente irregular y no a la tendencia-ciclo. Sin embargo, este problema no afecta a la serie ajustada estacionalmente, pues ésta incluye a ambos, a la tendencia-ciclo y al irregular.
 - ii. Inicialmente, los valores extremos al final de la serie son tratados como impulsos y se requieren observaciones adicionales antes de poder cambiar un impulso o un cambio transitorio. En estos casos se produce un impacto importante en las revisiones de la serie.

- El FMI (2001) señala que las estimaciones de la tendencia-ciclo del segmento más reciente deben interpretarse con cautela porque los valores atípicos son difíciles de identificar al final de la serie. Se requieren varias observaciones para verificar un cambio en la tendencia-ciclo señalada por la primera observación.

Basados en las recomendaciones internacionales se sugiere el siguiente procedimiento para la publicación de resultados del ajuste estacional:

- a) En el caso de la inflación de alimentos, debido a que únicamente para Costa Rica se detectó un componente estacional significativo, las señales se extraen sobre la serie original. Las tasas de variación también serán calculadas sobre la serie original. En el caso de Costa Rica se procede del mismo modo que se recomienda para la actividad agropecuaria.
- b) En el caso de la actividad agropecuaria, debido a que todas las series tienen estacionalidad, se recomienda el uso de la serie desestacionalizada para el análisis de coyuntura. En un gráfico se puede presentar la serie desestacionalizada y la tendencia-ciclo, incluyendo una nota que indique el problema de las colas al final de esta última serie. Además, el usuario debe tener acceso a la serie original, la serie desestacionalizada y la serie en tendencia-ciclo.

CAPÍTULO V: LOS PRONÓSTICOS DE CORTO PLAZO

5.1 Introducción

Tal como se mencionó en la sección 4.1, en Maravall (1999) se indica que el tratamiento estadístico de series de tiempo tiene como propósito responder a dos preguntas: *¿dónde estamos?* y *¿hacia dónde vamos?*.

Respondiendo a la segunda pregunta *¿Hacia dónde vamos?*, es necesario utilizar métodos de pronóstico. En este estudio se han aplicado los modelos ARIMA univariantes, que además de tener gran utilidad para el ajuste estacional, permite también generar pronósticos de corto plazo. Entonces, utilizando los modelos ajustados en el capítulo III se realizarán pronósticos para un periodo de 12 meses fuera de la muestra.

Adicionalmente, se realizará un pronóstico dentro del espacio muestral para evaluar la bondad del pronóstico y, sobretodo, definir la capacidad del modelo para predecir. Hay que señalar que el modelo que realiza el mejor ajuste no siempre garantiza su capacidad para predecir fuera del período de datos utilizado para seleccionar y estimar los parámetros del modelo. Esto es así porque los métodos que minimizan la suma de cuadrados de los residuos en realidad minimizan el error de la estimación a un paso fuera de la muestra $t+1$, lo cual no brinda información sobre la bondad del pronóstico a $t+h$ períodos por delante. Por esta razón, el análisis fuera de muestra, utilizando alguna función de pérdida²², es aún más importante que los estadísticos de bondad de ajuste utilizados comúnmente para la selección de modelos.

En la práctica esto se soluciona simulando distintos horizontes de pronóstico y evaluando el error asociado a cada horizonte. En este estudio se evaluará la capacidad del modelo para predecir 1, 3, 6 o 12 meses para cada uno de los modelos para IPC de alimentos y para el indicador de corto plazo de la actividad agropecuaria, tanto a nivel país como para la región.

²² Las funciones de pérdida comunes son el error medio, el error cuadrático medio, el error cuadrático medio porcentual, la raíz del error cuadrático medio, la raíz del error cuadrático medio porcentual, el error absoluto promedio, el error absoluto promedio porcentual.

5.2 Los pronósticos de corto plazo del IPC de alimentos

A) Pronóstico dentro de la muestra

Para llevar a cabo la evaluación del desempeño del modelo ARIMA para predecir, usualmente se reduce el tamaño de la muestra original en n_1 observaciones y se estiman de nuevo los parámetros del modelo; luego, se proyectan las n_1 observaciones y se compara con el observado. La diferencia fundamental de este análisis respecto al error estándar residual considerado en la etapa de construcción del modelo ARIMA, es que el error residual mide la capacidad para pronosticar una observación, mientras que con este análisis se evalúa la capacidad del modelo para predecir h observaciones.

Para el IPC de alimentos de cada país, el análisis se realizará cortando la serie en septiembre de 2014 para pronosticar los 12 valores que van de octubre de 2014 a septiembre de 2015. Con ese resultado se calculará el Error Absoluto Medio (EAM)²³ para el pronóstico a 1 mes, a 3 meses, a 6 meses y a 1 año. Entre más bajo es el EAM mayor será la precisión del pronóstico. El EAM se aplica no a los niveles de la serie original, sino a las tasas de variación interanual obtenidas a partir de los pronósticos. Esto es así porque la variable de interés no es el nivel del índice sino sus variaciones. El EAM es de fácil interpretación y, ya que es aplicado a tasas de variación, permite evaluar fácilmente la discrepancia en puntos porcentuales entre el observado y el estimado.

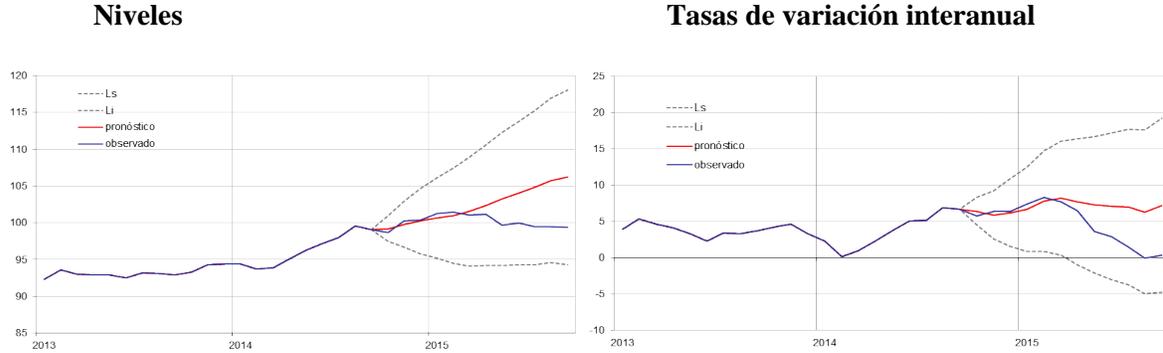
Para fines prácticos es importante definir la tolerancia o error máximo que el analista de datos está dispuesto a aceptar para el pronóstico del IPC de alimentos. Así por ejemplo, para una variable como la inflación de Costa Rica que oscila alrededor de un 4%, se acepta un modelo que tenga un error máximo de 1% pero no un modelo con un error de 4%. Por lo tanto, para este documento se definirá en forma arbitraria una tolerancia de 1%, sin perder de vista que el analista puede definir un valor mayor o incluso inferior. Más aún, el nivel de tolerancia puede variar de un país a otro,

²³ El EAM se calcula como $EAM = \frac{1}{N} \sum_{t=1}^N |e_{t+h,t}|$ donde $e_{t+h,t} = y_{t+h} - \hat{y}_{t+h,t}$, es el residuo del pronóstico de $t+h$, efectuado con información hasta el momento t .

dependiendo de los niveles de la serie; sin embargo, para facilitar el análisis en este documento se selecciona un valor fijo para todos los países.

a) Costa Rica

Gráfico 5.1: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de Costa Rica, incluyendo bandas al 95% de confianza

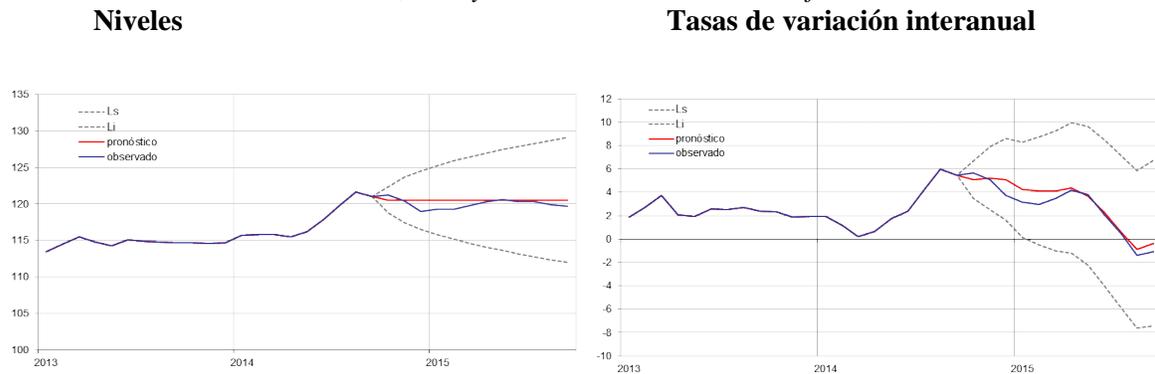


El modelo ARIMA (110)(100) fue ajustado para el IPCA de Costa Rica en la sección 3.3 de este documento. Los modelos con parámetros AR tienen a pronosticar pendientes constantes pero con movimientos dentro del año que corresponden al componente estacional. Al evaluar la capacidad de pronóstico comparando con los últimos 12 meses observados, se aprecia muy buen desempeño en el pronóstico de los primeros 6 meses. El EAM es de 0.5 puntos porcentuales a 6 meses, que representa el error promedio de los pronósticos que van de octubre 2014 a marzo 2015. Por ejemplo, en enero de 2015 el pronóstico de inflación era de 6.7% mientras que el observado fue de 7.3%, por lo cual el EAM es de 0.6 puntos porcentuales. Pronósticos superiores a 6 meses tienen errores que superan el nivel de tolerancia de un 1%. Ver tabla 5.1 del literal h) de este subacápito.

Adicionalmente, las bandas de confianza alrededor del pronóstico se abren rápidamente, producto de un error estándar residual alto (0.895%) que además se incrementa rápidamente. Por lo anterior, este modelo se recomienda para ser utilizado en horizontes de pronóstico de alrededor de 6 meses.

b) El Salvador

Gráfico 5.2: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de El Salvador, incluyendo bandas al 95% de confianza



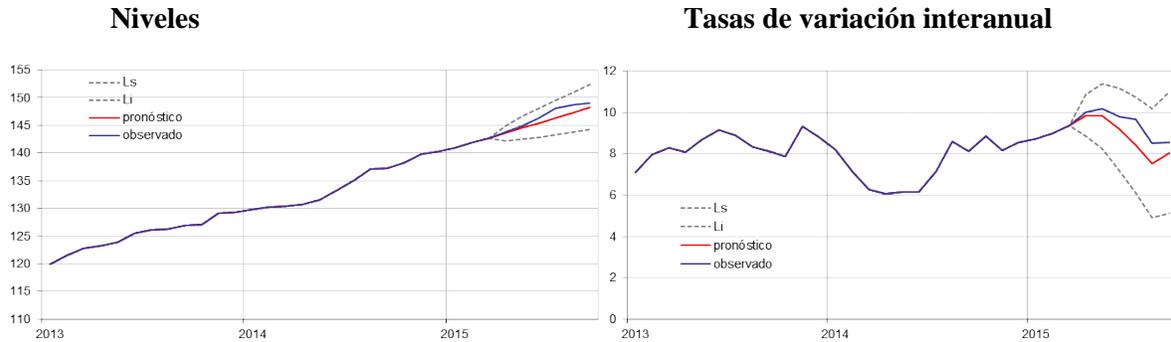
El modelo ARIMA (011)(000) fue ajustado para el IPCA de El Salvador en la sección 3.3 de este documento. Este modelo con un único parámetro MA y sin constante genera pronósticos que convergen rápidamente a un valor constante a partir de $t+2$. Al evaluar la capacidad de pronóstico comparando con los últimos 12 meses observados, se aprecia muy buen desempeño en todo el horizonte de pronóstico. El EAM es de 0.6% a 12 meses, que representa al error promedio de los pronósticos que van de octubre 2014 a septiembre 2015. Ver tabla 5.1 del literal h) de este subacápito. Por ejemplo, en octubre de 2014 el pronóstico de inflación era de 5.1% mientras que el observado fue de 5.7%, con un EAM de 0.6 puntos porcentuales.

A pesar de que los errores de pronóstico no superan el nivel de tolerancia de 1%, hay que ser muy prudentes para utilizar modelos MA(1), sin constante y sin componente estacional, para horizontes de pronóstico superiores a un mes, ya que produce pronósticos que convergen a un valor constante a partir de $t+2$. En el caso de El Salvador, este modelo funcionó adecuadamente debido a que el país está en una etapa de inflación casi estacionaria.

Adicionalmente, las bandas de confianza alrededor del pronóstico se abren rápidamente, producto de un error estándar residual alto (0.733%) que además se incrementa rápidamente. Por lo anterior, bajo el periodo analizado, este modelo se recomienda para ser utilizado en horizontes de pronóstico de 12 meses.

c) Guatemala

Gráfico 5.3: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de Guatemala, incluyendo bandas al 95% de confianza

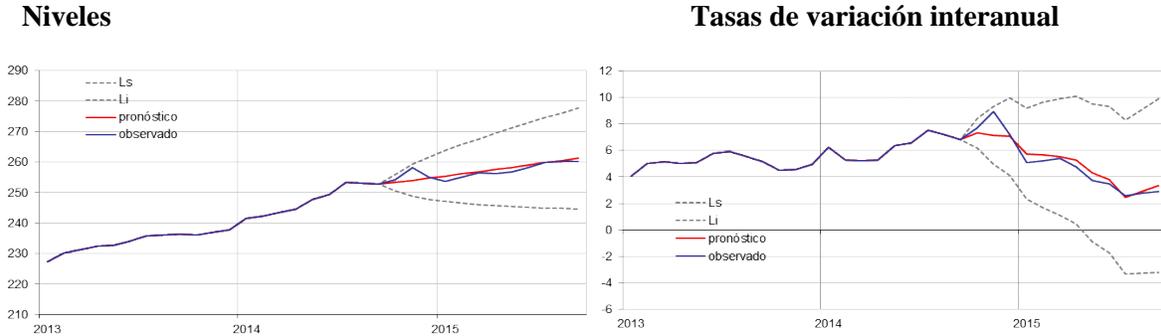


El modelo ARIMA(011)(000) fue ajustado para el IPCA de Guatemala en la sección 3.3 de este documento. Este modelo tiene un único parámetro MA más la constante y variables artificiales tipo *transitory change* (TC), por lo que el pronóstico produce una línea recta con pendiente positiva, cuyos cambios porcentuales son constantes. En el caso de Guatemala, para evaluar la capacidad de pronóstico se utilizaron únicamente los últimos 6 meses observados, debido a que la serie es muy corta, inicia en abril de 2011. Durante ese periodo se aprecia muy buen desempeño del pronóstico; el EAM es de 0.6 puntos porcentuales a 6 meses, lo que representa al error promedio de los pronósticos que van de abril a septiembre 2015. Ver tabla 5.1 del literal h) de este subacápite. Por ejemplo, en abril de 2015 el pronóstico de inflación fue de 9.8% mientras que el observado fue de 10%, por lo que el EAM es de 0.2 puntos porcentuales.

A pesar de que no se supera el nivel de tolerancia de un 1%, hay que tener presente que este modelo tiene una pendiente constante, por lo que hay que estar atentos a cambios de pendiente en los datos originales. Adicionalmente, las bandas de confianza alrededor del pronóstico son bastante estrechas al inicio debido a que el error estándar residual es uno de los más bajos (0.449%), no obstante se amplían al final de los 6 meses. Por lo anterior, conforme al periodo analizado, este modelo se recomienda para ser utilizado en horizontes de pronóstico de 6 meses.

d) Honduras

Gráfico 5.4: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de Honduras, incluyendo bandas al 95% de confianza

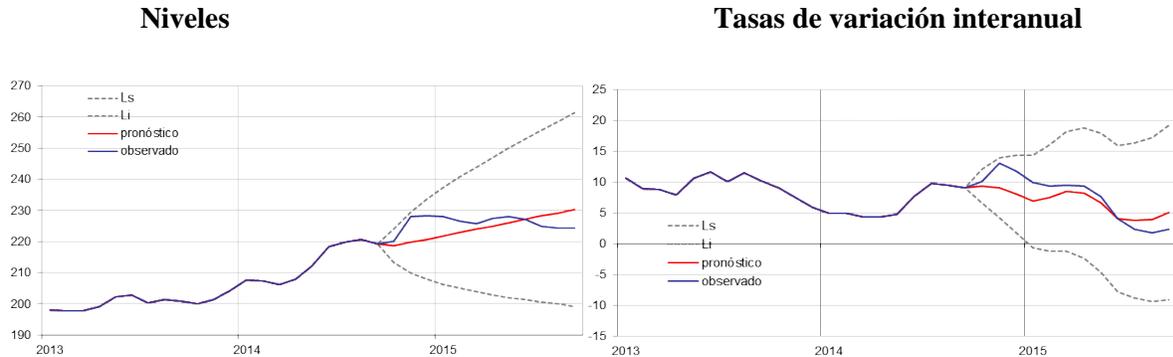


El modelo ARIMA (011)(000) fue ajustado para el IPCA de Honduras en la sección 3.3 de este documento. Este modelo tiene un único parámetro MA más la constante y cinco variables artificiales, por lo que el pronóstico produce una línea recta con pendiente positiva, cuyos cambios porcentuales son constantes. Para evaluar la capacidad de pronóstico se utilizaron los últimos 12 meses observados, periodo durante el cual el pronóstico se acerca mucho a los valores observados; de hecho, el EAM es de 0.5 puntos porcentuales a 12 meses, que representa el menor error obtenido para todos los modelos. Ver tabla 5.1 del literal h) de este subacápite. Por ejemplo, en octubre de 2014 el pronóstico de inflación fue de 7.3% mientras que el observado fue de 7.7%, lo que representa un EAM de 0.4 puntos porcentuales. A pesar de que el pronóstico es muy satisfactorio y no supera el nivel de tolerancia de un 1%, hay que tener presente que este modelo tiene una pendiente constante, por lo que hay que estar atentos a cambios de pendiente en los datos originales.

Adicionalmente, las bandas de confianza alrededor del pronóstico son estrechas al inicio debido a que el error estándar residual es bajo (0.533%), pero se amplían en forma importante después de los 6 meses. Bajo el periodo analizado, este modelo se recomienda para ser utilizado en horizontes de pronóstico de 12 meses.

e) Nicaragua

Gráfico 5.5: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de Nicaragua, incluyendo bandas al 95% de confianza

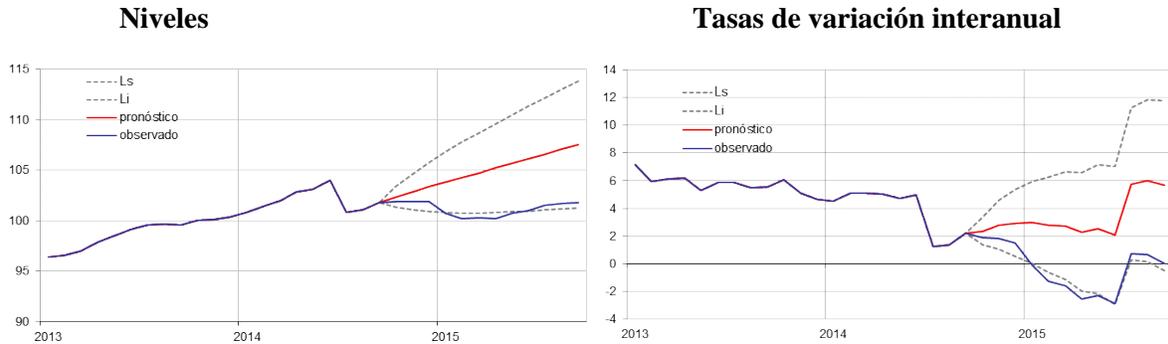


El modelo ARIMA (011)(000) fue ajustado para el IPCA de Nicaragua en la sección 3.3 de este documento. Este modelo tiene un único parámetro MA más la constante, por lo que el pronóstico produce una línea recta con pendiente positiva, cuyos cambios porcentuales son constantes. Para evaluar la capacidad de pronóstico se utilizaron los últimos 12 meses observados; el EAM a 12 meses es 1.9 puntos porcentuales, un valor que supera el nivel de tolerancia. Además, el EAM a 6 meses es 2.4 puntos porcentuales (p.p) y a 3 meses es 2.8 p.p., valores que siguen siendo muy altos (Ver tabla 5.1 del literal h) de este subacápite). De tal modo que el EAM a 1 mes (0.4%) es el único error que representa un nivel aceptable; el pronóstico de octubre de 2014 se estimó un crecimiento de 9.4% mientras que el observado fue de 10.1%.

Adicionalmente, las bandas de confianza alrededor del pronóstico son sumamente amplias debido a que el error estándar residual es el más alto de todos los modelos ajustados (1.21%). Por lo anterior, este modelo se recomienda para pronosticar únicamente el mes siguiente (t+1).

f) Panamá

Gráfico 5.6: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de Panamá, incluyendo bandas al 95% de confianza

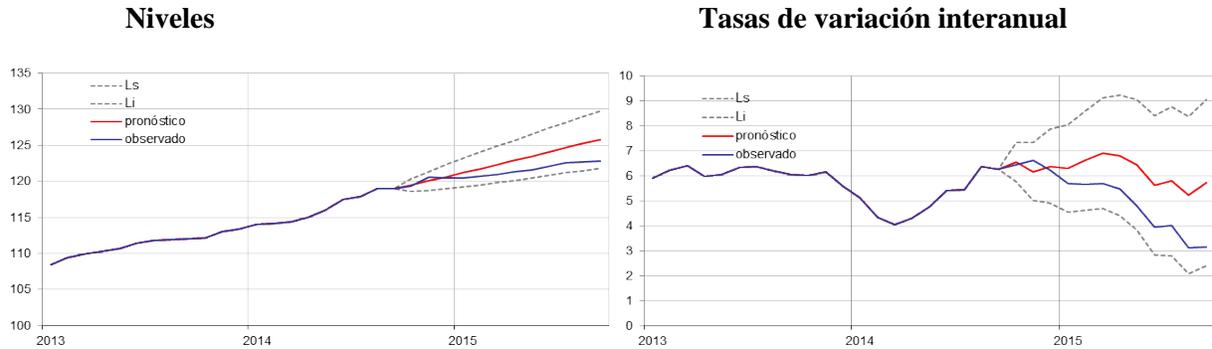


El modelo ARIMA(110)(000) fue ajustado para el IPCA de Panamá en la sección 3.3 de este documento. Este modelo con un parámetro AR (y sin estacionalidad) genera pronósticos que siguen una senda con pendiente positiva que es constante. Al evaluar la capacidad de pronóstico comparando con los últimos 12 meses observados, resulta que el pronóstico sobreestimó el valor observado en todos los casos. Aún cuando el EAM es de 0.5 p.p. a 1 mes y de 0.9 p.p. a 6 meses (Ver tabla 5.1 del literal h) de este subacápite), hay que tener presente que en el periodo analizado los pronósticos no son satisfactorios. Sin duda, el periodo evaluado coincide con cambios importantes en el comportamiento de la serie, por lo cual se recomienda estar vigilantes y evaluar la bondad de los nuevos pronósticos que se generen cuando llegue nueva información.

Si bien las bandas de confianza son estrechas al inicio, dado que el error estándar residual es bajo (0.498%), el nivel de tolerancia del 1% se alcanza luego de 6 meses de pronósticos, sugiriendo que este modelo solamente puede ser utilizado para pronósticos de corto plazo. Según estos resultados 6 meses es el horizonte de pronóstico recomendado, siempre que el usuario se mantenga atento a cambios en el comportamiento de la serie original.

g) Región

Gráfico 5.7: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IPCA de la Región, incluyendo bandas al 95% de confianza



El modelo ARIMA(011)(000) fue ajustado para el IPCA de la Región en la sección 3.3 de este documento. Este modelo tiene un único parámetro MA más la constante, por lo que el pronóstico produce una línea recta con pendiente positiva, cuyos cambios porcentuales son constantes. Para evaluar la capacidad de pronóstico se utilizaron los últimos 12 meses observados; el EAM a 12 meses es 1.2 p.p., un valor que es ligeramente superior al nivel de error aceptable. Incluso, el EAM a 1 mes es de 0.1 p.p., que se eleva a 0.2 p.p. en 3 meses, a 0.7 p.p. en 6 meses y a 0.6 p.p. en 9 meses (Ver tabla 5.1 del literal h) de este subacápito). Por ejemplo, el pronóstico de octubre de 2014 fue de un incremento de 6.5% mientras que el observado fue de 6.4%.

Además, las bandas de confianza alrededor del pronóstico de los primeros meses son bastante estrechas debido a que el error residual de este modelo es el más bajo (0.354%) de todos los modelos ajustados a los países analizados. Bajo estas condiciones, este modelo se puede utilizar para el pronóstico de un horizonte de 9 meses.

No obstante, es importante advertir que cuando los pronósticos siguen una línea recta, es fácil encontrar que a partir de algún punto se subestime o se sobreestime el valor observado. Por esta razón, se sugiere la vigilancia permanente de posibles cambios en el comportamiento de la serie, así como la actualización de los pronósticos cada vez que llega un nuevo dato.

h) Resumen

En la tabla 5.1 se presenta un resumen de los principales resultados obtenidos durante el proceso de evaluación de la capacidad de pronóstico de los modelos ARIMA ajustados a las series del IPC de alimentos de los países individualmente y al agregado regional.

El **error estándar residual** de la primera columna representa el tamaño del error que se obtuvo al momento de comparar el valor observado con el valor estimado a partir del modelo ARIMA. Este error se le conoce como **error un paso adelante**, pues evalúa la capacidad del modelo de estimar $t+1$. Se trata de un valor promedio, para todo el periodo de datos analizado.

El **error absoluto medio** (EAM) es una evaluación de la capacidad de pronóstico en un momento específico. Esta evaluación se realizó para distintos horizontes de pronóstico a fin de brindar evidencia que ayude a definir cuantos meses se pueden predecir con cada modelo bajo un error que se pueda considerar aceptable. Además, el EAM se calculó sobre las tasas de variación interanuales que se generan a partir de los índices pronosticados, debido a que la variable que resulta de utilidad para el analista no es el nivel de la serie, sino sus variaciones. Es importante mencionar que el EAM está influenciado por el momento del tiempo elegido para realizar la evaluación, ya que un mismo modelo puede brindar resultados muy buenos en ciertos periodos y desfavorables en otros (en periodos de cambios de tendencias por ejemplo).

Utilizando ambos estadísticos se llega a una recomendación que se brinda en la última columna de esta tabla, con resultados dispares entre los países. En cualquier caso, se recomienda actualizar los pronósticos cada vez que llega un nuevo dato, dejando el modelo ARIMA inalterado, pero reestimando los valores de los parámetros para capturar cualquier cambio en el comportamiento de la serie.

Tabla 5.1: IPC de alimentos y el Error absoluto medio para distintos horizontes de pronóstico, medido sobre la tasa de variación interanual

Modelo y origen del pronóstico	Error estándar Residual	EAM según horizonte de pronóstico en meses				Horizonte recomendado
		1	3	6	12	
Costa Rica	0.895%	0.6	0.4	0.5	2.6	6 meses
El Salvador	0.733%	0.6	0.7	0.8	0.6	12 meses
Guatemala ^{1/}	0.449%	0.2	0.4	0.6	n.d.	6 meses
Honduras	0.533%	0.4	0.8	0.6	0.5	12 meses
Nicaragua	1.210%	0.7	2.8	2.4	1.9	1 mes
Panamá	0.498%	0.5	0.9	2.4	3.7	6 meses
Región	0.354%	0.1	0.2	0.6	1.2	9 meses

1/ El horizonte de pronóstico a 12 meses no fue evaluado para Guatemala, ya que la serie es muy corta, inicia en abril de 2011.

B) Pronóstico fuera de la muestra

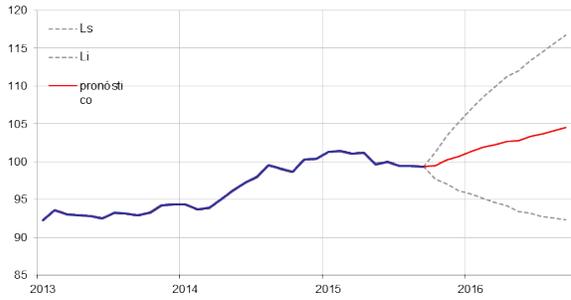
En los gráficos 5.8 se presentan los pronósticos de 12 meses para el IPC de alimentos de cada uno de los países y del agregado regional. El periodo pronosticado comprende de octubre de 2015 a septiembre de 2016. Cada estimación se acompaña de bandas al 95% de confianza, las cuales se amplían conforme se aleja del horizonte de pronóstico debido a que la incertidumbre aumenta cuanto más se aleja del último valor observado.

Si bien en los gráficos se presentan pronósticos para 12 meses, de la tabla 5.1 se deduce el horizonte de pronóstico que se recomienda emplear para cada país. Debido a que en algunos casos se recomienda la utilización del modelo ARIMA para lapsos menores a 12 meses, se requiere la aplicación de otro tipo de modelos cuando se quieran pronosticar 12 meses, en especial aquellos que utilicen además, variables explicativas.

En el caso regional, el modelo se recomienda para el pronóstico de 9 meses; en ese lapso el pronóstico de inflación de alimentos oscila alrededor de un 4%, con tendencia a aumentar durante el 2016 si no se realiza ningún tipo de intervención de la política macroeconómica y sectorial.

Gráfico 5.8: Pronóstico de 12 meses (octubre 2015 a septiembre 2016) del IPC alimentos en niveles y en tasas de variación interanual incluyendo bandas al 95% de confianza

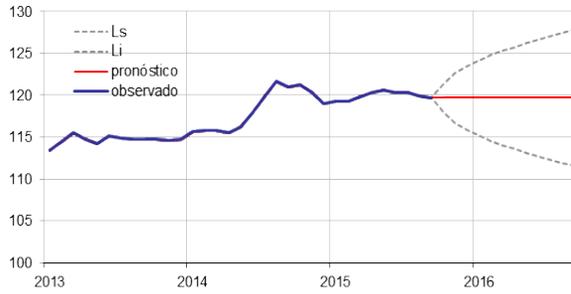
Costa Rica: Niveles



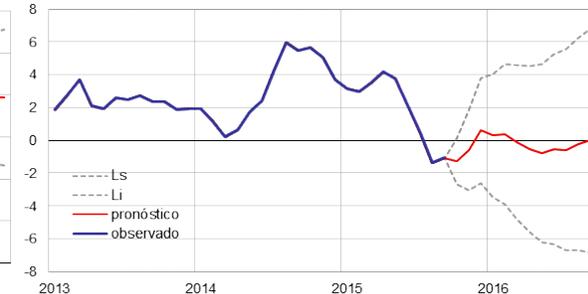
Costa Rica: Tasas de variación interanual



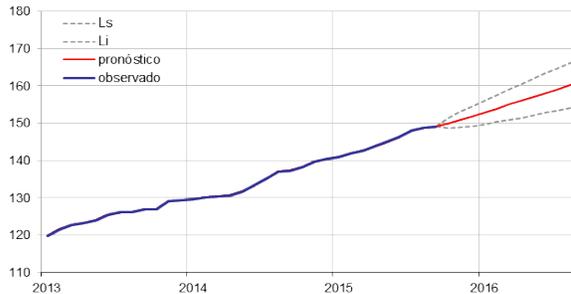
El Salvador: Niveles



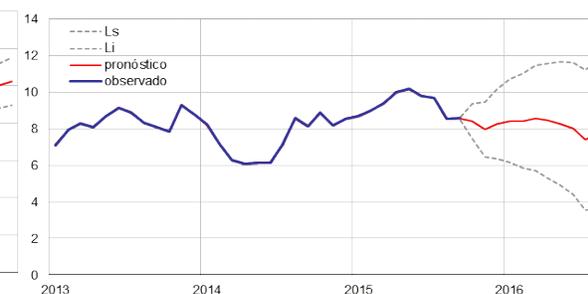
El Salvador: Tasas de variación interanual



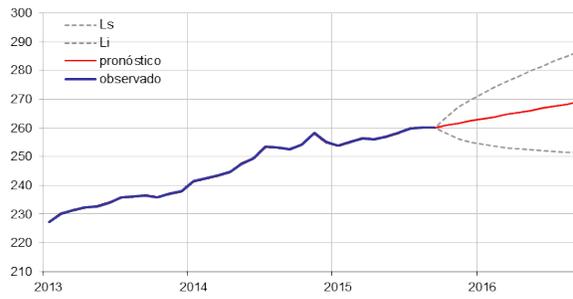
Guatemala: Niveles



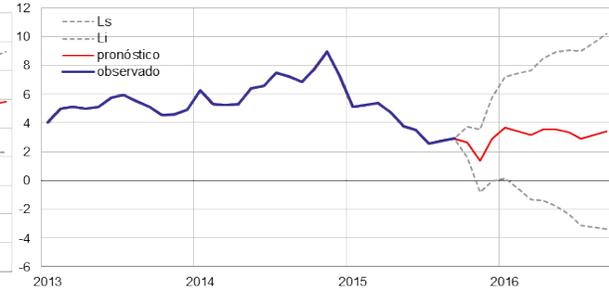
Guatemala: Tasas de variación interanual



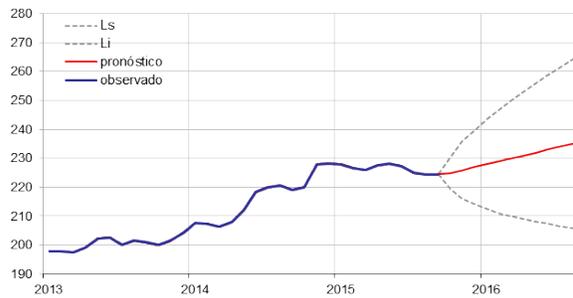
Honduras: Niveles



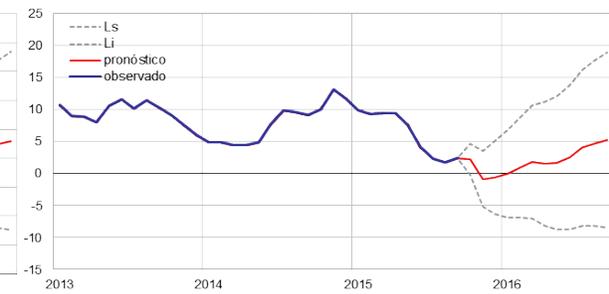
Honduras: Tasas de variación interanual



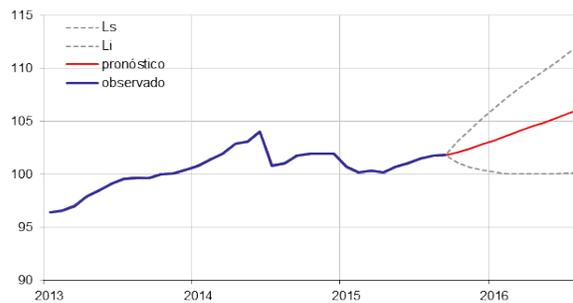
Nicaragua: Niveles



Nicaragua: Tasas de variación interanual



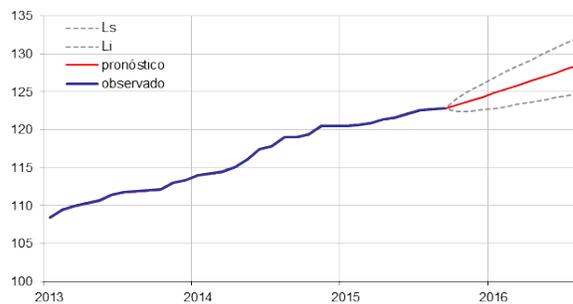
Panamá: Niveles



Panamá: Tasas de variación interanual



Región: Niveles



Región: Tasas de variación interanual



5.3 Los pronósticos de corto plazo de la actividad agropecuaria

A) Pronóstico dentro de la muestra

Del mismo modo que se procedió en el apartado 5.2, para llevar a cabo la evaluación del desempeño del modelo ARIMA para predecir la actividad agropecuaria, se reduce el tamaño de la muestra original en n_1 observaciones y se estiman de nuevo los parámetros del modelo; luego, se proyectan las n_1 observaciones y se compara con el observado. La diferencia fundamental de este análisis respecto al error estándar residual considerado en la etapa de construcción del modelo ARIMA, es que el error residual mide la capacidad del modelo para pronosticar una observación, mientras que con este análisis se evalúa la capacidad de predecir h observaciones.

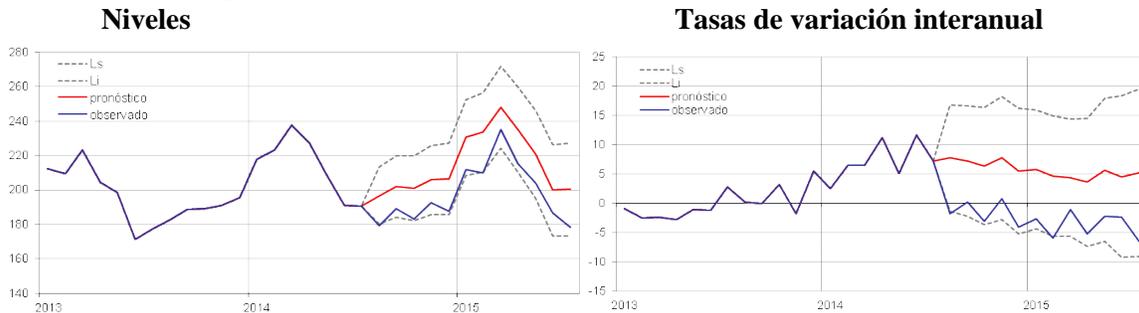
Para el indicador de corto plazo de la actividad agropecuaria el análisis se realizará reduciendo la serie 12 meses; con ese resultado se calculará el Error Absoluto Medio (EAM), que se explicó en el apartado 5.2, para el pronóstico a 1 mes, a 3 meses, a 6 meses y a 1 año. Entre más bajo es el EAM mejor es la precisión del pronóstico.

El EAM será calculado no sobre los niveles del indicador de la actividad agropecuaria sino sobre sus tasas de variación interanual. Esto es así porque el interés del analista se centra sobre las variaciones interanuales, de modo que el EAM se podrá interpretar en términos de los puntos porcentuales en que el pronóstico se aleja del valor observado. Con esto, el analista podrá decidir si la discrepancia promedio observada le resulta aceptable o no.

Para este documento ese nivel de tolerancia será establecido en un punto porcentual, es decir, si el pronóstico indica que la actividad económica crecerá 3% y el observado es de 4%, el pronóstico se considerará satisfactorio. Se advierte que ese valor es indicativo y que puede ser modificado por el usuario.

a) Costa Rica

Gráfico 5.9: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de Costa Rica, incluyendo bandas al 95% de confianza

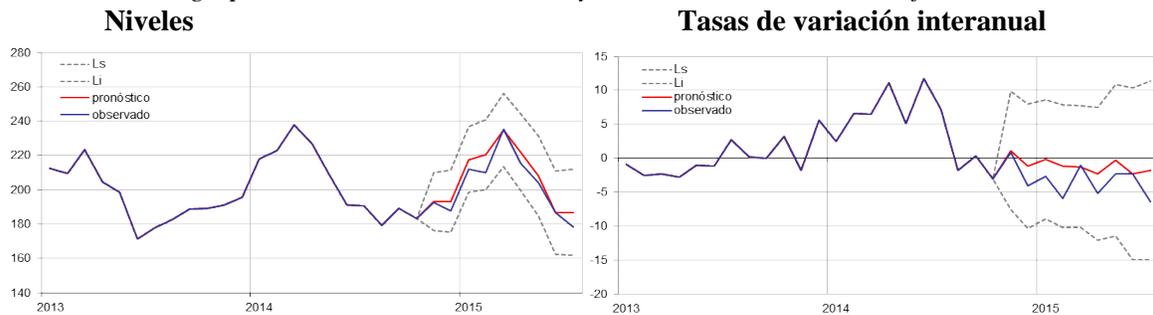


El modelo ARIMA(011)(011) fue ajustado para el IMAE agropecuario de Costa Rica en la sección 3.4 de este documento. Este modelo permite reproducir en el pronóstico la pendiente de los datos más recientes y los movimientos estacionales que se observan en la serie. Para evaluar la capacidad de pronóstico se redujo la muestra al periodo que va de enero de 2006 a julio de 2014. Durante el pronóstico a partir de agosto de 2014 se observa que en todos los meses se sobreestimó el nivel de la serie, es decir, se esperaban mayores niveles de actividad agropecuaria de los que finalmente fueron reportados. Esto indica que, dado el comportamiento pasado de la serie, el observado es menor a lo esperado. Por tal razón, los valores del EAM calculados sobre las tasas de variación interanuales son inaceptables (Ver tabla 5.2 del literal h) de este subacápite); así por ejemplo para agosto de 2014 se pronosticó una tasa de 7.7% mientras que el observado fue -1.8%, lo que representa un EAM de 9.5 puntos porcentuales.

No obstante, pasados tres meses de información, el modelo aprende de los datos y los pronósticos resultan más cercanos al observado. De hecho, utilizando el periodo comprendido entre enero de 2014 y octubre de 2015, se pronosticaron 9 meses (de noviembre de 2014 a julio de 2015) y el EAM disminuye ubicándose en 0.3 p.p a 1 mes, 1.9 p.p a 3 meses, 2.3 p.p. a 6 meses y 2.2 p.p. a 9 meses. El pronóstico de la tasa de variación a noviembre 2014 fue de 1.1% mientras que el observado fue de 0.8%, tal como se observa en el gráfico 5.10. En este nuevo periodo de evaluación el EAM obtenido

sugiere el uso de este modelo para el pronóstico de 1 mes, pero quizás hasta 12 meses para quien acepte un mayor nivel de tolerancia.

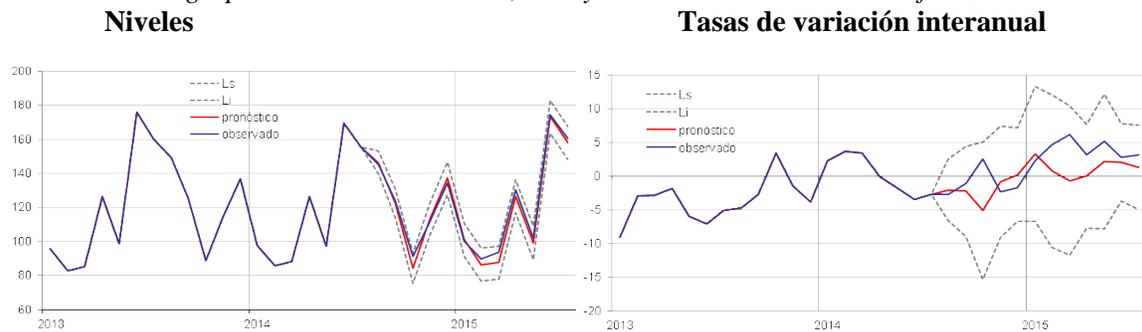
Gráfico 5.10: Pronóstico de 9 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de Costa Rica, incluyendo bandas al 95% de confianza



Adicionalmente, las bandas de confianza alrededor del pronóstico se abren rápidamente, producto de un error estándar residual alto (4.16%) que además se incrementa rápidamente. Esto hace que los pronósticos deban ser utilizados con cautela.

b) El Salvador

Gráfico 5.11: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de El Salvador, incluyendo bandas al 95% de confianza



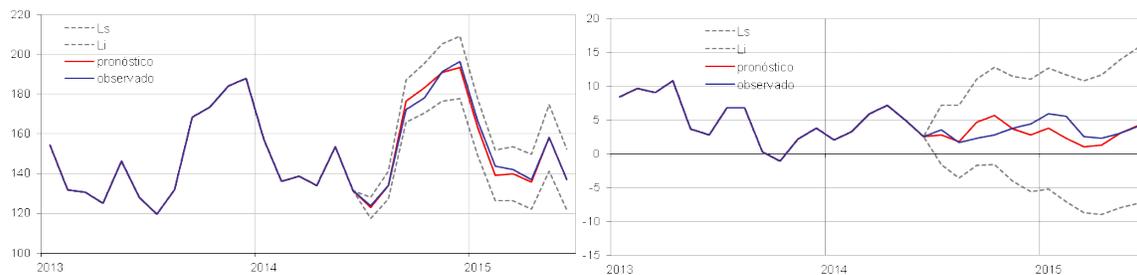
El modelo ARIMA(100)(011) fue ajustado para el IMAE agropecuario de El Salvador en la sección 3.4 de este documento. El parámetro AR(1) de este modelo recoge la pendiente de la serie mientras que el parámetro MA(12) genera los movimientos dentro del año que corresponden al componente estacional. Para evaluar la capacidad de pronóstico la serie se redujo al periodo enero 2006 a julio 2014; comparando los pronósticos con los últimos 12 meses observados, se aprecia que los valores observados

se encuentran dentro de las bandas de confianza, mismas que se mantienen bastante estrechas debido a que el error estándar de este modelo es uno de los más bajos (2.14%).

El EAM calculado sobre las tasas de variación interanuales muestra un error de 0.7 puntos porcentuales en el primer mes: el pronóstico fue de -2.05% y el observado fue de -2.75%. No obstante, a partir de los 3 meses los errores son sustancialmente mayores (Ver tabla 5.2 del literal h) de este subacápite). Si bien en algunos meses los errores son pequeños, en otros las discrepancias son tan altas que el EAM se aumenta en forma importante. De hecho, la mayor discrepancia se observa al pronosticar el tercer mes, de tal modo que si ese valor se elimina el EAM disminuye significativamente en todos los horizontes de pronóstico, sugiriendo el uso de este modelo hasta por 6 meses. No obstante, con la evaluación realizada, este modelo se recomienda para el pronóstico de 2 meses.

c) Guatemala

Gráfico 5.12: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de Guatemala, incluyendo bandas al 95% de confianza



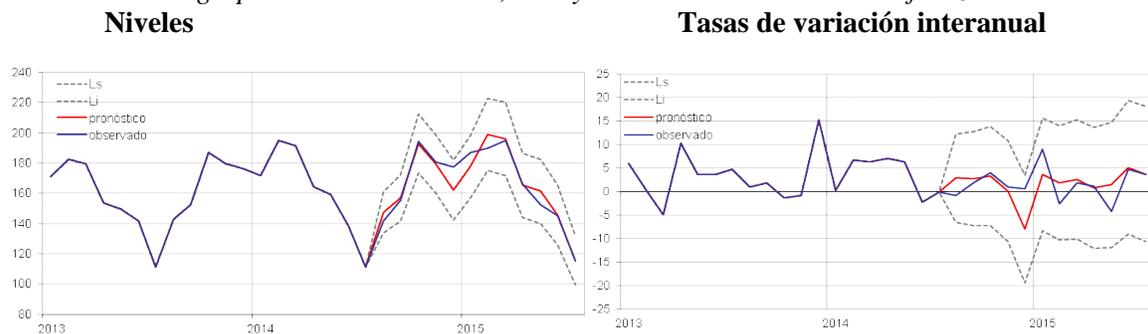
El modelo ARIMA(011)(011) fue ajustado para el IMAE agropecuario de Guatemala en la sección 3.4 de este documento. El parámetro MA(1) de este modelo recoge la pendiente de la serie mientras que el parámetro MA(12) genera los movimientos dentro del año que corresponden al componente estacional. Para evaluar la capacidad de pronóstico la serie se redujo al periodo enero 2009 a junio 2014; comparando los pronósticos con los últimos 12 meses observados, se aprecia que los valores observados

se encuentran dentro de las bandas de confianza, mismas que se mantienen bastante estrechas debido a que el error estándar también es muy bajo (2.08%).

El EAM calculado sobre las tasas de variación interanuales muestra un error de 0.8 puntos porcentuales en el primer mes: el pronóstico fue de 2.8% y el observado fue de 3.6%. Esos errores se mantienen bastante bajos durante los 12 meses analizados (Ver tabla 5.2 del literal h) de este subacápite), avalando el uso de este modelo para horizontes de 12 meses.

d) Honduras

Gráfico 5.13: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de Honduras, incluyendo bandas al 95% de confianza



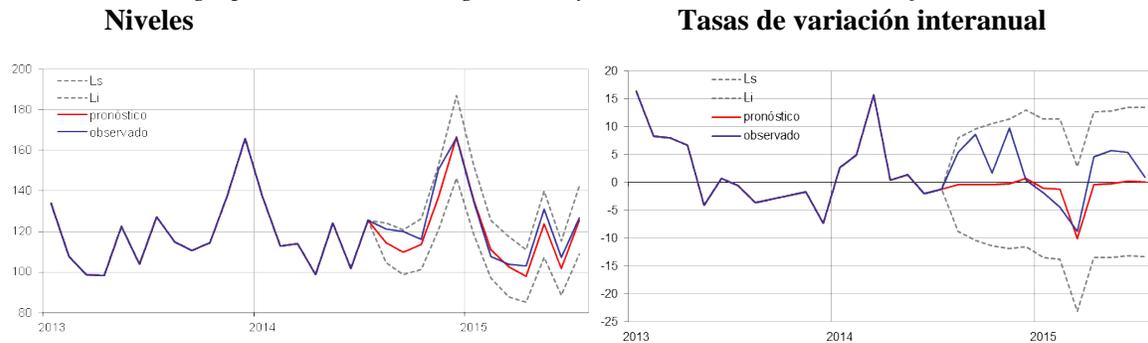
El modelo ARIMA(011)(011) fue ajustado para el IMAE agropecuario de Honduras en la sección 3.4 de este documento. El parámetro MA(1) de este modelo recoge la pendiente de la serie mientras que el parámetro MA(12) genera los movimientos dentro del año que corresponden al componente estacional. Para evaluar la capacidad de pronóstico la serie se redujo al periodo enero 2006 a julio 2014; comparando los pronósticos con los últimos 12 meses observados, se aprecia que los valores observados se encuentran dentro de las bandas de confianza.

El EAM calculado sobre las tasas de variación interanuales muestra un error inaceptable de 3.6 puntos porcentuales en el primer mes: el pronóstico fue de 2.9% y el observado fue de -0.8%. No obstante, para los meses siguientes los errores son mucho menores, con EAM por debajo de 1 punto porcentual, produciendo que el EAM a 3 meses sea de 1.8 puntos porcentuales (Ver tabla 5.2 del literal h) de este subacápite). Considerando los

altos niveles de esta serie, se pueden utilizar niveles de tolerancia superiores a 1 punto porcentual, en cuyo caso este modelo se puede utilizar para un horizonte de 3 meses y con una mayor tolerancia quizás hasta de 6 meses.

e) Nicaragua

Gráfico 5.14: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de Nicaragua, incluyendo bandas al 95% de confianza



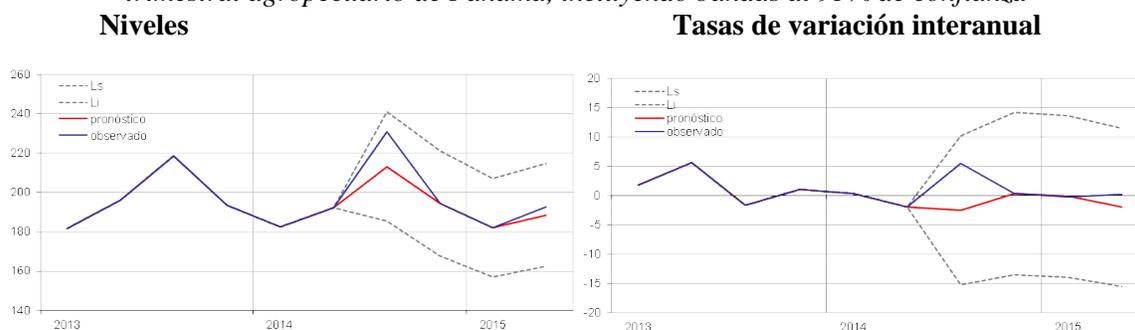
El modelo ARIMA(101)(011) fue ajustado para el IMAE agropecuario de Nicaragua en la sección 3.4 de este documento. Este modelo permite reproducir en el pronóstico la pendiente de los datos más recientes y los movimientos estacionales que se observan en la serie. Para evaluar la capacidad de pronóstico se redujo la muestra al periodo que va de enero de 2006 a julio de 2014. Desde el inicio del pronóstico se observan discrepancias muy importantes respecto al observado. Esto genera valores del EAM que son inaceptables (Ver tabla 5.2 del literal h) de este subacápite); así por ejemplo para agosto de 2014 se pronosticó una tasa de 5.3% mientras que el observado fue -0.5%, lo que representa un EAM de 5.8 puntos porcentuales.

En este caso, el pronóstico de los primeros 4 meses tiene errores muy grandes, mientras que en otros meses los errores son sumamente pequeños. Esto representa un caso similar al de Costa Rica, donde pasados algunos meses el modelo aprende con la nueva información y genera resultados más satisfactorios.

Por lo tanto, se sugiere un uso cauteloso de este modelo; se recomienda utilizarlo durante un tiempo para el pronóstico de un solo mes y que sea la evidencia empírica la que indique si el horizonte de pronóstico se puede ampliar.

f) Panamá

Gráfico 5.15: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del PIB trimestral agropecuario de Panamá, incluyendo bandas al 95% de confianza



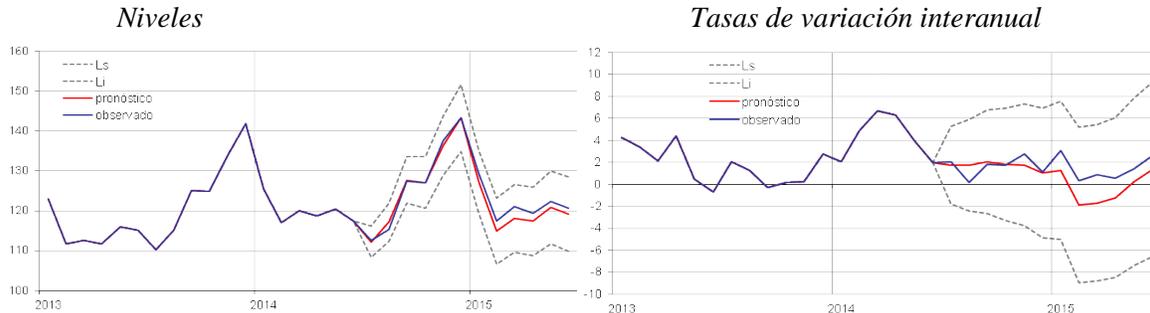
El modelo ARIMA (001)(011) fue ajustado para el PIB trimestral agropecuario de Panamá en la sección 3.4 de este documento. Este modelo reproduce en el pronóstico el nivel de la serie en el mes anterior más los movimientos estacionales del año anterior. Para evaluar la capacidad de pronóstico se redujo la muestra en 4 trimestres, utilizando el periodo que va del I trimestre de 2007 al II trimestre de 2014.

El pronóstico del III trimestre de 2014 no fue satisfactorio, se pronosticó un crecimiento de 5.5% y el observado fue de -2.5, lo que generó un EAM de 8 puntos porcentuales. No obstante, los siguientes tres pronósticos fueron altamente satisfactorios, con errores tan bajos que, en el promedio de los 4 trimestres, el EAM es de 2.6 puntos porcentuales (Ver tabla 5.2 del literal h) de este subacápite). Por lo anterior, se sugiere darle seguimiento a nuevos pronósticos con este modelo a fin de ratificar la recomendación de utilizarlo para pronosticar un horizonte de 4 trimestres.

Es importante mencionar que las bandas de confianza del pronóstico son muy amplias, debido a que el error residual del modelo resultó muy elevado (6.35%). Esto es evidencia de que la serie tiene una volatilidad que es mayor a la observada en las series mensuales del resto de países.

g) Región

Gráfico 5.16: Pronóstico de 12 meses, en niveles y en tasas de variación interanual del IMAE agropecuario de la región, incluyendo bandas al 95% de confianza



El modelo ARIMA(011)(011) fue ajustado para el IMAE agropecuario de la región en la sección 3.4 de este documento. El parámetro MA(1) de este modelo recoge la pendiente de la serie mientras que el parámetro MA(12) genera los movimientos dentro del año que corresponden al componente estacional. Para evaluar la capacidad de pronóstico la serie se redujo al periodo en 12 meses, al periodo comprendido entre enero 2009 a junio 2014. Comparando los pronósticos de los últimos 12 meses con los valores observados, se encuentra que el EAM es muy bajo (Ver tabla 5.2 del literal h) de este subacápite). Por ejemplo, al pronosticar julio de 2014 se estimó un crecimiento de 1.7% y el observado fue de 2.1%, obteniendo un EAM de 0.4 puntos porcentuales. De tal modo que este modelo puede ser utilizado para pronósticos en un horizonte de 12 meses. Este modelo además tiene un error residual de 1.63% que resultó ser el más bajo de todos los modelos ajustados a las series por país.

h) Resumen

En la tabla 5.2 se presenta un resumen de los principales resultados obtenidos durante el proceso de evaluación de la capacidad de pronóstico de los modelos ARIMA ajustados a las series de la actividad agropecuaria de los países individualmente y al agregado regional. En Panamá se utilizó la serie del PIB trimestral del sector agropecuario mientras que para el resto de países se utilizó el IMAE agropecuario.

La descripción de los estadísticos incluidos en dicha tabla puede ser consultada en la sección 5.2. En la última columna se brinda una recomendación sobre el horizonte de pronóstico a utilizar. En el caso de Costa Rica el horizonte de pronóstico recomendado se podría ampliar a 12 meses si se aumenta el nivel de error tolerable, mientras que en El Salvador y en Honduras se podría aumentar a 6 meses. En cualquier caso, se recomienda actualizar los pronósticos cada vez que llega un nuevo dato, dejando el modelo ARIMA inalterado, pero reestimando los parámetros para capturar cualquier cambio en el comportamiento de la serie.

Tabla 5.2: IMAE agropecuario y Error Absoluto Medio para distintos horizontes de pronóstico, medido sobre la tasa de variación interanual

Modelo y origen del pronóstico	Error estándar Residual	EAM según horizonte de pronóstico en meses				Horizonte recomendado
		1	3	6	12	
Costa Rica ^{2/}	4.16% ^{1/}	9.5	8.6	8.5	8.5	1 mes
El Salvador	2.14% ^{1/}	0.7	3.2	2.3	2.8	2 meses
Guatemala	2.08%	0.8	1.1	1.3	1.3	12 meses
Honduras	4.59%	3.6	1.8	3.4	2.7	3 meses
Nicaragua	4.34%	5.8	5.7	4.7	4.1	1 mes
Panamá ^{3/}	6.35%	8.0	4.0	2.7	2.6	4 trimestres
Región	1.63%	0.4	0.7	0.6	1.2	12 meses

1/ Corresponde al error residual respecto a la última observación de 2015.

2/ Si el pronóstico se inicia 3 meses después los valores del EAM bajan significativamente: 0.34 a 1 mes, 1.91 a 3 meses, 2.27 a 6 meses y 2.24 a 9 meses.

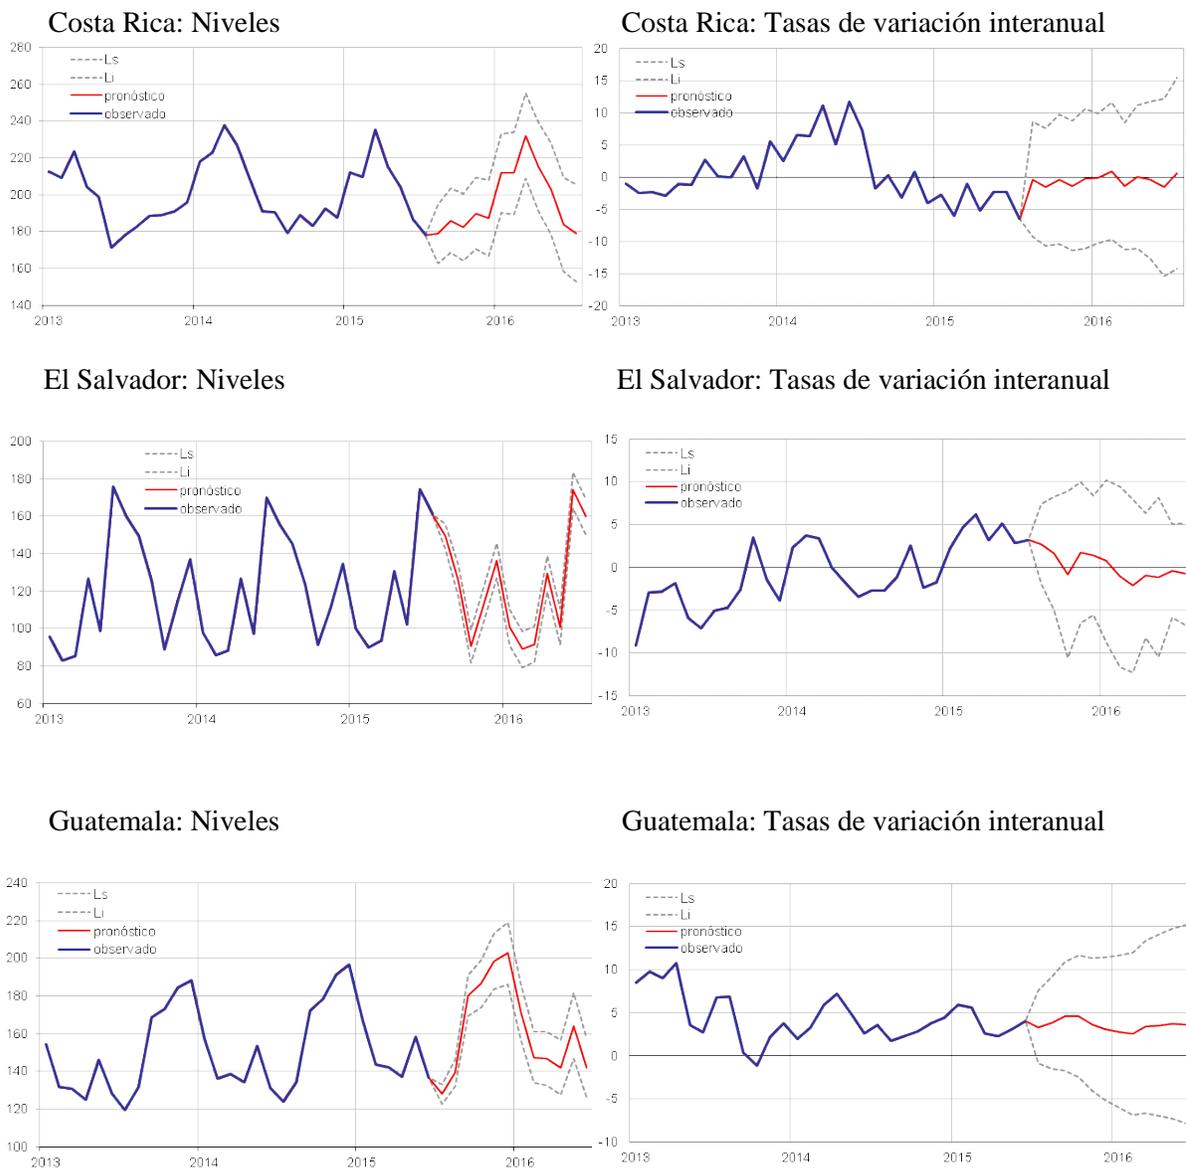
3/ En Panamá el horizonte de pronóstico corresponde a: 1, 2, 3 y 4 trimestres.

C) Pronóstico fuera de la muestra

En los gráficos 5.17 se presentan los pronósticos de 12 meses para la actividad agropecuaria de cada uno de los países y del agregado regional, acompañado de bandas al 95% de confianza. Si bien se presentan pronósticos para 12 meses, la tabla 5.2 resume el horizonte de pronóstico que se recomienda emplear para cada país. En los casos que se recomienden horizontes inferiores a 12 meses, se requiere el uso de modelos alternativos para estimaciones de más largo plazo, en especial aquellos que utilicen además, variables explicativas.

En el caso de la región, debido a que el modelo puede utilizarse por 12 meses, se prevé un crecimiento de la actividad agropecuaria entre un 2% y 3% a junio de 2016, con un comportamiento casi estacionario durante el horizonte de pronóstico. Esto sugiere la necesidad de una intervención de la política macroeconómica y sectorial para reactivar el sector agropecuario.

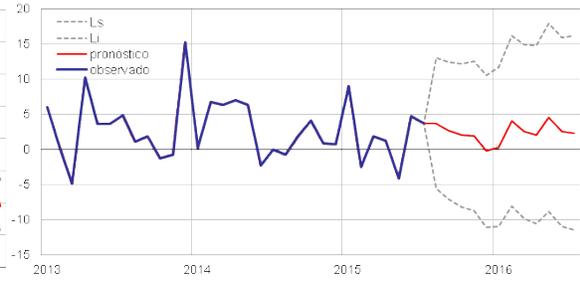
Gráfico 5.17: Pronóstico de 12 meses del IMAE agropecuario y de 4 trimestres para el PIB trimestral agropecuario de Panamá en niveles y en tasas de variación interanual incluyendo bandas al 95% de confianza



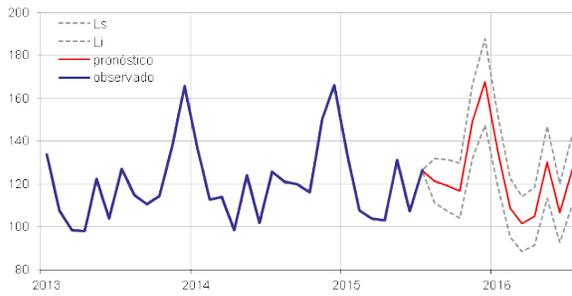
Honduras: Niveles



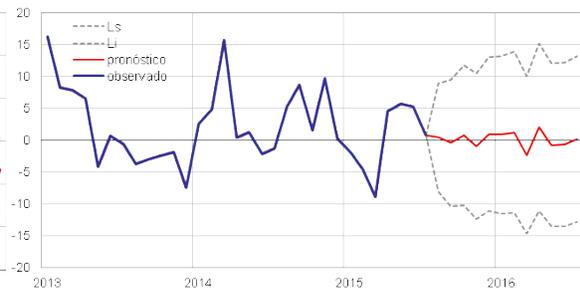
Honduras: Tasas de variación interanual



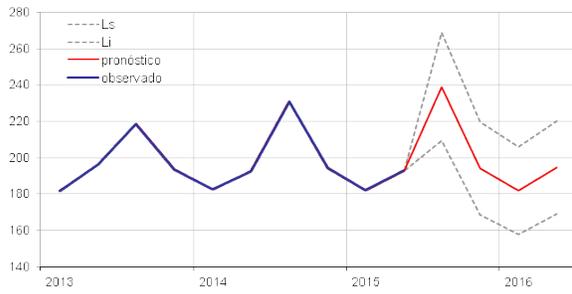
Nicaragua: Niveles



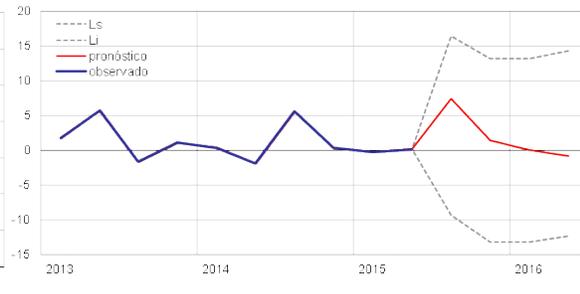
Nicaragua: Tasas de variación interanual



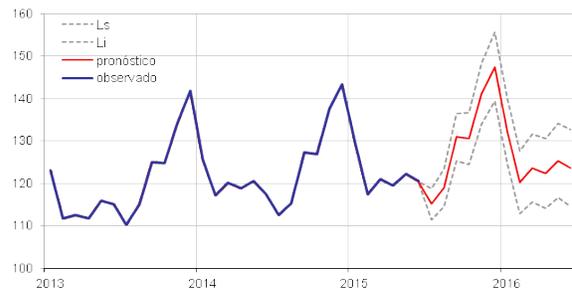
Panamá: Niveles



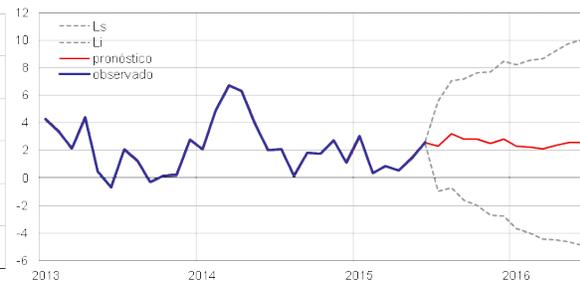
Panamá: Tasas de variación interanual



Región: Niveles



Región: Tasas de variación interanual



CONCLUSIONES Y RECOMENDACIONES

1. Los modelos ARIMA univariantes ajustados en este estudio resultan muy poderosos para el pronóstico de corto plazo y para el análisis descriptivo de las series. El analista de datos conoce plenamente su serie luego de construir un modelo ARIMA. No requieren de teoría económica ya que se basan únicamente en el pasado de la serie y en los errores que genera el modelo ajustado; de tal forma que son un punto de partida básico que debería acompañar a cualquier otro tipo de modelo.
2. Lo anterior sugiere que si en el futuro se elaboran modelos multivariados para las variables del IPC de alimentos y de la actividad productiva del sector agropecuario, los nuevos modelos no sustituyen a los ARIMA. Los modelos ARIMA pueden ser utilizados para conocer la senda que seguiría una serie si las condiciones se mantienen inalteradas.
3. Se evidenció que el modelo que mejor ajuste los datos durante el periodo de análisis, no garantiza su capacidad para predecir fuera del período utilizado para seleccionar y estimar los parámetros del modelo. De hecho, no es posible conocer a priori la capacidad de un modelo ARIMA para salir fuera del espacio muestral. El análisis se debe realizar para cada serie en particular y determinar, basados en un criterio de ajuste, el número de periodos que puede predecir un modelo en particular. En este estudio se sugiere el uso de los modelos ARIMA para predecir los siguientes horizontes:

País	Horizonte recomendado para el indicador agropecuario	Horizonte recomendado para el IPC de alimentos
Costa Rica	1 mes	6 meses
El Salvador	2 meses	12 meses
Guatemala	12 meses	6 meses ^{1/}
Honduras	3 meses	12 meses
Nicaragua	1 mes	1 mes
Panamá	4 trimestres	6 meses
Región	12 meses	9 meses

1/ El horizonte de pronóstico de 12 meses no fue evaluado para el IPC de Guatemala.

Para los modelos que no alcanzan horizontes de 12 meses se sugiere el uso de modelos complementarios, en particular aquellos que utilizan variables explicativas.

4. Con los modelos ajustados en este estudio se estima que para la mitad del 2016 la inflación regional de alimentos podría aumentar alrededor de un 4%, mientras que la producción agropecuaria regional se mantiene estacionaria entre 2% y 3%.
5. Es importante mencionar que los modelos ARIMA presentan debilidad para predecir puntos de giro. Por esta razón es importante seguir una política de revisiones donde los pronósticos se actualizan cada vez que se tiene una nueva observación, a fin de incluir toda la información conocida en t . En estos casos, el modelo ARIMA y las variables artificiales se mantienen fijos y únicamente se reestiman los valores de los parámetros.
6. Estos modelos ARIMA requieren de una revisión anual o en un periodo más corto en caso se sospeche de algún cambio estructural de los datos. Por ejemplo, se conoce que el Banco Central de Costa Rica estará divulgando un nuevo IMAE a finales de 2015 para mantener consistencia con el cambio de año base de las cuentas nacionales. Este cambio sugiere una revisión del modelo aquí identificado. Nicaragua también ha realizado recientemente revisiones al IMAE del sector agropecuario que sugieren la revisión del modelo ARIMA.
7. En el proceso de ajuste estacional llama la atención que el IPC de alimentos de la mayoría de los países de la región no presentan estacionalidad. Se exceptúa Costa Rica que muestra una estacionalidad débil. Siendo que los productos agropecuarios están sujetos a las oscilaciones estacionales, se esperaba un componente estacional importante. Esto hace sospechar de políticas de fijación o regulación de precios de algunos bienes agropecuarios presentes en la canasta del IPC de alimentos, que hace que el componente estacional se cancele. Para evaluar el componente estacional convendría hacer análisis por subgrupos de alimentos como granos básicos, hortalizas, productos tradicionales y no tradicionales de exportación, y en última instancia por tipos de bienes agropecuarios.
8. Para el análisis de coyuntura las recomendaciones internacionales se inclinan por la publicación de series desestacionalizadas. La serie desestacionalizada debe

actualizarse cada vez que se tiene nueva información, bajo un procedimiento llamado revisiones concurrentes parciales, es decir, la especificación del modelo se mantiene constante mientras que los valores de los parámetros y las estimaciones de los factores estacionales se actualizan cada vez que se tiene nueva información. La serie original, la serie desestacionalizada y la serie en tendencia-ciclo deben estar además disponibles al usuario.

9. Para la presentación de resultados de las series analizadas en este estudio se sugiere el siguiente procedimiento:
 - En el caso de la inflación de alimentos, debido a que únicamente para Costa Rica se detectó un componente estacional significativo, las señales se extraen sobre la serie original. Las tasas de variación también serán calculadas sobre la serie original. En el caso de Costa Rica se procede del mismo modo que se recomienda para la actividad agropecuaria.
 - En el caso de la actividad agropecuaria, debido a que todas las series tienen estacionalidad, se recomienda el uso de la serie desestacionalizada para el análisis de coyuntura. En un gráfico se puede presentar la serie desestacionalizada y la tendencia-ciclo, incluyendo una nota que indique el problema de las colas al final de esta última serie.

BIBLIOGRAFÍA

Banco Central de Costa Rica (s/f). **Metodología de cálculo del Índice Mensual de Actividad Económica (IMAE)**. San José, Costa Rica.

Banco de Guatemala (2013). **Índice Mensual de la Actividad Económica (IMAE). Aspectos Metodológicos 2013**. Junio. Guatemala.

Banco Central de Honduras (s/f). **Metodología de Cálculo del Índice Mensual de Actividad Económica (IMAE), Base 2000**. Tegucigalpa, Honduras.

Banco Central de Nicaragua (s/f). **Índice Mensual de Actividad Económica (IMAE), Referencia 2006**. Managua, Nicaragua.

Banco Central de Nicaragua (2010). **Índice de Precios al Consumidor base 2006=100. Nota metodológica**. Managua, Nicaragua.

Banco Central de Reserva de El Salvador (2008). **Metodología del Índice de Volumen de la Actividad Económica (IVAE) Base 1990**. Septiembre. San Salvador.

Box, G and Jenkins, G. (1970). **Time Series Analysis: Forecasting and Control**. Holden-Day. USA. (2nd edition 1976)

Davidson, Russell y Mackinnon, James. (1993). **Estimation and inference in econometrics**. Oxford University Press. New York, USA.

Instituto Nacional de Estadística y Censos de Panamá. (s/f). **Metodología de estimación del sistema de Cuentas Nacionales Trimestrales con año de referencia 2007**. Ciudad de Panamá, Panamá.

Instituto Nacional de Estadística y Censos de Panamá. (s/f). **Nota Técnica para IPC Base 2013=100**. Ciudad de Panamá, Panamá.

Instituto Nacional de Estadística y Censos de Costa Rica. (s/f). **Índice de Precios al Consumidor Base junio 2015. Metodología (Versión preliminar)**. San José, Costa Rica.

Maddala, G. (1996). **Introducción a la econometría**. Prentice-Hall Hispanoamericana, S.A. México.

Maravall, Agustín. (1999). **Short-Term Analysis of Macroeconomic Time Series**. Economics: Beyond the millennium. Oxford: Oxford University Press. Editado por Alan Firman y Gérard-Varet. Pag 244-272.

Pankratz, Alan. (1983). **Forecasting with univariate Box-Jenkins models. Concepts and cases.** John Wiley and Sons. USA.

Pankratz, Alan. (1991). **Forecasting with Dynamic Regression Models.** John Wiley and Sons. USA.

REFERENCIAS DE MANUALES:

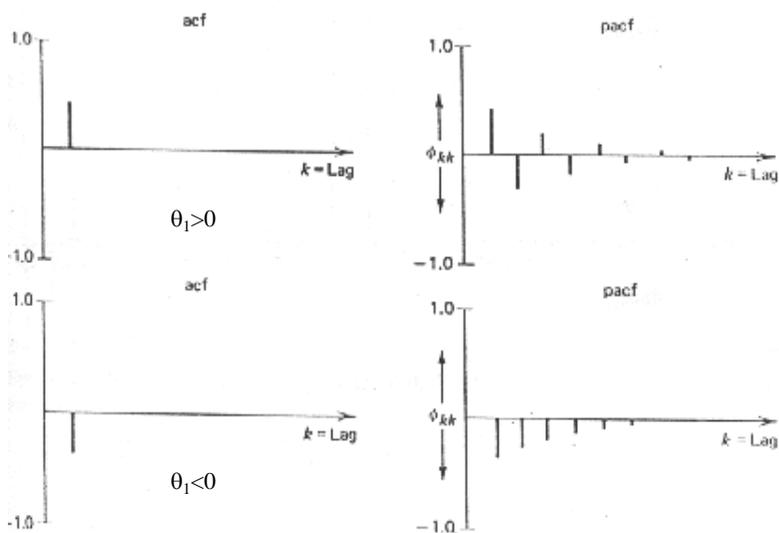
- ♦ Eurostat (2015). **ESS guidelines on seasonal adjustment.** Luxemburgo.
- ♦ FMI (2001). **Manual de Cuentas Nacionales Trimestrales. Conceptos, fuentes de datos y compilación.** Washington, D.C.
- ♦ FMI (2013). **Update of the quarterly national accounts manual: an outline.** Washington, D.C.
- ♦ OECD (2012). **OECD System of Composite Leading Indicators.**

PROGRAMAS INFOMÁTICOS GRATUITOS:

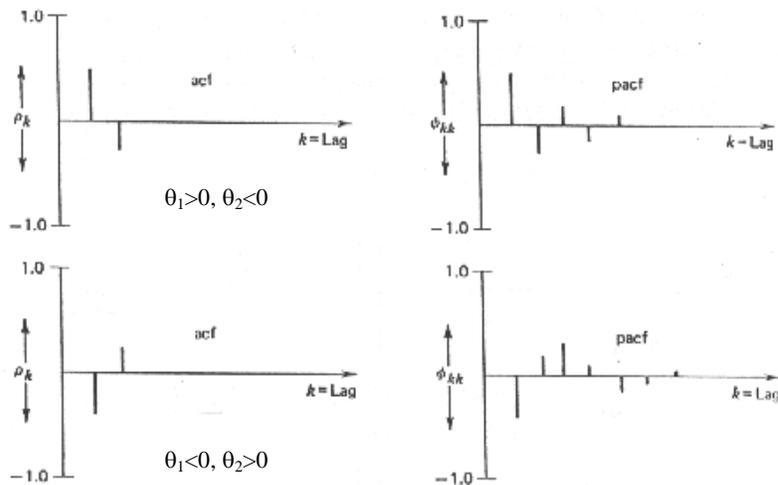
- ♦ El Banco de España permite descargar en forma gratuita el paquete Tramo-Seats (**TSW+**) en:
http://www.bde.es/bde/es/secciones/servicios/Profesionales/Programas_estadi/Programas_estad_d9fa7f3710fd821.html
- ♦ El US Census Bureau permite descargar en forma gratuita el **paquete X-13ARIMA-SEATS** en:
<http://www.census.gov/srd/www/winx13/index.html#x13data>

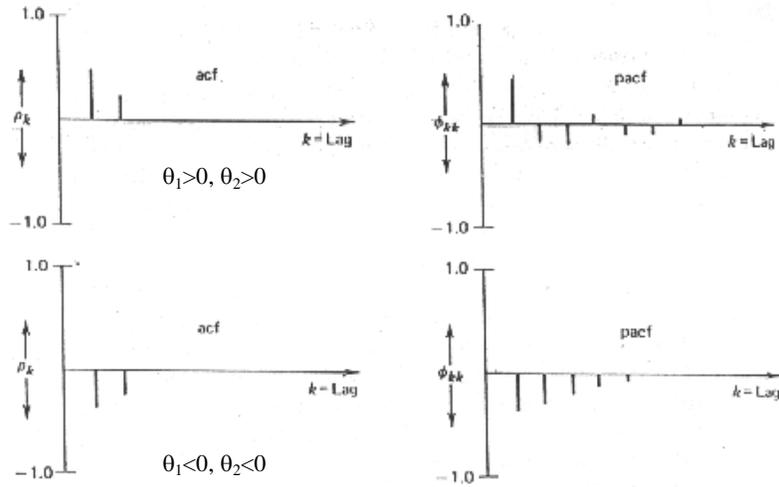
ANEXO 1: ESTRUCTURAS TEÓRICAS DE ALGUNAS FUNCIONES DE AUTOCORRELACIÓN PARA DISTINTOS MODELOS ARIMA

Modelo MA(1)

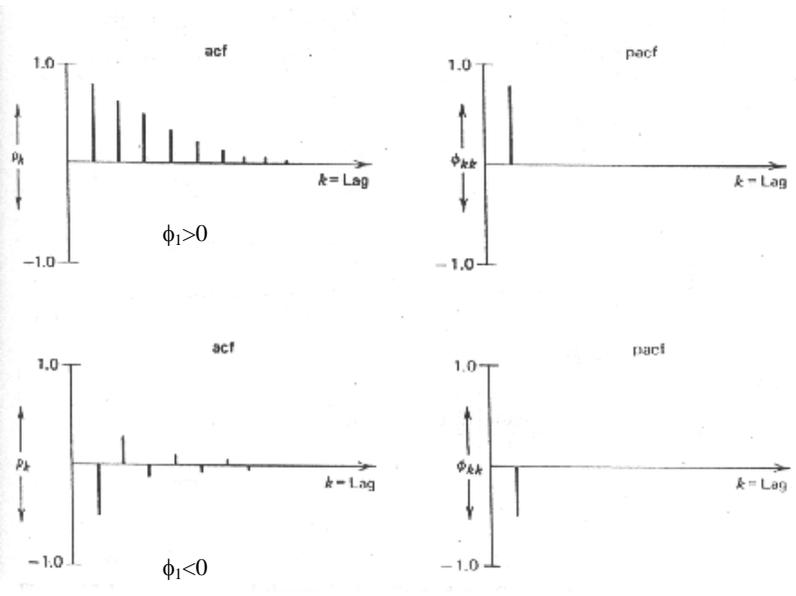


Modelo MA(2)

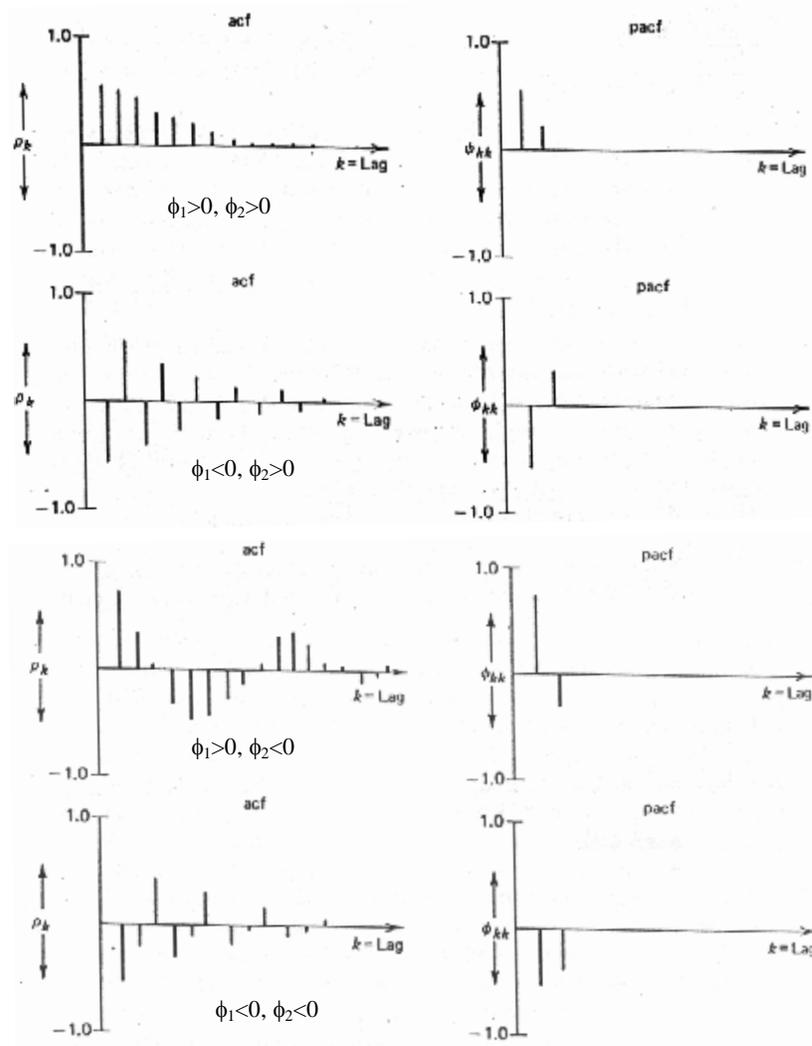




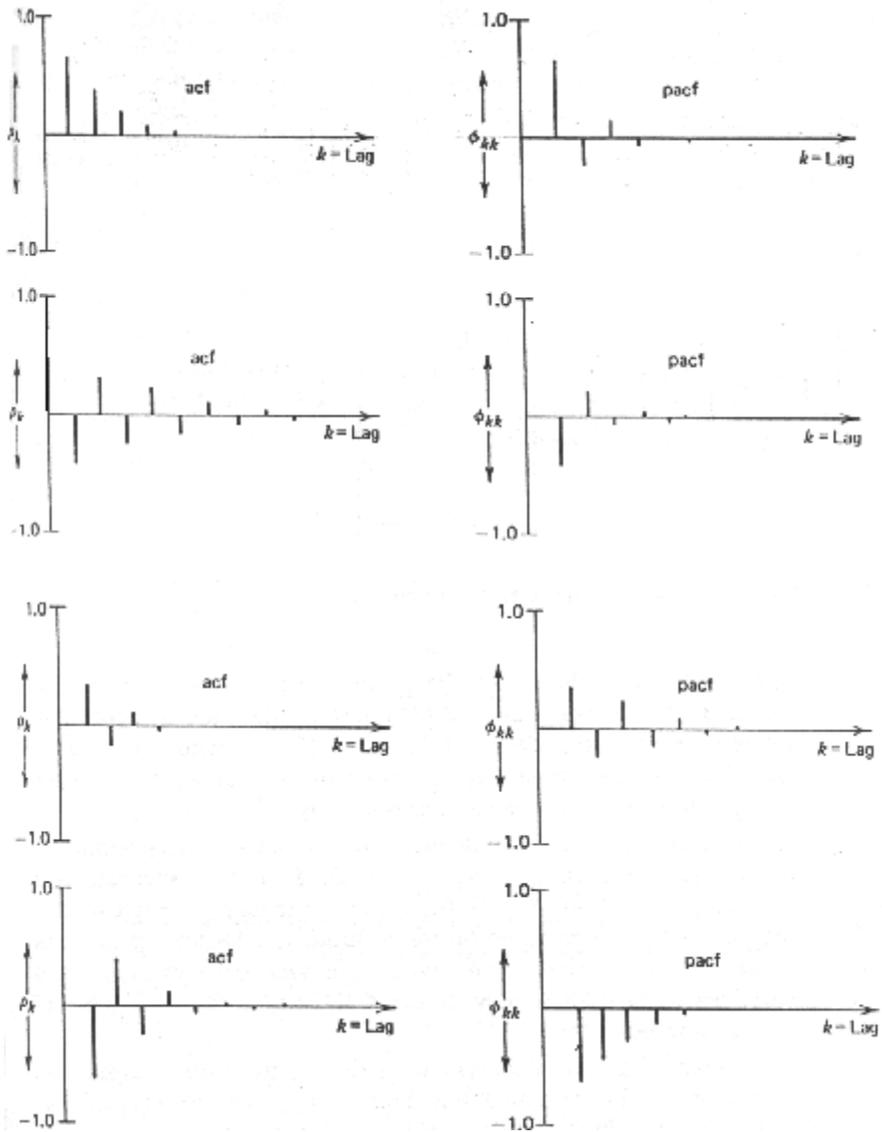
Modelo AR(1)



Modelo AR(2)



Modelo ARMA(1,1)



Fuente: Pankratz, 1983, pag' 301-305.

ANEXO 2: SERIES DE DATOS UTILIZADAS EN ESTE INFORME

Índices de Precios al consumidor del grupo Alimentos 2009-2015

	COSTA RICA	EL SALVADOR	GUATEMALA	HONDURAS	NICARAGUA	PANAMÁ	REGIÓN
2009	81.18	107.31		205.20	156.70	79.07	
2009M02	79.51	106.37		204.40	154.40	79.42	
2009M03	78.84	105.72		202.80	152.47	79.87	
2009M04	78.48	104.56		201.00	150.86	79.81	
2009M05	77.69	104.31		199.80	150.08	78.79	
2009M06	77.13	103.21		199.70	147.27	79.07	
2009M07	77.16	102.64		200.30	144.43	79.24	
2009M08	77.78	101.80		199.00	143.93	79.42	
2009M09	77.94	102.07		197.70	144.45	79.13	
2009M10	78.28	101.38		197.30	144.93	79.24	
2009M11	78.09	100.76		196.80	143.46	79.07	
2009M12	79.58	100.00		195.70	143.54	79.24	
2010	80.14	101.33		196.20	146.26	80.21	
2010M02	80.19	102.03		197.40	150.32	80.33	
2010M03	79.98	103.55		199.00	153.67	80.44	
2010M04	80.32	102.84		200.10	154.16	80.61	
2010M05	80.83	102.27		199.20	152.47	80.89	
2010M06	81.46	104.50		202.40	152.07	81.46	
2010M07	82.06	104.48		204.00	155.45	81.75	
2010M08	82.82	103.47		204.20	151.99	82.49	
2010M09	82.39	104.58		205.30	152.37	82.32	
2010M10	83.28	107.46		209.60	159.51	82.43	
2010M11	85.08	108.44		213.70	164.58	82.49	
2010M12	86.76	107.88		211.90	163.24	83.28	
2011	87.06	108.16		211.40	162.72	84.08	
2011M02	86.59	108.53		211.20	163.58	84.48	
2011M03	86.24	109.61		213.10	163.82	84.88	
2011M04	85.60	112.17	105.01	214.30	164.45	85.50	98.01
2011M05	85.71	112.63	105.71	215.00	166.04	85.84	98.46
2011M06	85.59	113.74	107.76	216.60	168.28	85.50	99.27
2011M07	86.17	114.31	110.66	219.90	168.04	85.84	100.50
2011M08	86.77	113.58	112.13	220.10	170.52	86.53	101.23
2011M09	85.89	112.10	111.64	218.30	170.85	87.49	100.84

2011M10	86.91	111.64	111.38	217.50	171.70	87.95	101.02
2011M11	87.67	111.98	111.55	218.10	176.84	88.92	101.74
2011M12	90.29	111.29	112.08	218.40	178.34	89.54	102.59
2012	88.84	111.39	111.91	218.50	178.83	90.00	102.40
2012M02	88.93	111.43	112.61	219.23	181.57	91.13	103.03
2012M03	88.91	111.36	113.35	220.03	181.62	91.42	103.33
2012M04	89.27	112.40	114.03	221.23	184.51	92.22	104.09
2012M05	89.91	112.11	114.06	221.43	182.90	93.52	104.42
2012M06	90.46	112.19	114.97	221.33	181.66	93.58	104.76
2012M07	90.18	112.12	115.74	222.63	181.81	94.04	105.07
2012M08	90.14	111.67	116.49	223.73	180.77	94.49	105.33
2012M09	89.60	112.00	117.44	224.93	182.18	94.38	105.61
2012M10	89.50	112.07	117.76	225.80	183.32	94.32	105.77
2012M11	90.15	112.45	118.19	226.60	187.37	95.23	106.50
2012M12	91.37	112.52	118.82	226.70	192.77	95.97	107.36
2013	92.29	113.46	119.84	227.30	197.91	96.42	108.43
2013M02	93.63	114.44	121.54	230.20	197.79	96.54	109.45
2013M03	93.05	115.50	122.77	231.30	197.62	96.99	109.95
2013M04	92.94	114.75	123.24	232.30	199.15	97.90	110.30
2013M05	92.86	114.26	123.96	232.70	202.29	98.47	110.72
2013M06	92.50	115.10	125.50	234.10	202.68	99.10	111.40
2013M07	93.24	114.91	126.05	235.80	200.20	99.55	111.76
2013M08	93.14	114.73	126.20	236.10	201.50	99.67	111.86
2013M09	92.91	114.67	126.96	236.50	200.86	99.61	111.99
2013M10	93.27	114.71	127.01	236.00	199.98	100.01	112.12
2013M11	94.28	114.56	129.19	237.00	201.52	100.07	113.06
2013M12	94.39	114.70	129.26	237.90	204.29	100.41	113.36
2014	94.37	115.65	129.70	241.50	207.53	100.81	114.00
2014M02	93.69	115.77	130.22	242.40	207.38	101.43	114.20
2014M03	93.87	115.75	130.46	243.40	206.26	101.94	114.42
2014M04	95.07	115.48	130.71	244.60	207.93	102.85	115.05
2014M05	96.24	116.24	131.59	247.60	212.02	103.08	116.01
2014M06	97.18	117.88	133.22	249.50	218.24	103.99	117.44
2014M07	97.98	119.81	135.04	253.50	219.80	100.81	117.83
2014M08	99.53	121.60	137.03	253.10	220.65	101.03	119.01
2014M09	99.06	120.97	137.27	252.70	219.15	101.77	118.99
2014M10	98.63	121.22	138.27	254.20	220.07	101.89	119.34
2014M11	100.28	120.36	139.75	258.20	227.89	101.90	120.54
2014M12	100.36	118.95	140.30	255.10	228.26	101.90	120.43
2015	101.29	119.31	141.00	253.79	228.00	100.70	120.51
2015M02	101.41	119.23	141.93	255.10	226.69	100.17	120.66

2015M03	101.08	119.81	142.68	256.50	225.83	100.30	120.92
2015M04	101.19	120.30	143.78	256.20	227.46	100.20	121.35
2015M05	99.65	120.62	144.97	256.90	228.12	100.70	121.57
2015M06	100.00	120.31	146.28	258.20	227.22	101.00	122.07
2015M07	99.43	120.35	148.10	260.00	224.90	101.50	122.55
2015M08	99.45	119.92	148.71	260.10	224.44	101.70	122.71
2015M09	99.35	119.68	149.03	260.10	224.42	101.80	122.77

IMAE del Sector Agropecuario 2006-2015

	COSTA RICA	EL SALVADOR	GUATEMALA	HONDURAS	NICARAGUA	REGIÓN
2006M01	189.3	102.3	115.2	125.0	118.9	101.8
2006M02	190.1	82.8	94.1	134.9	82.9	89.5
2006M03	208.8	76.0	100.6	130.5	79.1	92.0
2006M04	169.4	108.7	99.7	108.8	73.3	89.6
2006M05	195.8	92.0	117.4	128.6	95.8	99.9
2006M06	160.3	167.2	98.3	122.5	87.4	100.4
2006M07	151.9	147.1	98.7	87.6	99.0	93.7
2006M08	161.5	137.9	100.7	112.7	99.5	96.6
2006M09	162.1	113.7	137.1	123.8	96.1	105.1
2006M10	165.4	77.7	141.6	152.0	96.7	103.8
2006M11	166.4	107.4	147.2	144.0	123.5	112.4
2006M12	163.9	132.5	145.1	119.0	147.8	115.3
2007M01	209.9	108.2	127.5	123.9	109.3	108.4
2007M02	206.3	87.6	108.8	153.4	89.4	99.6
2007M03	213.4	80.2	104.4	143.5	89.0	96.8
2007M04	195.8	121.7	108.3	128.0	84.8	100.8
2007M05	202.1	102.0	121.6	129.8	111.4	105.2
2007M06	173.2	184.6	109.8	128.3	102.7	110.5
2007M07	166.0	158.5	105.4	89.7	118.5	101.4
2007M08	161.3	147.9	109.4	122.6	115.7	103.4
2007M09	158.2	123.5	145.7	130.0	109.9	111.0
2007M10	170.3	79.5	137.7	158.6	112.7	105.7
2007M11	173.0	116.2	152.7	146.9	138.4	118.2
2007M12	173.7	143.1	146.5	130.2	164.0	121.4
2008M01	203.1	109.0	128.0	143.6	115.9	110.5
2008M02	203.0	86.4	102.9	154.8	95.7	98.0
2008M03	192.7	79.3	103.3	149.3	89.1	94.4
2008M04	193.4	118.5	99.3	117.8	94.9	96.9
2008M05	188.0	98.2	122.8	118.0	117.9	102.7
2008M06	174.0	182.4	113.2	127.4	111.8	111.9
2008M07	170.4	160.6	105.2	89.6	117.2	101.9
2008M08	155.2	146.6	112.3	125.0	116.3	103.5
2008M09	165.4	120.3	148.3	134.1	111.3	112.7
2008M10	167.5	77.8	152.1	154.6	110.9	109.3

2008M11	156.2	111.8	152.0	137.5	117.7	112.3
2008M12	165.4	138.8	151.5	136.5	153.1	120.8
2009M01	177.6	97.8	132.7	135.1	102.6	105.0
2009M02	188.5	82.9	111.3	150.3	90.4	97.4
2009M03	191.0	81.8	109.8	142.9	86.3	95.9
2009M04	188.4	116.0	106.9	122.3	83.4	97.7
2009M05	188.2	93.4	125.2	120.4	111.7	102.4
2009M06	174.7	170.7	112.3	121.5	106.5	108.5
2009M07	151.9	153.2	105.1	89.6	121.2	98.5
2009M08	156.4	141.7	113.8	120.4	117.6	102.9
2009M09	155.5	117.7	151.2	125.5	109.9	111.2
2009M10	165.2	77.7	157.3	160.7	109.0	111.5
2009M11	169.0	110.1	161.5	137.5	143.5	119.3
2009M12	172.8	132.3	160.6	132.9	177.8	125.6
2010M01	195.4	106.5	141.0	142.0	120.9	113.7
2010M02	195.7	86.2	112.8	151.4	96.6	100.1
2010M03	227.0	78.4	112.0	151.4	93.3	102.4
2010M04	209.7	120.1	108.5	125.6	85.4	102.2
2010M05	196.4	99.7	127.8	118.2	114.4	105.5
2010M06	179.0	178.0	110.0	123.7	111.5	109.9
2010M07	160.6	161.2	102.9	86.9	126.2	100.2
2010M08	170.5	149.2	111.0	115.3	119.7	104.6
2010M09	167.9	126.5	147.7	126.4	109.3	112.9
2010M10	165.8	81.5	154.5	153.8	112.2	110.8
2010M11	176.7	116.5	156.7	137.2	144.4	119.7
2010M12	177.7	136.9	158.8	133.7	169.4	125.6
2011M01	188.5	104.2	137.3	149.5	115.5	111.6
2011M02	201.7	87.1	113.3	168.8	99.7	103.2
2011M03	220.4	82.8	112.8	168.6	93.8	104.3
2011M04	218.0	117.7	113.3	133.5	92.3	105.9
2011M05	205.9	99.8	137.3	127.9	125.6	112.0
2011M06	179.8	173.3	116.8	131.3	113.7	112.4
2011M07	153.6	154.0	111.4	96.9	131.1	102.3
2011M08	167.4	144.4	117.1	129.7	124.9	107.3
2011M09	171.4	121.0	157.2	139.2	119.7	117.8
2011M10	173.0	82.9	165.3	165.3	121.5	117.6
2011M11	182.3	114.9	169.6	147.3	153.1	126.3
2011M12	178.1	137.2	170.0	141.7	188.8	132.0
2012M01	214.7	105.2	142.3	161.7	115.2	118.0
2012M02	214.8	85.3	120.1	182.3	99.3	108.0
2012M03	228.8	87.9	120.0	189.3	91.4	110.2
2012M04	210.3	129.1	113.0	139.4	92.2	107.0
2012M05	200.9	105.1	141.1	144.5	128.0	115.4
2012M06	173.3	189.3	124.8	136.9	103.4	116.0
2012M07	172.8	168.8	112.0	106.2	128.1	108.0
2012M08	182.4	156.9	123.3	141.7	119.4	113.8
2012M09	188.7	128.8	168.0	150.0	113.9	125.5
2012M10	183.1	86.0	175.3	189.3	117.2	124.6
2012M11	194.5	115.8	180.3	180.9	139.8	133.7
2012M12	185.4	142.4	181.3	153.0	179.1	138.0

2013M01	212.6	95.6	154.4	171.4	133.9	123.1
2013M02	209.4	82.8	131.7	182.8	107.5	111.7
2013M03	223.5	85.4	130.9	180.0	98.6	112.5
2013M04	204.3	126.7	125.1	153.6	98.2	111.8
2013M05	198.7	98.9	146.2	149.7	122.6	115.9
2013M06	171.2	175.8	128.2	141.9	104.1	115.2
2013M07	177.5	160.3	119.6	111.3	127.3	110.3
2013M08	182.7	149.5	131.8	143.2	115.0	115.2
2013M09	188.5	125.4	168.5	152.7	110.5	125.1
2013M10	189.0	89.0	173.3	186.9	114.4	124.8
2013M11	191.0	114.1	184.2	179.5	137.3	134.0
2013M12	195.7	136.9	188.2	176.3	165.7	141.8
2014M01	217.9	97.8	157.5	171.7	137.3	125.6
2014M02	223.1	85.9	136.1	195.1	112.7	117.1
2014M03	237.9	88.3	138.6	191.4	114.1	120.1
2014M04	227.1	126.6	134.1	164.3	98.6	118.8
2014M05	208.8	97.2	153.5	159.1	124.1	120.5
2014M06	191.2	169.8	131.5	138.6	101.9	117.5
2014M07	190.4	155.9	123.9	111.2	125.7	112.6
2014M08	179.4	145.4	134.1	142.1	121.1	115.4
2014M09	189.0	124.0	172.3	155.5	120.0	127.4
2014M10	183.1	91.3	178.3	194.5	116.1	127.0
2014M11	192.5	111.4	191.3	181.1	150.5	137.7
2014M12	187.8	134.5	196.5	177.5	166.2	143.4
2015M01	212.0	100.0	166.8	187.1	134.7	129.4
2015M02	209.8	89.9	143.7	190.2	107.5	117.5
2015M03	235.4	93.8	142.1	194.9	103.9	121.1
2015M04	215.3	130.6	137.1	166.3	103.1	119.5
2015M05	204.1	102.2	158.2	152.5	131.2	122.3
2015M06	186.8	174.6	136.9	145.1	107.3	120.6
2015M07	178.1	160.9		115.3	126.6	

*PIB trimestral del Sector Agropecuario de Panamá 2006-2015
Millones de balboas a precios constantes con año de referencia 2007*

Trimestres	I	II	III	IV
2007	271.0	179.6	191.0	173.4
2008	254.2	206.8	198.6	175.7
2009	182.2	179.6	195.5	170.6
2010	176.4	168.5	204.8	178.8
2011	175.6	181.9	216.1	188.3
2012	178.6	185.8	222.6	191.6
2013	181.7	196.3	218.8	193.7
2014	182.4	192.5	230.9	194.3
2015	182.0	192.8		

ANEXO 3: PONDERADOS UTILIZADOS PARA LA CONSTRUCCIÓN DE INDICADORES REGIONALES

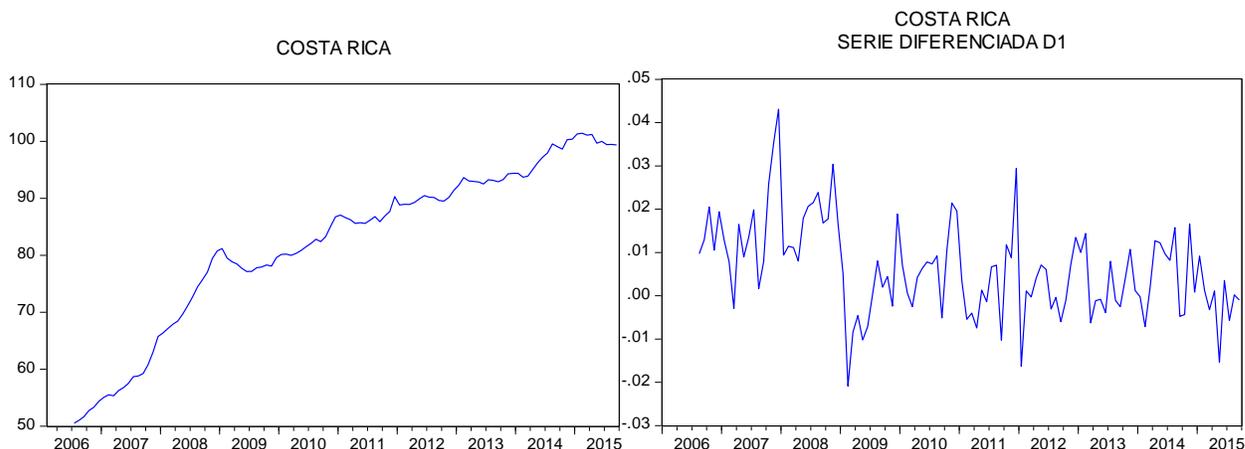
Datos básicos del INB por país y ponderadores 2006-2014

Año	2006	2007	2008	2009	2010	2011	2012	2013	2014
INB por PPA (en miles de millones US\$)									
Costa Rica	45.85	49.13	52.46	51.11	55.22	59.28	62.53	65.61	68.63
El Salvador	39.05	41.67	43.23	41.82	42.96	44.74	45.94	47.52	49.26
Guatemala	77.61	84.51	89.07	89.73	93.42	98.77	104.49	110.16	115.19
Honduras	25.36	28.12	29.98	29.77	30.42	31.99	31.06	32.19	34.00
Nicaragua	18.74	20.44	21.52	21.00	22.00	23.89	25.45	27.04	28.81
Panamá	40.15	45.89	50.62	52.90	56.41	57.19	63.23	74.57	77.08
Centroamérica	206.62	223.87	236.26	233.42	244.01	258.68	269.46	282.52	295.89
CA y Panamá	246.77	269.76	286.88	286.32	300.43	315.88	332.69	357.08	372.97
Ponderadores Centroamérica									
Costa Rica	0.222	0.219	0.222	0.219	0.226	0.229	0.232	0.232	0.232
El Salvador	0.189	0.186	0.183	0.179	0.176	0.173	0.170	0.168	0.166
Guatemala	0.376	0.378	0.377	0.384	0.383	0.382	0.388	0.390	0.389
Honduras	0.123	0.126	0.127	0.128	0.125	0.124	0.115	0.114	0.115
Nicaragua	0.091	0.091	0.091	0.090	0.090	0.092	0.094	0.096	0.097
Centroamérica	1.000								
Ponderadores Centroamérica y Panamá									
Costa Rica	0.186	0.182	0.183	0.179	0.184	0.188	0.188	0.184	0.184
El Salvador	0.158	0.154	0.151	0.146	0.143	0.142	0.138	0.133	0.132
Guatemala	0.315	0.313	0.310	0.313	0.311	0.313	0.314	0.308	0.309
Honduras	0.103	0.104	0.105	0.104	0.101	0.101	0.093	0.090	0.091
Nicaragua	0.076	0.076	0.075	0.073	0.073	0.076	0.076	0.076	0.077
Panamá	0.163	0.170	0.176	0.185	0.188	0.181	0.190	0.209	0.207
CA y Panamá	1.000								

Fuente: Banco Mundial. <http://datos.bancomundial.org/indicador/NY.GNP.MKTP.PP.CD>

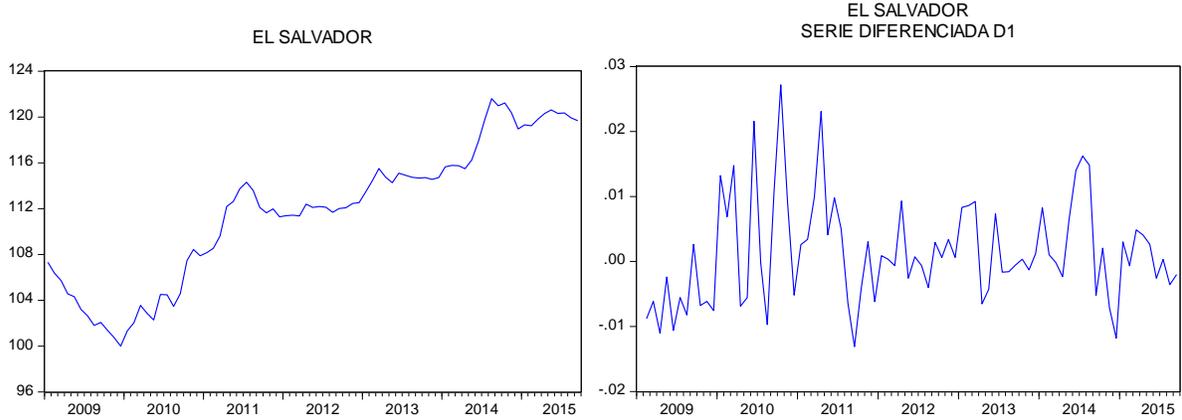
ANEXO 4: ANÁLISIS PREVIO DEL IPC DE ALIMENTOS

Gráficos y correlogramas del IPC alimentos de Costa Rica



Correlogram of CR						Correlogram of D(CR)							
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob		
		1	0.968	0.968	106.92	0.000			1	0.354	0.354	14.138	0.000
		2	0.935	-0.041	207.54	0.000			2	0.223	0.112	19.815	0.000
		3	0.901	-0.029	301.85	0.000			3	0.012	-0.113	19.832	0.000
		4	0.867	-0.016	390.01	0.000			4	0.042	0.053	20.041	0.000
		5	0.833	-0.019	472.17	0.000			5	0.091	0.101	21.020	0.001
		6	0.798	-0.035	548.30	0.000			6	0.014	-0.072	21.043	0.002
		7	0.763	-0.018	618.60	0.000			7	0.043	0.034	21.266	0.003
		8	0.728	-0.032	683.11	0.000			8	0.000	0.002	21.266	0.006
		9	0.691	-0.039	741.83	0.000			9	-0.066	-0.102	21.791	0.010
		10	0.656	0.000	795.20	0.000			10	-0.042	0.008	22.012	0.015
		11	0.620	-0.022	843.42	0.000			11	0.068	0.140	22.581	0.020
		12	0.586	-0.002	886.89	0.000			12	0.180	0.127	26.643	0.009
		13	0.551	-0.025	925.79	0.000			13	0.060	-0.095	27.098	0.012
		14	0.515	-0.044	960.15	0.000			14	-0.040	-0.080	27.300	0.018
		15	0.481	-0.005	990.34	0.000			15	-0.145	-0.097	30.033	0.012
		16	0.448	0.017	1016.9	0.000			16	-0.020	0.077	30.084	0.018
		17	0.419	0.025	1040.4	0.000			17	-0.028	-0.025	30.186	0.025
		18	0.394	0.045	1061.3	0.000			18	0.001	-0.012	30.186	0.036
		19	0.371	-0.004	1080.1	0.000			19	0.002	0.017	30.187	0.049
		20	0.347	-0.013	1096.7	0.000			20	-0.126	-0.142	32.367	0.040
		21	0.324	-0.014	1111.4	0.000			21	-0.119	-0.034	34.332	0.033
		22	0.302	-0.013	1124.2	0.000			22	-0.081	0.067	35.242	0.037
		23	0.281	0.001	1135.5	0.000			23	0.180	0.231	39.834	0.016
		24	0.261	0.005	1145.3	0.000			24	0.284	0.149	51.390	0.001
		25	0.243	-0.007	1153.9	0.000			25	0.161	-0.048	55.140	0.000
		26	0.226	0.001	1161.4	0.000			26	0.096	0.029	56.496	0.000
		27	0.209	-0.001	1168.0	0.000			27	-0.053	-0.081	56.906	0.001
		28	0.195	0.018	1173.7	0.000			28	-0.045	-0.098	57.216	0.001
		29	0.183	0.028	1178.8	0.000			29	-0.074	-0.059	58.043	0.001
		30	0.173	0.008	1183.5	0.000			30	-0.011	0.027	58.060	0.002
		31	0.163	-0.016	1187.7	0.000			31	-0.053	-0.071	58.495	0.002
		32	0.150	-0.063	1191.2	0.000			32	0.037	0.167	58.713	0.003
		33	0.136	-0.017	1194.2	0.000			33	-0.109	-0.068	60.631	0.002
		34	0.123	-0.009	1196.7	0.000			34	-0.126	-0.152	63.196	0.002
		35	0.109	-0.016	1198.6	0.000			35	0.132	0.209	66.037	0.001
		36	0.093	-0.037	1200.1	0.000			36	0.161	0.064	70.361	0.001

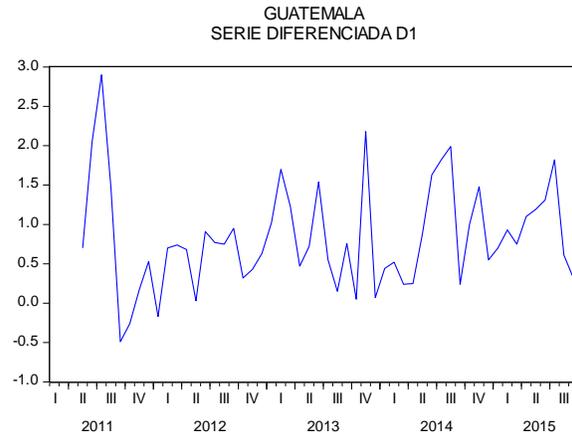
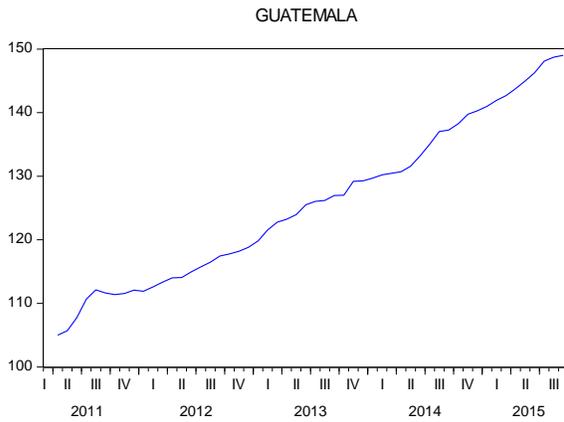
Gráficos y correlogramas del IPC alimentos de El Salvador



Correlogram of SV					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.975	0.975	79.927	0.000	
2	0.941	-0.202	155.32	0.000	
3	0.904	-0.048	225.77	0.000	
4	0.864	-0.073	290.90	0.000	
5	0.820	-0.062	350.42	0.000	
6	0.776	-0.030	404.34	0.000	
7	0.731	-0.006	452.91	0.000	
8	0.685	-0.058	496.15	0.000	
9	0.637	-0.063	534.03	0.000	
10	0.585	-0.092	566.45	0.000	
11	0.528	-0.113	593.27	0.000	
12	0.473	0.023	615.07	0.000	
13	0.420	0.022	632.51	0.000	
14	0.366	-0.082	645.93	0.000	
15	0.320	0.157	656.33	0.000	
16	0.279	0.034	664.41	0.000	
17	0.244	0.017	670.65	0.000	
18	0.213	0.051	675.48	0.000	
19	0.183	-0.044	679.11	0.000	
20	0.152	-0.077	681.67	0.000	
21	0.125	0.062	683.42	0.000	
22	0.105	0.090	684.68	0.000	
23	0.087	-0.050	685.56	0.000	
24	0.069	-0.057	686.11	0.000	
25	0.052	-0.037	686.44	0.000	
26	0.037	-0.061	686.61	0.000	
27	0.022	-0.002	686.67	0.000	
28	0.008	-0.014	686.68	0.000	
29	-0.005	0.004	686.68	0.000	
30	-0.018	-0.009	686.73	0.000	
31	-0.032	-0.064	686.87	0.000	
32	-0.045	0.031	687.14	0.000	
33	-0.057	-0.003	687.60	0.000	
34	-0.069	0.004	688.28	0.000	
35	-0.077	0.044	689.15	0.000	
36	-0.085	0.010	690.23	0.000	

Correlogram of D(SV)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.310	0.310	7.9761	0.005	
2	0.009	-0.097	7.9825	0.018	
3	0.040	0.075	8.1189	0.044	
4	0.042	0.006	8.2695	0.082	
5	-0.020	-0.036	8.3028	0.140	
6	-0.039	-0.022	8.4386	0.208	
7	0.044	0.065	8.6093	0.282	
8	0.072	0.038	9.0752	0.336	
9	0.120	0.106	10.399	0.319	
10	-0.047	-0.133	10.610	0.389	
11	-0.274	-0.249	17.741	0.088	
12	-0.057	0.112	18.050	0.114	
13	-0.009	-0.047	18.059	0.155	
14	-0.103	-0.065	19.105	0.161	
15	-0.139	-0.082	21.044	0.135	
16	-0.074	-0.060	21.609	0.156	
17	-0.007	0.012	21.614	0.200	
18	-0.134	-0.128	23.519	0.171	
19	-0.058	0.072	23.875	0.201	
20	-0.109	-0.095	25.175	0.195	
21	-0.053	-0.023	25.488	0.227	
22	-0.028	-0.080	25.576	0.270	
23	-0.060	0.011	25.995	0.301	
24	-0.106	-0.101	27.311	0.290	
25	-0.043	-0.012	27.534	0.330	
26	0.014	-0.038	27.559	0.381	
27	0.079	0.117	28.328	0.394	
28	0.094	0.047	29.438	0.391	
29	0.006	-0.138	29.443	0.442	
30	-0.025	0.010	29.528	0.490	
31	-0.015	-0.080	29.560	0.540	
32	0.018	0.049	29.602	0.588	
33	0.015	-0.016	29.633	0.636	
34	-0.132	-0.239	32.116	0.560	
35	-0.026	0.015	32.216	0.603	
36	0.126	0.062	34.592	0.536	

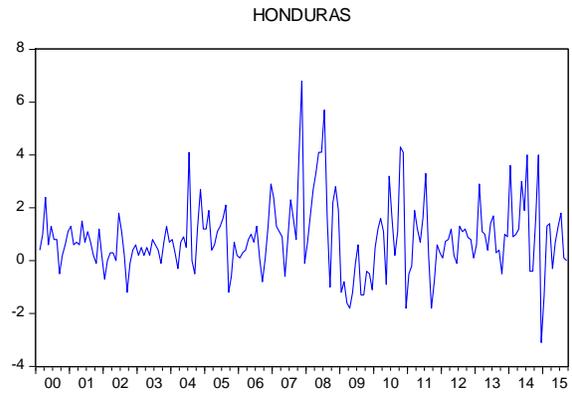
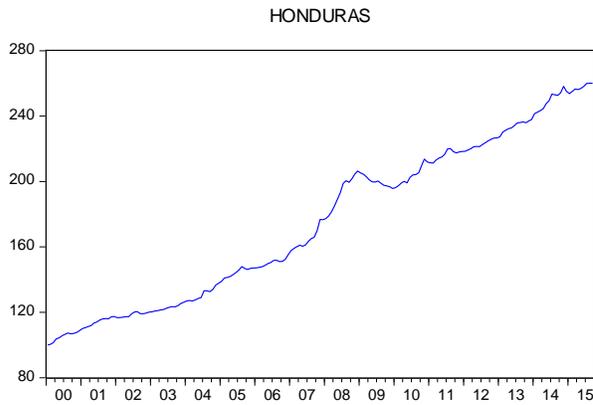
Gráficos y correlogramas del IPC alimentos de Guatemala



Correlogram of GT					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.938	0.938	50.217	0.000	
2	0.874	-0.053	94.615	0.000	
3	0.812	-0.011	133.72	0.000	
4	0.759	0.039	168.61	0.000	
5	0.711	0.000	199.78	0.000	
6	0.661	-0.039	227.26	0.000	
7	0.609	-0.031	251.16	0.000	
8	0.558	-0.035	271.60	0.000	
9	0.506	-0.032	288.79	0.000	
10	0.452	-0.055	302.82	0.000	
11	0.398	-0.035	313.96	0.000	
12	0.347	-0.018	322.62	0.000	
13	0.296	-0.034	329.09	0.000	
14	0.244	-0.060	333.58	0.000	
15	0.196	0.002	336.55	0.000	
16	0.152	-0.004	338.38	0.000	
17	0.112	-0.009	339.41	0.000	
18	0.074	-0.017	339.87	0.000	
19	0.035	-0.040	339.98	0.000	
20	-0.005	-0.044	339.98	0.000	
21	-0.046	-0.040	340.17	0.000	
22	-0.085	-0.035	340.86	0.000	
23	-0.122	-0.030	342.31	0.000	
24	-0.153	0.007	344.68	0.000	

Correlogram of D(GT)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.294	0.294	4.8321	0.028	
2	-0.058	-0.157	5.0221	0.081	
3	-0.135	-0.078	6.0917	0.107	
4	-0.092	-0.036	6.5956	0.159	
5	-0.046	-0.031	6.7217	0.242	
6	-0.110	-0.124	7.4664	0.280	
7	-0.074	-0.025	7.8107	0.350	
8	0.075	0.088	8.1758	0.416	
9	0.075	-0.012	8.5508	0.480	
10	-0.187	-0.254	10.911	0.364	
11	0.039	0.229	11.017	0.442	
12	0.091	-0.017	11.608	0.478	
13	-0.090	-0.219	12.194	0.512	
14	-0.027	0.127	12.248	0.586	
15	-0.124	-0.138	13.436	0.569	
16	-0.112	-0.168	14.430	0.567	
17	0.044	0.144	14.589	0.625	
18	0.018	-0.011	14.616	0.688	
19	0.104	0.038	15.552	0.687	
20	0.107	-0.046	16.567	0.681	
21	-0.041	0.012	16.720	0.728	
22	-0.042	0.019	16.882	0.770	
23	0.150	0.100	19.073	0.697	
24	0.016	0.002	19.098	0.747	

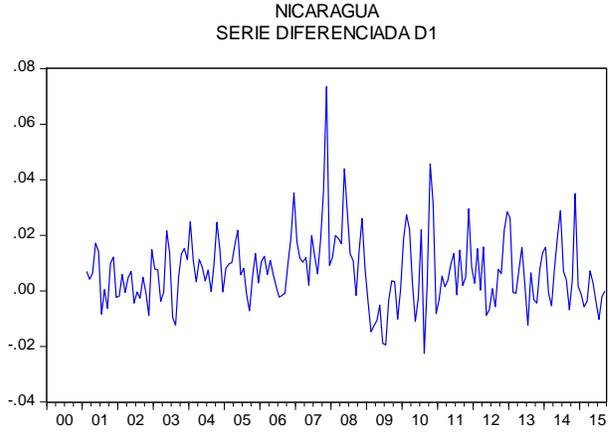
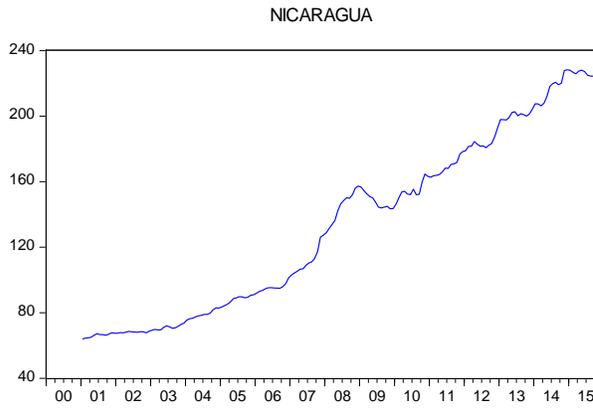
Gráficos y correlogramas del IPC alimentos de Honduras



Correlogram of HN					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.985	0.985	186.47	0.000	
2	0.970	-0.025	368.27	0.000	
3	0.955	-0.011	545.38	0.000	
4	0.941	0.005	717.98	0.000	
5	0.926	-0.014	886.04	0.000	
6	0.911	-0.008	1049.6	0.000	
7	0.895	-0.016	1208.6	0.000	
8	0.880	-0.007	1363.1	0.000	
9	0.865	-0.018	1513.1	0.000	
10	0.849	-0.027	1658.3	0.000	
11	0.832	-0.030	1798.7	0.000	
12	0.816	0.017	1934.6	0.000	
13	0.800	-0.003	2066.0	0.000	
14	0.784	-0.016	2192.9	0.000	
15	0.769	-0.010	2315.5	0.000	
16	0.753	0.014	2433.8	0.000	
17	0.738	0.002	2548.2	0.000	
18	0.724	0.008	2658.8	0.000	
19	0.709	0.002	2765.7	0.000	
20	0.695	-0.003	2869.0	0.000	
21	0.681	-0.010	2968.7	0.000	
22	0.668	0.007	3065.1	0.000	
23	0.654	-0.001	3158.1	0.000	
24	0.641	-0.011	3248.0	0.000	
25	0.627	-0.029	3334.4	0.000	
26	0.613	-0.014	3417.6	0.000	
27	0.598	-0.009	3497.4	0.000	
28	0.584	-0.007	3573.9	0.000	
29	0.570	-0.011	3647.3	0.000	
30	0.556	-0.006	3717.5	0.000	
31	0.542	-0.004	3784.7	0.000	
32	0.528	-0.012	3848.9	0.000	
33	0.514	-0.007	3910.1	0.000	
34	0.500	-0.011	3968.4	0.000	
35	0.486	-0.011	4023.8	0.000	
36	0.472	-0.013	4076.3	0.000	

Correlogram of D(HN)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.344	0.344	22.558	0.000	
2	-0.009	-0.144	22.574	0.000	
3	0.093	0.169	24.237	0.000	
4	0.287	0.224	40.239	0.000	
5	0.089	-0.103	41.769	0.000	
6	0.039	0.102	42.072	0.000	
7	0.113	0.045	44.572	0.000	
8	0.197	0.094	52.306	0.000	
9	0.065	-0.025	53.160	0.000	
10	-0.164	-0.230	58.527	0.000	
11	-0.135	-0.052	62.207	0.000	
12	-0.001	-0.042	62.207	0.000	
13	-0.084	-0.127	63.632	0.000	
14	-0.245	-0.127	75.923	0.000	
15	-0.113	0.025	78.577	0.000	
16	-0.013	-0.019	78.613	0.000	
17	-0.123	-0.054	81.792	0.000	
18	-0.179	0.044	88.540	0.000	
19	-0.133	-0.049	92.296	0.000	
20	-0.053	0.026	92.895	0.000	
21	-0.124	-0.078	96.197	0.000	
22	-0.147	-0.015	100.83	0.000	
23	0.056	0.201	101.50	0.000	
24	0.110	-0.039	104.15	0.000	
25	-0.097	-0.113	106.22	0.000	
26	-0.191	-0.075	114.26	0.000	
27	0.023	0.029	114.38	0.000	
28	0.075	-0.037	115.63	0.000	
29	0.034	0.070	115.90	0.000	
30	-0.027	-0.041	116.07	0.000	
31	0.048	-0.039	116.60	0.000	
32	0.106	0.056	119.18	0.000	
33	-0.060	-0.171	120.02	0.000	
34	-0.116	0.055	123.12	0.000	
35	0.109	0.127	125.88	0.000	
36	0.290	0.120	145.71	0.000	

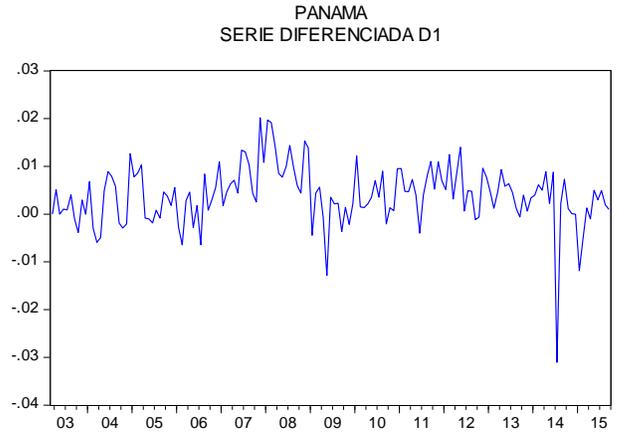
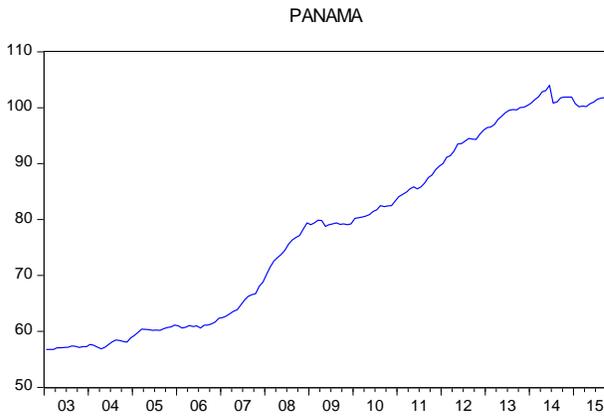
Gráficos y correlogramas del IPC alimentos de Nicaragua



Correlogram of NI					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.986	0.986	175.13	0.000	
2	0.972	-0.033	346.15	0.000	
3	0.957	-0.019	513.00	0.000	
4	0.942	-0.032	675.45	0.000	
5	0.926	-0.022	833.40	0.000	
6	0.910	-0.017	986.80	0.000	
7	0.894	-0.015	1135.6	0.000	
8	0.877	-0.025	1279.7	0.000	
9	0.859	-0.027	1419.1	0.000	
10	0.842	-0.015	1553.6	0.000	
11	0.824	-0.011	1683.3	0.000	
12	0.808	0.033	1808.6	0.000	
13	0.791	-0.016	1929.5	0.000	
14	0.774	-0.030	2045.9	0.000	
15	0.757	-0.013	2157.9	0.000	
16	0.740	-0.001	2265.5	0.000	
17	0.723	0.028	2369.2	0.000	
18	0.708	0.004	2469.0	0.000	
19	0.692	-0.011	2565.1	0.000	
20	0.676	-0.028	2657.3	0.000	
21	0.660	-0.013	2745.7	0.000	
22	0.644	0.005	2830.5	0.000	
23	0.628	-0.002	2911.7	0.000	
24	0.613	-0.008	2989.4	0.000	
25	0.597	-0.029	3063.7	0.000	
26	0.581	-0.021	3134.4	0.000	
27	0.564	-0.012	3201.7	0.000	
28	0.547	-0.029	3265.4	0.000	
29	0.530	-0.006	3325.6	0.000	
30	0.514	0.006	3382.5	0.000	
31	0.498	-0.016	3436.3	0.000	
32	0.481	-0.025	3486.8	0.000	
33	0.464	-0.013	3534.1	0.000	
34	0.447	0.023	3578.4	0.000	
35	0.432	0.020	3620.1	0.000	
36	0.417	0.002	3659.2	0.000	

Correlogram of D(NI)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.382	0.382	26.159	0.000	
2	-0.003	-0.175	26.160	0.000	
3	0.020	0.107	26.235	0.000	
4	0.096	0.055	27.909	0.000	
5	0.191	0.160	34.622	0.000	
6	0.103	-0.033	36.580	0.000	
7	0.031	0.037	36.762	0.000	
8	-0.061	-0.113	37.462	0.000	
9	-0.052	0.003	37.966	0.000	
10	-0.028	-0.067	38.110	0.000	
11	-0.014	0.011	38.148	0.000	
12	0.016	0.015	38.198	0.000	
13	0.047	0.079	38.630	0.000	
14	-0.059	-0.114	39.313	0.000	
15	-0.151	-0.067	43.765	0.000	
16	-0.080	-0.011	45.011	0.000	
17	0.010	0.021	45.030	0.000	
18	0.008	-0.034	45.042	0.000	
19	-0.065	-0.031	45.894	0.001	
20	-0.145	-0.088	50.101	0.000	
21	-0.067	0.061	51.007	0.000	
22	-0.024	-0.057	51.125	0.000	
23	0.045	0.097	51.536	0.001	
24	0.027	-0.034	51.686	0.001	
25	-0.037	0.017	51.971	0.001	
26	0.009	0.019	51.988	0.002	
27	-0.076	-0.108	53.210	0.002	
28	-0.066	-0.014	54.121	0.002	
29	-0.060	-0.082	54.879	0.003	
30	-0.013	0.022	54.916	0.004	
31	-0.023	-0.051	55.028	0.005	
32	-0.069	0.012	56.059	0.005	
33	-0.048	-0.002	56.559	0.007	
34	0.007	0.049	56.569	0.009	
35	0.108	0.081	59.182	0.007	
36	0.191	0.159	67.346	0.001	

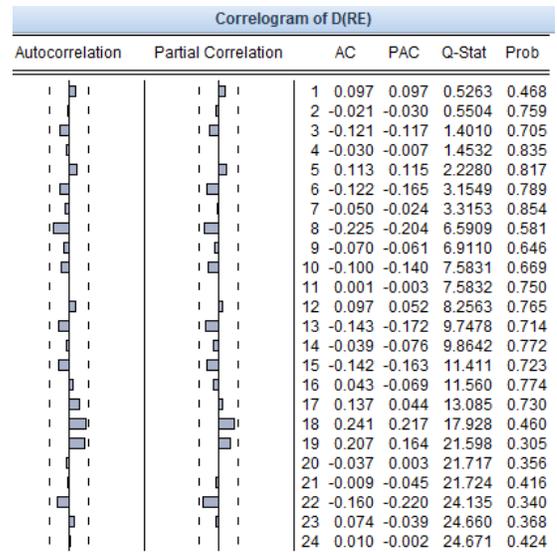
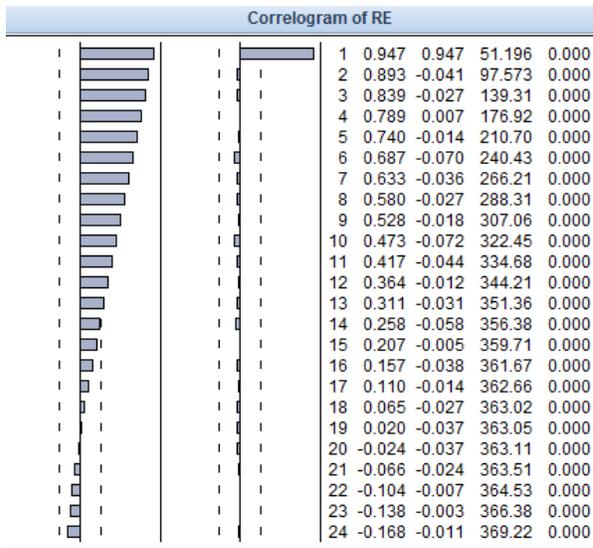
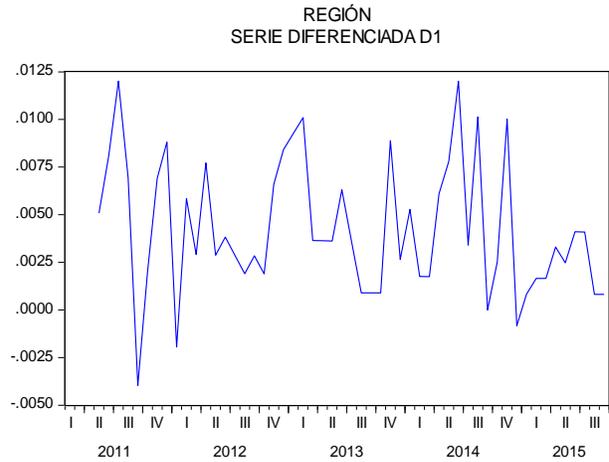
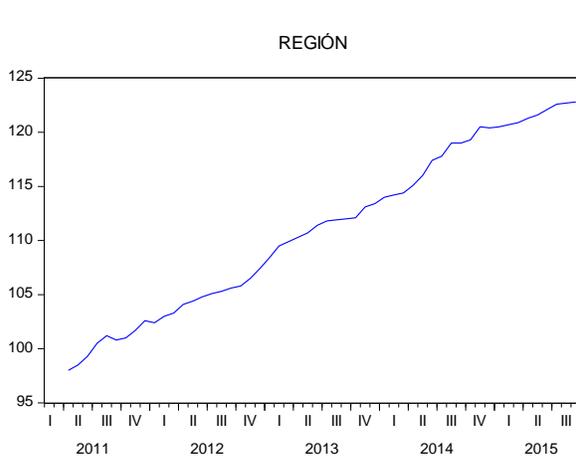
Gráficos y correlogramas del IPC alimentos de Panamá



Correlogram of PA					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.987	0.987	151.89	0.000	
2	0.973	-0.026	300.54	0.000	
3	0.959	-0.020	445.85	0.000	
4	0.944	-0.008	587.84	0.000	
5	0.930	-0.019	726.42	0.000	
6	0.915	-0.011	861.59	0.000	
7	0.900	-0.031	993.20	0.000	
8	0.885	-0.021	1121.1	0.000	
9	0.868	-0.039	1245.2	0.000	
10	0.850	-0.055	1365.2	0.000	
11	0.832	-0.017	1480.9	0.000	
12	0.814	-0.024	1592.3	0.000	
13	0.796	-0.012	1699.5	0.000	
14	0.777	-0.010	1802.6	0.000	
15	0.758	-0.024	1901.3	0.000	
16	0.737	-0.098	1995.3	0.000	
17	0.716	0.005	2084.7	0.000	
18	0.695	-0.006	2169.6	0.000	
19	0.675	0.010	2250.1	0.000	
20	0.655	-0.001	2326.5	0.000	
21	0.634	-0.009	2398.8	0.000	
22	0.614	-0.014	2467.1	0.000	
23	0.594	-0.017	2531.5	0.000	
24	0.574	-0.002	2591.9	0.000	
25	0.554	0.002	2648.7	0.000	
26	0.533	-0.018	2701.8	0.000	
27	0.513	-0.005	2751.4	0.000	
28	0.493	-0.017	2797.6	0.000	
29	0.473	-0.016	2840.5	0.000	
30	0.453	-0.011	2880.1	0.000	
31	0.434	0.004	2916.7	0.000	
32	0.414	-0.018	2950.3	0.000	
33	0.394	-0.015	2981.0	0.000	
34	0.375	-0.012	3009.0	0.000	
35	0.356	-0.007	3034.4	0.000	
36	0.337	0.001	3057.4	0.000	

Correlogram of D(PA)					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.240	0.240	8.9050	0.003	
2	0.145	0.093	12.196	0.002	
3	0.146	0.099	15.565	0.001	
4	0.160	0.103	19.618	0.001	
5	0.117	0.044	21.795	0.001	
6	0.267	0.219	33.235	0.000	
7	0.227	0.114	41.564	0.000	
8	0.158	0.044	45.599	0.000	
9	0.078	-0.034	46.591	0.000	
10	0.009	-0.101	46.605	0.000	
11	0.055	-0.003	47.115	0.000	
12	0.004	-0.097	47.118	0.000	
13	0.038	-0.029	47.363	0.000	
14	0.011	-0.053	47.385	0.000	
15	-0.036	-0.072	47.610	0.000	
16	-0.013	0.028	47.637	0.000	
17	-0.017	0.001	47.685	0.000	
18	-0.104	-0.071	49.559	0.000	
19	-0.114	-0.069	51.861	0.000	
20	-0.099	-0.050	53.602	0.000	
21	-0.062	0.025	54.286	0.000	
22	-0.070	-0.010	55.166	0.000	
23	-0.048	0.020	55.586	0.000	
24	-0.093	-0.029	57.177	0.000	
25	-0.010	0.103	57.196	0.000	
26	-0.145	-0.074	61.076	0.000	
27	-0.081	0.006	62.313	0.000	
28	0.039	0.116	62.593	0.000	
29	-0.094	-0.114	64.262	0.000	
30	-0.061	0.008	64.975	0.000	
31	-0.062	-0.064	65.711	0.000	
32	-0.170	-0.162	71.337	0.000	
33	-0.118	-0.032	74.078	0.000	
34	-0.067	-0.072	74.956	0.000	
35	-0.012	0.077	74.986	0.000	
36	0.017	0.061	75.045	0.000	

Gráficos y correlogramas del IPC alimentos de la Región



ANEXO 5: PRUEBAS DE INTEGRACIÓN DEL IPC DE ALIMENTOS

Resultados de las pruebas de integración para el IPC alimentos de Costa Rica

Null Hypothesis: CR has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.948461	0.6223
Test critical values:		
1% level	-4.044415	
5% level	-3.451568	
10% level	-3.151211	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(CR)
 Method: Least Squares
 Date: 11/09/15 Time: 19:35
 Sample (adjusted): 2006M09 2015M09
 Included observations: 109 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CR(-1)	-0.035733	0.018339	-1.948461	0.0540
D(CR(-1))	0.307282	0.091462	3.359673	0.0011
C	1.935203	0.583220	3.318136	0.0012
@TREND("2000M01")	0.009781	0.008077	1.210974	0.2286
R-squared	0.192184	Mean dependent var		0.443394
Adjusted R-squared	0.169103	S.D. dependent var		0.826342
S.E. of regression	0.753240	Akaike info criterion		2.307141
Sum squared resid	59.57387	Schwarz criterion		2.405906
Log likelihood	-121.7392	Hannan-Quinn criter.		2.347194
F-statistic	8.326687	Durbin-Watson stat		2.064298
Prob(F-statistic)	0.000051			

Null Hypothesis: D(CR) has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.003875	0.0000
Test critical values:		
1% level	-2.586350	
5% level	-1.943796	
10% level	-1.614784	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(CR,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:45
 Sample (adjusted): 2006M09 2015M09
 Included observations: 109 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CR(-1))	-0.499264	0.083157	-6.003875	0.0000
R-squared	0.250217	Mean dependent var		-0.005422
Adjusted R-squared	0.250217	S.D. dependent var		0.938046
S.E. of regression	0.812254	Akaike info criterion		2.431125
Sum squared resid	71.25373	Schwarz criterion		2.455816
Log likelihood	-131.4963	Hannan-Quinn criter.		2.441138
Durbin-Watson stat	2.201524			

Resultados de las pruebas de integración para el IPC alimentos de El Salvador

Null Hypothesis: SV has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.081956	0.1178
Test critical values:		
1% level	-4.078420	
5% level	-3.467703	
10% level	-3.160627	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(SV)
 Method: Least Squares
 Date: 11/09/15 Time: 19:46
 Sample (adjusted): 2009M03 2015M09
 Included observations: 79 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
SV(-1)	-0.141492	0.045910	-3.081956	0.0029
D(SV(-1))	0.346111	0.103628	3.339948	0.0013
C	10.49756	3.477591	3.018630	0.0035
@TREND("2000M01")	0.036379	0.012088	3.009443	0.0036
R-squared	0.200412	Mean dependent var		0.168481
Adjusted R-squared	0.168429	S.D. dependent var		0.881008
S.E. of regression	0.803396	Akaike info criterion		2.449367
Sum squared resid	48.40833	Schwarz criterion		2.569339
Log likelihood	-92.74999	Hannan-Quinn criter.		2.497431
F-statistic	6.266117	Durbin-Watson stat		1.973103
Prob(F-statistic)	0.000747			

Null Hypothesis: D(SV) has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.285016	0.0000
Test critical values:		
1% level	-2.594563	
5% level	-1.944969	
10% level	-1.614082	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(SV,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:47
 Sample (adjusted): 2009M03 2015M09
 Included observations: 79 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(SV(-1))	-0.665800	0.105934	-6.285016	0.0000
R-squared	0.336129	Mean dependent var		0.008861
Adjusted R-squared	0.336129	S.D. dependent var		1.036952
S.E. of regression	0.844890	Akaike info criterion		2.513358
Sum squared resid	55.67951	Schwarz criterion		2.543351
Log likelihood	-98.27763	Hannan-Quinn criter.		2.525374
Durbin-Watson stat	1.958454			

Resultados de las pruebas de integración para el IPC alimentos de Guatemala

Null Hypothesis: GT has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.244537	0.8905
Test critical values:		
1% level	-4.140858	
5% level	-3.496960	
10% level	-3.177579	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(GT)
 Method: Least Squares
 Date: 11/09/15 Time: 19:47
 Sample (adjusted): 2011M05 2015M09
 Included observations: 53 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
GT(-1)	-0.077829	0.062536	-1.244537	0.2191
C	-0.169978	0.988548	-0.171947	0.8642
@TREND("2000M01")	0.066418	0.049573	1.339790	0.1864
R-squared	0.043764	Mean dependent var		0.830566
Adjusted R-squared	0.005515	S.D. dependent var		0.672551
S.E. of regression	0.670694	Akaike info criterion		2.093930
Sum squared resid	22.49151	Schwarz criterion		2.205456
Log likelihood	-52.48916	Hannan-Quinn criter.		2.136818
F-statistic	1.144184	Durbin-Watson stat		1.358262
Prob(F-statistic)	0.326680			

Null Hypothesis: D(GT) has a unit root
 Exogenous: None
 Lag Length: 1 (Automatic - based on SIC, maxlag=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.631248	0.0095
Test critical values:		
1% level	-2.611094	
5% level	-1.947381	
10% level	-1.612725	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(GT,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:48
 Sample (adjusted): 2011M07 2015M09
 Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(GT(-1))	-0.265236	0.100802	-2.631248	0.0113
D(GT(-1),2)	-0.112139	0.135613	-0.826903	0.4123
R-squared	0.177457	Mean dependent var		-0.033922
Adjusted R-squared	0.160671	S.D. dependent var		0.788310
S.E. of regression	0.722209	Akaike info criterion		2.225423
Sum squared resid	25.55773	Schwarz criterion		2.301181
Log likelihood	-54.74828	Hannan-Quinn criter.		2.254372
Durbin-Watson stat	2.127511			

Resultados de las pruebas de integración para el IPC alimentos de Honduras

Null Hypothesis: HN has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 4 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.891291	0.1678
Test critical values:		
1% level	-4.008706	
5% level	-3.434433	
10% level	-3.141157	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(HN)
 Method: Least Squares
 Date: 11/09/15 Time: 19:48
 Sample (adjusted): 2000M06 2015M09
 Included observations: 184 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
HN(-1)	-0.039917	0.013806	-2.891291	0.0043
D(HN(-1))	0.383040	0.071544	5.353903	0.0000
D(HN(-2))	-0.138421	0.076843	-1.801349	0.0733
D(HN(-3))	0.082680	0.076562	1.079917	0.2816
D(HN(-4))	0.253928	0.072143	3.519794	0.0005
C	3.857357	1.237906	3.116033	0.0021
@TREND("2000M01")	0.036723	0.012515	2.934291	0.0038
R-squared	0.243073	Mean dependent var		0.846196
Adjusted R-squared	0.217415	S.D. dependent var		1.388004
S.E. of regression	1.227881	Akaike info criterion		3.285758
Sum squared resid	266.8615	Schwarz criterion		3.408066
Log likelihood	-295.2898	Hannan-Quinn criter.		3.335331
F-statistic	9.473396	Durbin-Watson stat		1.953508
Prob(F-statistic)	0.000000			

Null Hypothesis: D(HN) has a unit root
 Exogenous: None
 Lag Length: 3 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.137961	0.0018
Test critical values:		
1% level	-2.577590	
5% level	-1.942564	
10% level	-1.615553	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(HN,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:49
 Sample (adjusted): 2000M06 2015M09
 Included observations: 184 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(HN(-1))	-0.244338	0.077865	-3.137961	0.0020
D(HN(-1),2)	-0.306729	0.087222	-3.516646	0.0006
D(HN(-2),2)	-0.417369	0.075940	-5.496067	0.0000
D(HN(-3),2)	-0.293952	0.071078	-4.135606	0.0001
R-squared	0.358376	Mean dependent var		-0.003261
Adjusted R-squared	0.347682	S.D. dependent var		1.585195
S.E. of regression	1.280301	Akaike info criterion		3.353567
Sum squared resid	295.0509	Schwarz criterion		3.423457
Log likelihood	-304.5282	Hannan-Quinn criter.		3.381895
Durbin-Watson stat	1.963085			

Resultados de las pruebas de integración para el IPC alimentos de Nicaragua

Null Hypothesis: NI has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 1 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.717249	0.2310
Test critical values:		
1% level	-4.011352	
5% level	-3.435708	
10% level	-3.141907	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(NI)

Method: Least Squares

Date: 11/09/15 Time: 19:49

Sample (adjusted): 2001M03 2015M09

Included observations: 175 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
NI(-1)	-0.038488	0.014164	-2.717249	0.0073
D(NI(-1))	0.378961	0.069556	5.448242	0.0000
C	1.404355	0.497695	2.821715	0.0053
@TREND("2000M01")	0.042426	0.014900	2.847317	0.0049
R-squared	0.186123	Mean dependent var		0.914286
Adjusted R-squared	0.171845	S.D. dependent var		1.897463
S.E. of regression	1.726749	Akaike info criterion		3.952950
Sum squared resid	509.8645	Schwarz criterion		4.025288
Log likelihood	-341.8832	Hannan-Quinn criter.		3.982293
F-statistic	13.03516	Durbin-Watson stat		1.872774
Prob(F-statistic)	0.000000			

Null Hypothesis: D(NI) has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.619822	0.0000
Test critical values:		
1% level	-2.578243	
5% level	-1.942655	
10% level	-1.615495	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(NI,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:49
 Sample (adjusted): 2001M03 2015M09
 Included observations: 175 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(NI(-1))	-0.500268	0.065653	-7.619822	0.0000
R-squared	0.250198	Mean dependent var		-0.002686
Adjusted R-squared	0.250198	S.D. dependent var		2.107952
S.E. of regression	1.825299	Akaike info criterion		4.047063
Sum squared resid	579.7188	Schwarz criterion		4.065147
Log likelihood	-353.1180	Hannan-Quinn criter.		4.054398
Durbin-Watson stat	1.918707			

Resultados de las pruebas de integración para el IPC alimentos de Panamá

Null Hypothesis: PA has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.971116	0.6119
Test critical values:		
1% level	-4.019975	
5% level	-3.439857	
10% level	-3.144346	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(PA)
 Method: Least Squares
 Date: 11/09/15 Time: 19:50
 Sample (adjusted): 2003M03 2015M09
 Included observations: 151 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
PA(-1)	-0.028835	0.014629	-1.971116	0.0506
D(PA(-1))	0.240852	0.079110	3.044526	0.0028
C	1.234133	0.549083	2.247627	0.0261
@TREND("2000M01")	0.010962	0.005406	2.027636	0.0444
R-squared	0.083407	Mean dependent var		0.298212
Adjusted R-squared	0.064701	S.D. dependent var		0.513221
S.E. of regression	0.496341	Akaike info criterion		1.463025
Sum squared resid	36.21405	Schwarz criterion		1.542953
Log likelihood	-106.4584	Hannan-Quinn criter.		1.495495
F-statistic	4.458847	Durbin-Watson stat		2.047473
Prob(F-statistic)	0.004983			

Null Hypothesis: D(PA) has a unit root
 Exogenous: None
 Lag Length: 5 (Automatic - based on SIC, maxlag=13)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.975626	0.0464
Test critical values: 1% level	-2.580897	
5% level	-1.943027	
10% level	-1.615260	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(PA,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:50
 Sample (adjusted): 2003M08 2015M09
 Included observations: 146 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(PA(-1))	-0.196386	0.099404	-1.975626	0.0502
D(PA(-1),2)	-0.579093	0.113967	-5.081219	0.0000
D(PA(-2),2)	-0.504638	0.116859	-4.318343	0.0000
D(PA(-3),2)	-0.413037	0.113070	-3.652936	0.0004
D(PA(-4),2)	-0.296045	0.102067	-2.900500	0.0043
D(PA(-5),2)	-0.262183	0.081949	-3.199341	0.0017
R-squared	0.409570	Mean dependent var		0.000342
Adjusted R-squared	0.388483	S.D. dependent var		0.642818
S.E. of regression	0.502680	Akaike info criterion		1.502503
Sum squared resid	35.37624	Schwarz criterion		1.625117
Log likelihood	-103.6827	Hannan-Quinn criter.		1.552324
Durbin-Watson stat	2.073668			

Resultados de las pruebas de integración para el IPC alimentos de la Región

Null Hypothesis: RE has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.001539	0.5870
Test critical values:		
1% level	-4.140858	
5% level	-3.496960	
10% level	-3.177579	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(RE)
 Method: Least Squares
 Date: 11/09/15 Time: 19:51
 Sample (adjusted): 2011M05 2015M09
 Included observations: 53 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RE(-1)	-0.179461	0.089662	-2.001539	0.0508
C	6.660192	2.908413	2.289975	0.0263
@TREND("2000M01")	0.084579	0.043859	1.928440	0.0595
R-squared	0.086905	Mean dependent var		0.467925
Adjusted R-squared	0.050381	S.D. dependent var		0.387682
S.E. of regression	0.377790	Akaike info criterion		0.945983
Sum squared resid	7.136269	Schwarz criterion		1.057509
Log likelihood	-22.06854	Hannan-Quinn criter.		0.988870
F-statistic	2.379404	Durbin-Watson stat		1.645539
Prob(F-statistic)	0.103015			

Null Hypothesis: D(RE) has a unit root
 Exogenous: None
 Lag Length: 1 (Automatic - based on SIC, maxlag=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.355683	0.0192
Test critical values: 1% level	-2.611094	
5% level	-1.947381	
10% level	-1.612725	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(RE,2)
 Method: Least Squares
 Date: 11/09/15 Time: 19:51
 Sample (adjusted): 2011M07 2015M09
 Included observations: 51 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(RE(-1))	-0.268487	0.113974	-2.355683	0.0225
D(RE(-1),2)	-0.307975	0.133429	-2.308157	0.0253
R-squared	0.276192	Mean dependent var		-0.013725
Adjusted R-squared	0.261421	S.D. dependent var		0.526885
S.E. of regression	0.452808	Akaike info criterion		1.291731
Sum squared resid	10.04674	Schwarz criterion		1.367489
Log likelihood	-30.93913	Hannan-Quinn criter.		1.320680
Durbin-Watson stat	2.114042			

ANEXO 6: RESULTADOS MODELOS DEL IPC DE ALIMENTOS

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de Costa Rica

MODEL FINALLY CHOSEN :

(1,1,0)(1,0,0) WITH MEAN

OUTLIERS

31 TC (1 2009)

65 AO (11 2011)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
PHI1	-0.49455	0.83388E-01	-5.93	1
BPHI	-0.26869	0.92414E-01	-2.91	12

ESTIMATES OF REGRESSION PARAMETERS CONCENTRATED OUT OF THE LIKELIHOOD

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
MU	0.61684E-02	0.00220	2.80	
OUT 1 (31)	0.12558E-01	(0.00675)	1.86	TC (1 2009)
OUT 2 (65)	-0.13893E-01	(0.00464)	-3.00	AO (11 2011)

RESIDUALS STATISTICS

MEAN	-0.0005358
ST.DEV.OF MEAN	0.0008559
T-VALUE	-0.6259932
NORMALITY TEST (CHI-SQUARE(2))	0.2727
SKEWNESS	-0.1229(SE = 0.2368)
KURTOSIS	3.0276(SE = 0.4736)
SUM OF SQUARES	0.8417405E-02
DURBIN-WATSON	2.0636
STANDARD ERROR OF RESIDUALS	0.8953534E-02
MSE OF RESID.	0.8016576E-04

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0323	0.0070	-0.0182	0.0121	0.1431	-0.0057	0.0138	0.0469	-0.0316	0.0520	0.0064	-0.0500
SE	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967
Q	0.11	0.12	0.16	0.17	2.51	2.52	2.54	2.80	2.92	3.24	3.25	3.56
PV	-1.00	-1.00	0.69	0.92	0.47	0.64	0.77	0.83	0.89	0.92	0.95	0.97

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0248	-0.0888	-0.0992	0.0622	0.0019	-0.0340	0.0599	-0.1078	-0.0505	-0.0743	0.0733	0.1013
SE	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967
Q	3.63	4.62	5.87	6.37	6.37	6.52	7.00	8.55	8.90	9.66	10.40	11.84
PV	0.98	0.97	0.95	0.96	0.97	0.98	0.98	0.97	0.98	0.97	0.97	0.96

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0098	0.1571	-0.0110	-0.0290	-0.0407	0.0478	-0.0755	0.1929	-0.0677	-0.1491	0.0598	0.1799
SE	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967
Q	11.86	15.41	15.43	15.55	15.80	16.15	17.02	22.81	23.53	27.08	27.66	32.98
PV	0.97	0.91	0.93	0.95	0.96	0.96	0.96	0.82	0.83	0.71	0.73	0.52

LJUNG-BOX Q VALUE OF ORDER 24 IS 11.84 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(22),p-value= 0.9605

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1332	-0.0298	-0.0489	-0.0438	-0.1127	0.0093	-0.0605	-0.0483	-0.0046	-0.0516	-0.0068	0.0013
SE	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967
Q	1.95	2.05	2.32	2.54	3.99	4.00	4.43	4.70	4.70	5.02	5.03	5.03
PV	-1.00	-1.00	0.13	0.28	0.26	0.41	0.49	0.58	0.70	0.76	0.83	0.89

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0483	0.1844	0.0243	0.0075	-0.0329	-0.0145	-0.0955	-0.1147	-0.0506	0.0214	-0.0156	-0.0678
SE	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967
Q	5.32	9.58	9.66	9.67	9.81	9.83	11.04	12.81	13.15	13.22	13.25	13.90
PV	0.91	0.65	0.72	0.79	0.83	0.88	0.85	0.80	0.83	0.87	0.90	0.91

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.1772	0.0815	-0.1033	-0.0335	-0.1159	-0.1816	-0.0465	0.1583	-0.0779	0.0609	0.1052	0.1140
SE	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967	0.0967
Q	18.37	19.32	20.88	21.04	23.05	28.05	28.38	32.28	33.24	33.83	35.62	37.76
PV	0.74	0.73	0.70	0.74	0.68	0.46	0.50	0.35	0.36	0.38	0.35	0.30

MCLEOD-LI Q VALUE OF ORDER 24 IS 13.90 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.9489

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	YES

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de El Salvador

MODEL FINALLY CHOSEN :

(0,1,1)(0,0,0) WITHOUT MEAN

OUTLIERS

18 AO (6 2010)

28 AO (4 2011)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	0.39166	0.10287	3.81	1

ESTIMATES OF REGRESSION PARAMETERS CONCENTRATED OUT OF THE LIKELIHOOD

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (18)	0.89666E-02	(0.00404)	2.22	AO (6 2010)
OUT 2 (28)	0.91480E-02	(0.00404)	2.26	AO (4 2011)

RESIDUALS STATISTICS

MEAN	0.0011525
ST.DEV.OF MEAN	0.0008144
T-VALUE	1.4151172
NORMALITY TEST (CHI-SQUARE(2))	1.876
SKEWNESS	0.3747(SE = 0.2774)
KURTOSIS	2.8756(SE = 0.5547)
SUM OF SQUARES	0.4139143E-02
DURBIN-WATSON	1.9473
STANDARD ERROR OF RESIDUALS	0.7331787E-02
MSE OF RESID.	0.5375510E-04

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0147	0.0230	0.0125	0.1022	-0.0369	-0.0006	0.0619	0.1001	0.1085	0.0003	-0.1815	0.0585
SE	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132
Q	0.02	0.06	0.07	0.95	1.07	1.07	1.41	2.30	3.36	3.36	6.43	6.76
PV	-1.00	0.81	0.96	0.81	0.90	0.96	0.97	0.94	0.91	0.95	0.78	0.82

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0198	-0.0332	-0.1179	0.0731	0.0085	-0.1194	0.0430	-0.0121	-0.0184	0.0155	-0.0568	-0.0364
SE	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132
Q	6.79	6.90	8.28	8.81	8.82	10.30	10.50	10.51	10.55	10.58	10.94	11.10
PV	0.87	0.91	0.87	0.89	0.92	0.89	0.91	0.94	0.96	0.97	0.98	0.98

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0265	0.0462	0.0679	0.1192	-0.0110	-0.0215	-0.0321	0.0472	0.0372	-0.1381	-0.0061	0.1595
SE	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132
Q	11.18	11.44	12.00	13.77	13.79	13.85	13.99	14.29	14.48	17.19	17.19	20.97
PV	0.99	0.99	0.99	0.98	0.99	0.99	0.99	1.00	1.00	0.99	0.99	0.97

LJUNG-BOX Q VALUE OF ORDER 24 IS 11.10 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(23). p-value= 0.9822

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1085	0.1493	0.1828	0.1189	0.1306	0.2022	0.1452	-0.0618	0.1411	-0.0562	-0.0534	0.1117
SE	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132
Q	0.95	2.78	5.56	6.76	8.21	11.76	13.61	13.95	15.75	16.04	16.31	17.48
PV	-1.00	0.10	0.06	0.08	0.08	0.04	0.03	0.05	0.05	0.07	0.09	0.09

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.1148	0.0442	0.0314	0.0036	-0.0490	0.1045	0.0015	-0.0142	-0.0623	-0.0294	-0.0610	-0.0605
SE	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132
Q	18.75	18.94	19.04	19.04	19.28	20.42	20.42	20.44	20.87	20.96	21.38	21.81
PV	0.09	0.13	0.16	0.21	0.25	0.25	0.31	0.37	0.41	0.46	0.50	0.53

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0715	-0.0968	0.0046	-0.0682	-0.0647	-0.0268	-0.0442	-0.0406	-0.0283	-0.0006	-0.1096	-0.0134
SE	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132	0.1132
Q	22.41	23.53	23.54	24.12	24.65	24.74	25.00	25.23	25.34	25.34	27.08	27.11
PV	0.55	0.55	0.60	0.62	0.65	0.69	0.72	0.76	0.79	0.83	0.79	0.83

McLEOD-LI Q VALUE OF ORDER 24 IS 21.81 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.5908

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	-
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de Guatemala

MODEL FINALLY CHOSEN :

(0,1,1)(0,0,0) WITH MEAN

OUTLIERS

32 TC (11 2013)

4 TC (7 2011)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	0.21160	0.13425	1.58	1

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
MU	0.65809E-02	0.00074	8.84	
OUT 1 (32)	0.12883E-01	(0.00394)	3.27	TC (11 2013)
OUT 2 (4)	0.14201E-01	(0.00394)	3.61	TC (7 2011)

RESIDUALS STATISTICS

MEAN	-0.0002851
ST.DEV.OF MEAN	0.0006269
T-VALUE	-0.4547783
NORMALITY TEST (CHI-SQUARE(2))	0.9450
SKEWNESS	0.3365(SE = 0.3464)
KURTOSIS	2.9725(SE = 0.6928)
SUM OF SQUARES	0.9864161E-03
DURBIN-WATSON	2.1514
STANDARD ERROR OF RESIDUALS	0.4486752E-02
MSE OF RESID.	0.2013094E-04

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.1434	-0.0375	-0.0355	-0.0036	-0.0720	-0.0144	-0.0546	0.0448	0.0556	-0.1784	0.0827	0.0956
SE	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414
Q	1.09	1.17	1.24	1.24	1.54	1.55	1.73	1.85	2.05	4.12	4.57	5.20
PV	-1.00	0.28	0.54	0.74	0.82	0.91	0.94	0.97	0.98	0.90	0.92	0.92

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.1340	-0.0290	-0.0959	-0.0578	0.1454	0.0400	0.0380	-0.0082	-0.0236	0.0038	0.1182	-0.0588
SE	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414
Q	6.46	6.52	7.21	7.46	9.13	9.26	9.38	9.38	9.43	9.44	10.78	11.13
PV	0.89	0.93	0.93	0.94	0.91	0.93	0.95	0.97	0.98	0.99	0.98	0.98

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0749	-0.1082	0.1427	0.0314	0.0553	-0.0655	-0.1191	-0.0578	-0.1104	-0.0030	0.0470	0.1174
SE	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414
Q	11.71	12.98	15.28	15.40	15.78	16.33	18.27	18.76	20.62	20.62	21.01	23.57
PV	0.98	0.98	0.95	0.96	0.97	0.97	0.95	0.96	0.94	0.95	0.96	0.93

LJUNG-BOX Q VALUE OF ORDER 24 IS 11.13 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(23). p-value= 0.9819

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.3865	-0.0585	-0.1218	0.1213	0.0544	-0.1657	-0.1629	0.0548	0.2193	-0.0290	-0.2088	-0.1539
SE	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414
Q	7.92	8.11	8.93	9.76	9.93	11.56	13.16	13.35	16.39	16.45	19.35	20.98
PV	-1.00	0.00	0.01	0.02	0.04	0.04	0.04	0.06	0.04	0.06	0.04	0.03

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0095	-0.1382	-0.2185	-0.2084	0.0029	0.0451	-0.0858	-0.1614	-0.0555	0.0785	-0.0209	-0.1176
SE	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414
Q	20.98	22.36	25.91	29.23	29.23	29.40	30.01	32.27	32.55	33.12	33.16	34.54
PV	0.05	0.05	0.03	0.02	0.02	0.03	0.04	0.03	0.04	0.04	0.06	0.06

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0024	0.2622	0.3327	0.0687	-0.0383	-0.0099	0.0259	-0.0166	-0.0148	0.0970	0.1340	0.1322
SE	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414	0.1414
Q	34.55	42.00	54.51	55.07	55.25	55.26	55.35	55.39	55.43	56.96	60.07	63.32
PV	0.08	0.02	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.00	0.00

McLEOD-LI Q VALUE OF ORDER 24 IS 34.54 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.0754

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	-
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de Honduras

MODEL FINALLY CHOSEN :

(0,1,1)(0,0,0) WITH MEAN

OUTLIERS

62 AO (2 2014) 24 TC (12 2010)

66 AO (6 2014) 18 LS (6 2010)

72 AO (12 2014)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	0.74135	0.75033E-01	9.88	1

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
MU	0.27584E-02	0.00103	2.67	
OUT 1 (62)	-0.58153E-02	(0.00205)	-2.84	AO (2 2014)
OUT 2 (66)	-0.80156E-02	(0.00209)	-3.84	AO (6 2014)
OUT 3 (72)	-0.78146E-02	(0.00196)	-3.99	AO (12 2014)
OUT 4 (24)	-0.13823E-01	(0.00312)	-4.43	TC (12 2010)
OUT 5 (18)	0.14503E-01	(0.00363)	4.00	LS (6 2010)

RESIDUALS STATISTICS

MEAN	0.0008492
ST.DEV.OF MEAN	0.0006073
T-VALUE	1.3982798
NORMALITY TEST (CHI-SQUARE(2))	1.529
SKEWNESS	0.3413(SE = 0.2847)
KURTOSIS	3.1731(SE = 0.5695)
SUM OF SQUARES	0.2072895E-02
DURBIN-WATSON	2.0516
STANDARD ERROR OF RESIDUALS	0.5328772E-02
MSE OF RESID.	0.2839582E-04

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0462	-0.1302	-0.0758	0.1448	0.1845	-0.1950	0.0887	0.0397	0.2331	-0.0845	-0.1542	0.0632
SE	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162
Q	0.16	1.49	1.94	3.63	6.40	9.55	10.21	10.34	15.04	15.67	17.79	18.15
PV	-1.00	0.22	0.38	0.30	0.17	0.09	0.12	0.17	0.06	0.07	0.06	0.08

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0556	-0.0580	-0.0056	0.1734	0.0520	-0.0671	-0.0406	0.0016	0.0963	0.0035	-0.0459	0.1290
SE	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162
Q	18.44	18.76	18.76	21.67	21.94	22.39	22.56	22.56	23.55	23.55	23.78	25.65
PV	0.10	0.13	0.17	0.12	0.15	0.17	0.21	0.26	0.26	0.32	0.36	0.32

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0120	0.0098	0.0137	0.0628	-0.0645	0.0370	0.0876	-0.0032	-0.0604	0.0347	0.0481	-0.0125
SE	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162
Q	25.67	25.68	25.70	26.18	26.70	26.88	27.88	27.88	28.38	28.55	28.89	28.91
PV	0.37	0.42	0.48	0.51	0.53	0.58	0.58	0.63	0.65	0.69	0.72	0.76

LJUNG-BOX Q VALUE OF ORDER 24 IS 25.65 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(23). p-value= 0.3176

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1091	0.0012	-0.0471	-0.0857	0.1293	-0.0771	-0.0052	-0.0579	0.1002	0.0994	0.1215	-0.0641
SE	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162
Q	0.92	0.92	1.09	1.68	3.05	3.54	3.54	3.82	4.69	5.56	6.88	7.25
PV	-1.00	0.34	0.58	0.64	0.55	0.62	0.74	0.80	0.79	0.78	0.74	0.78

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0186	-0.0126	-0.1481	-0.0802	-0.1187	-0.0303	-0.0250	-0.0726	-0.0337	-0.0466	-0.0038	-0.0698
SE	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162
Q	7.28	7.30	9.39	10.01	11.40	11.50	11.56	12.11	12.23	12.46	12.47	13.01
PV	0.84	0.89	0.81	0.82	0.78	0.83	0.87	0.88	0.91	0.93	0.95	0.95

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0861	-0.1017	-0.0661	0.0199	0.0332	0.0605	-0.0712	-0.0234	-0.0676	-0.0124	-0.0307	-0.0156
SE	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162	0.1162
Q	13.87	15.08	15.60	15.65	15.79	16.25	16.92	16.99	17.62	17.64	17.77	17.81
PV	0.95	0.94	0.95	0.96	0.97	0.97	0.97	0.98	0.98	0.99	0.99	0.99

McLEOD-LI Q VALUE OF ORDER 24 IS 13.01 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.9659

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	-
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : MILDLY POOR FIT QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	MILDLY POOR

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de Nicaragua

MODEL FINALLY CHOSEN :

(0,1,1)(0,0,0) WITH MEAN

NO OUTLIERS DETECTED

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	0.51125	0.96088E-01	5.32	1

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE
MU	0.43741E-02	0.00204	2.15

RESIDUALS STATISTICS

MEAN	0.0019370
ST.DEV.OF MEAN	0.0013351
T-VALUE	1.4508341
NORMALITY TEST (CHI-SQUARE(2))	0.5642
SKEWNESS	0.0585(SE = 0.2756)
KURTOSIS	3.3972(SE = 0.5512)
SUM OF SQUARES	0.1142132E-01
DURBIN-WATSON	2.0777
STANDARD ERROR OF RESIDUALS	0.1210071E-01
MSE OF RESID.	0.1464272E-03

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0416	-0.0718	0.0401	0.0137	0.1494	-0.0839	0.0606	-0.0239	0.0108	0.0372	-0.0151	0.0028
SE	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125
Q	0.14	0.57	0.71	0.72	2.65	3.27	3.60	3.65	3.66	3.79	3.81	3.81
PV	-1.00	0.45	0.70	0.87	0.62	0.66	0.73	0.82	0.89	0.92	0.96	0.98

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.2218	0.0384	-0.0941	0.0082	0.1144	0.0301	0.0499	-0.0943	0.1172	-0.0098	-0.0056	0.1026
SE	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125
Q	8.58	8.73	9.61	9.62	10.97	11.06	11.33	12.29	13.81	13.82	13.82	15.05
PV	0.74	0.79	0.79	0.84	0.81	0.85	0.88	0.87	0.84	0.88	0.91	0.89

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0284	0.1734	-0.0742	-0.0276	-0.1283	0.0675	0.0746	-0.1207	0.0765	0.0520	0.0574	0.0183
SE	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125
Q	15.14	18.77	19.45	19.55	21.65	22.25	22.99	24.97	25.79	26.17	26.65	26.70
PV	0.92	0.81	0.82	0.85	0.80	0.81	0.82	0.77	0.77	0.79	0.81	0.84

LJUNG-BOX Q VALUE OF ORDER 24 IS 15.05 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(23). p-value= 0.8929

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.2083	0.2478	0.0007	-0.1713	-0.0426	-0.0242	-0.0792	-0.0261	-0.0696	-0.1136	-0.1131	-0.0781
SE	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125
Q	3.56	8.66	8.66	11.16	11.32	11.37	11.93	11.99	12.43	13.63	14.83	15.42
PV	-1.00	0.00	0.01	0.01	0.02	0.04	0.06	0.10	0.13	0.14	0.14	0.16

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0660	-0.0347	0.0419	0.0445	-0.0956	0.0740	0.0170	-0.0242	0.0627	-0.0381	-0.0627	0.0016
SE	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125
Q	15.84	15.96	16.13	16.33	17.28	17.85	17.88	17.95	18.38	18.54	18.99	18.99
PV	0.20	0.25	0.31	0.36	0.37	0.40	0.46	0.53	0.56	0.61	0.65	0.70

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0678	0.0361	0.0871	0.0127	-0.0151	-0.0109	0.0074	-0.1090	-0.0094	0.0107	-0.0187	0.0310
SE	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125	0.1125
Q	19.54	19.70	20.63	20.65	20.68	20.69	20.70	22.32	22.33	22.35	22.40	22.54
PV	0.72	0.76	0.76	0.80	0.84	0.87	0.90	0.87	0.90	0.92	0.94	0.95

McLEOD-LI Q VALUE OF ORDER 24 IS 18.99 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.7523

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	-
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de Panamá

MODEL FINALLY CHOSEN :

(1,1,0)(0,0,0) WITH MEAN

OUTLIERS

139 LS (7 2014)

59 AO (11 2007)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
PHI1	-0.44670	0.72568E-01	-6.16	1

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
MU	0.40425E-02	0.00073	5.56	
OUT 1 (139)	-0.36259E-01	(0.00455)	-7.97	LS (7 2014)
OUT 2 (59)	0.70432E-02	(0.00275)	2.57	AO (11 2007)

RESIDUALS STATISTICS

MEAN	0.0002929
ST.DEV.OF MEAN	0.0004060
T-VALUE	0.7215136
NORMALITY TEST (CHI-SQUARE(2))	0.8909
SKEWNESS	-0.1459(SE = 0.2007)
KURTOSIS	3.2416(SE = 0.4013)
SUM OF SQUARES	0.3671812E-02
DURBIN-WATSON	2.0253
STANDARD ERROR OF RESIDUALS	0.4980918E-02
MSE OF RESID.	0.2480954E-04

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0155	0.0051	0.0567	0.0986	0.0249	0.1318	0.1753	0.0824	0.0382	-0.0822	0.0540	0.0196
SE	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819
Q	0.04	0.04	0.54	2.05	2.14	4.88	9.74	10.83	11.06	12.15	12.63	12.69
PV	-1.00	0.84	0.76	0.56	0.71	0.43	0.14	0.15	0.20	0.20	0.25	0.31

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0135	-0.0126	0.0095	0.0480	-0.1018	-0.0328	-0.1226	0.0525	-0.0742	-0.1070	0.0183	-0.0749
SE	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819
Q	12.72	12.75	12.77	13.15	14.92	15.11	17.71	18.19	19.16	21.19	21.25	22.26
PV	0.39	0.47	0.55	0.59	0.53	0.59	0.47	0.51	0.51	0.45	0.51	0.50

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0238	-0.1124	-0.0188	0.0930	-0.0473	-0.0429	0.0350	-0.1056	-0.1451	0.0546	0.0274	0.1073
SE	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819
Q	22.36	24.67	24.73	26.34	26.76	27.11	27.34	29.49	33.57	34.15	34.30	36.59
PV	0.56	0.48	0.53	0.50	0.53	0.57	0.61	0.54	0.39	0.41	0.45	0.39

LJUNG-BOX Q VALUE OF ORDER 24 IS 22.26 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(23). p-value= 0.5048

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0916	-0.0404	-0.0806	0.0948	-0.0195	0.1382	-0.0074	-0.0568	-0.0830	0.0204	0.0822	0.0441
SE	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819
Q	1.27	1.52	2.53	3.92	3.98	6.98	6.99	7.51	8.61	8.68	9.78	10.10
PV	-1.00	0.22	0.28	0.27	0.41	0.22	0.32	0.38	0.38	0.47	0.46	0.52

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0084	-0.0069	-0.0215	0.0754	0.2242	0.0027	0.0798	-0.0765	-0.0892	-0.0325	0.0745	-0.0247
SE	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819
Q	10.11	10.12	10.20	11.16	19.72	19.73	20.83	21.85	23.25	23.43	24.42	24.53
PV	0.61	0.68	0.75	0.74	0.23	0.29	0.29	0.29	0.28	0.32	0.33	0.37

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0038	-0.0166	-0.0834	-0.0303	0.0175	0.0222	-0.0335	0.0189	0.1059	0.0865	-0.0023	0.0915
SE	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819	0.0819
Q	24.54	24.59	25.87	26.04	26.10	26.19	26.41	26.47	28.65	30.11	30.11	31.78
PV	0.43	0.49	0.47	0.52	0.57	0.62	0.65	0.70	0.64	0.61	0.66	0.62

McLEOD-LI Q VALUE OF ORDER 24 IS 24.53 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24)

p-value= 0.4314

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	-
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IPC de alimentos de la Región

MODEL FINALLY CHOSEN :

(0,1,1)(0,0,0) WITH MEAN

NO OUTLIERS DETECTED

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	0.15436	0.13571	1.14	1

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE
MU	0.42409E-02	0.00056	7.58

RESIDUALS STATISTICS

MEAN	-0.0000564
ST.DEV.OF MEAN	0.0004861
T-VALUE	-0.1161071
NORMALITY TEST (CHI-SQUARE(2))	0.5075
SKEWNESS	0.1798(SE = 0.3397)
KURTOSIS	2.6761(SE = 0.6794)
SUM OF SQUARES	0.6389864E-03
DURBIN-WATSON	1.9590
STANDARD ERROR OF RESIDUALS	0.3539653E-02
MSE OF RESID.	0.1252915E-04

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0007	-0.0251	-0.1252	0.0149	0.1343	-0.1464	-0.0147	-0.1876	-0.0031	-0.0800	-0.0178	0.0988
SE	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387
Q	0.00	0.04	0.93	0.95	2.02	3.33	3.35	5.59	5.59	6.02	6.04	6.73
PV	-1.00	0.85	0.63	0.81	0.73	0.65	0.76	0.59	0.69	0.74	0.81	0.82

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.1298	-0.0210	-0.1245	0.0303	0.1390	0.1917	0.1992	-0.0652	0.0308	-0.1493	0.0851	-0.0117
SE	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387
Q	7.94	7.97	9.15	9.22	10.77	13.81	17.18	17.55	17.64	19.73	20.43	20.44
PV	0.79	0.85	0.82	0.87	0.82	0.68	0.51	0.55	0.61	0.54	0.56	0.62

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0754	-0.0840	-0.1136	0.0584	-0.0444	0.1220	-0.0970	-0.0943	-0.0569	-0.0251	0.1386	0.1393
SE	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387
Q	21.04	21.80	23.25	23.65	23.89	25.79	27.05	28.29	28.77	28.87	32.04	35.45
PV	0.64	0.65	0.62	0.65	0.69	0.64	0.62	0.61	0.63	0.67	0.56	0.45

LJUNG-BOX Q VALUE OF ORDER 24 IS 20.44 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(23). p-value= 0.6150

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0041	0.2479	0.1168	0.0838	-0.0812	0.1008	-0.0678	-0.1813	-0.0541	-0.0900	-0.1410	-0.0484
SE	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387
Q	0.00	3.45	4.24	4.65	5.04	5.66	5.95	8.05	8.24	8.78	10.14	10.30
PV	-1.00	0.06	0.12	0.20	0.28	0.34	0.43	0.33	0.41	0.46	0.43	0.50

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0591	-0.1279	-0.0873	0.0519	0.0316	-0.0129	0.0353	-0.0938	-0.0811	-0.0049	-0.0212	-0.1013
SE	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387
Q	10.56	11.77	12.34	12.55	12.63	12.65	12.75	13.53	14.12	14.13	14.17	15.20
PV	0.57	0.55	0.58	0.64	0.70	0.76	0.81	0.81	0.82	0.86	0.90	0.89

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0639	-0.0276	-0.1401	-0.0377	0.0370	-0.1229	0.0034	0.0166	0.1451	0.0067	0.3481	0.0670
SE	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387	0.1387
Q	15.62	15.70	17.91	18.07	18.24	20.17	20.17	20.21	23.32	23.33	43.34	44.13
PV	0.90	0.92	0.88	0.90	0.92	0.89	0.91	0.93	0.87	0.89	0.13	0.14

McLEOD-LI Q VALUE OF ORDER 24 IS 15.20 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.9149

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	-
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

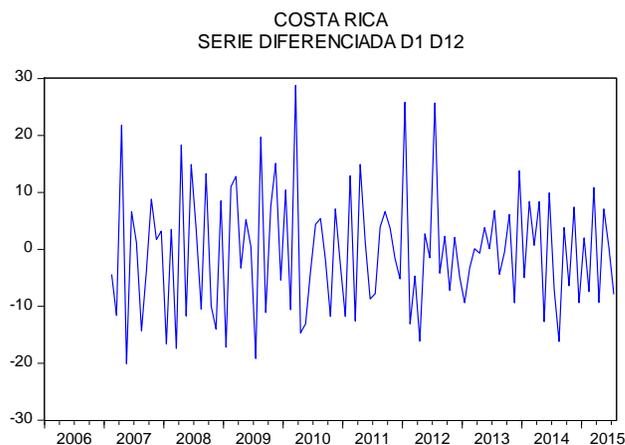
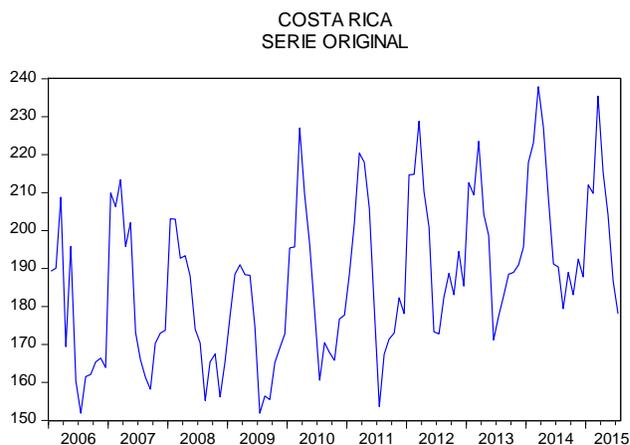
ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

ANEXO 7: ANÁLISIS PREVIO DE LA PRODUCCIÓN AGROPECUARIA

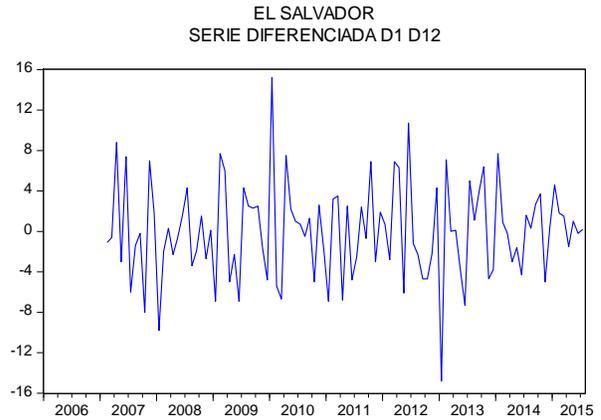
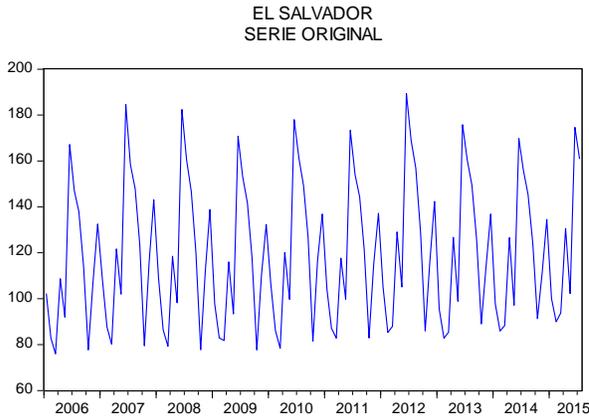
Gráficos y correlogramas del IMAE agropecuario de Costa Rica



Correlogram of CR						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.735	0.735	63.746	0.000
		2	0.506	-0.074	94.267	0.000
		3	0.135	-0.461	96.446	0.000
		4	-0.112	-0.062	97.978	0.000
		5	-0.280	0.042	107.58	0.000
		6	-0.337	-0.065	121.63	0.000
		7	-0.317	-0.057	134.19	0.000
		8	-0.135	0.297	136.47	0.000
		9	0.067	0.157	137.03	0.000
		10	0.392	0.361	156.76	0.000
		11	0.613	0.281	205.40	0.000
		12	0.759	0.220	280.69	0.000
		13	0.588	-0.379	326.32	0.000
		14	0.378	-0.061	345.39	0.000
		15	0.073	0.110	346.10	0.000
		16	-0.135	-0.013	348.59	0.000
		17	-0.268	0.072	358.48	0.000
		18	-0.323	0.021	372.91	0.000
		19	-0.306	-0.111	386.05	0.000
		20	-0.158	-0.030	389.58	0.000
		21	0.014	0.014	389.60	0.000
		22	0.296	-0.001	402.32	0.000
		23	0.498	0.072	438.66	0.000
		24	0.596	0.036	491.25	0.000
		25	0.469	-0.139	524.15	0.000
		26	0.287	0.040	536.58	0.000
		27	0.014	-0.049	536.61	0.000
		28	-0.157	-0.074	540.41	0.000
		29	-0.289	0.010	553.51	0.000
		30	-0.345	-0.007	572.30	0.000
		31	-0.297	0.098	586.41	0.000
		32	-0.181	-0.016	591.72	0.000
		33	-0.009	-0.039	591.73	0.000
		34	0.247	0.017	601.84	0.000
		35	0.399	-0.069	628.66	0.000
		36	0.481	-0.011	668.05	0.000

Correlogram of DCR						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.469	-0.469	23.057	0.000
		2	0.170	-0.064	26.113	0.000
		3	-0.086	-0.041	26.911	0.000
		4	-0.123	-0.220	28.542	0.000
		5	0.066	-0.113	29.012	0.000
		6	0.005	0.007	29.015	0.000
		7	-0.120	-0.180	30.610	0.000
		8	0.139	-0.041	32.777	0.000
		9	0.017	0.123	32.810	0.000
		10	-0.016	0.032	32.838	0.000
		11	0.100	0.089	34.002	0.000
		12	-0.172	-0.045	37.493	0.000
		13	0.032	-0.072	37.612	0.000
		14	-0.084	-0.143	38.468	0.000
		15	0.064	-0.007	38.968	0.001
		16	-0.091	-0.137	39.987	0.001
		17	0.061	-0.129	40.450	0.001
		18	0.150	0.198	43.294	0.001
		19	-0.132	-0.029	45.521	0.001
		20	0.032	-0.153	45.650	0.001
		21	-0.010	0.042	45.663	0.001
		22	-0.080	0.003	46.521	0.002
		23	0.184	0.120	51.055	0.001
		24	-0.086	0.122	52.067	0.001
		25	-0.062	-0.046	52.604	0.001
		26	0.086	-0.084	53.625	0.001
		27	-0.133	-0.108	56.142	0.001
		28	0.109	-0.050	57.850	0.001
		29	0.029	0.009	57.974	0.001
		30	-0.083	0.047	58.997	0.001
		31	-0.047	-0.178	59.322	0.002
		32	0.132	0.009	61.964	0.001
		33	-0.034	0.158	62.139	0.002
		34	0.050	0.062	62.523	0.002
		35	0.003	0.117	62.525	0.003
		36	-0.102	0.028	64.181	0.003

Gráficos y correlogramas del IMAE agropecuario de El Salvador



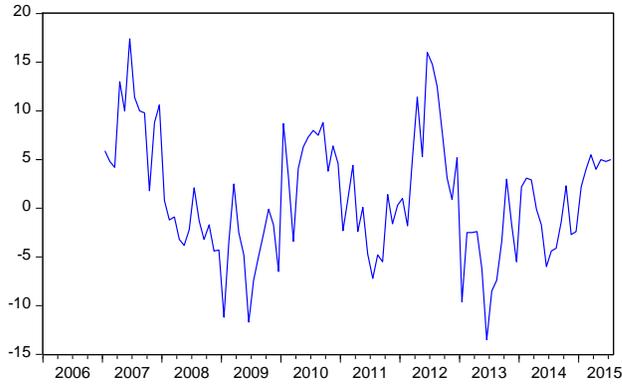
Correlogram of SV

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.348	0.348	14.301	0.000	
2	0.025	-0.109	14.376	0.001	
3	-0.270	-0.278	23.128	0.000	
4	-0.317	-0.155	35.313	0.000	
5	-0.170	-0.015	38.846	0.000	
6	-0.104	-0.133	40.170	0.000	
7	-0.141	-0.246	42.664	0.000	
8	-0.291	-0.386	53.320	0.000	
9	-0.262	-0.332	62.039	0.000	
10	0.032	-0.103	62.174	0.000	
11	0.314	-0.035	74.934	0.000	
12	0.891	0.802	178.53	0.000	
13	0.298	-0.385	190.28	0.000	
14	0.002	0.023	190.28	0.000	
15	-0.258	0.065	199.23	0.000	
16	-0.304	0.055	211.75	0.000	
17	-0.168	-0.032	215.62	0.000	
18	-0.103	-0.095	217.09	0.000	
19	-0.130	-0.059	219.47	0.000	
20	-0.268	0.031	229.61	0.000	
21	-0.242	0.013	237.97	0.000	
22	0.031	-0.158	238.11	0.000	
23	0.282	-0.010	249.77	0.000	
24	0.791	-0.041	342.30	0.000	
25	0.269	0.065	353.14	0.000	
26	0.004	0.001	353.15	0.000	
27	-0.222	0.005	360.69	0.000	
28	-0.269	0.019	371.90	0.000	
29	-0.150	0.040	375.42	0.000	
30	-0.090	0.037	376.70	0.000	
31	-0.108	0.026	378.57	0.000	
32	-0.231	0.051	387.24	0.000	
33	-0.208	0.038	394.32	0.000	
34	0.038	0.037	394.56	0.000	
35	0.250	-0.043	405.04	0.000	
36	0.682	-0.081	484.20	0.000	

Correlogram of DSV

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	-0.275	-0.275	7.9616	0.005	
2	-0.123	-0.215	9.5585	0.008	
3	0.135	0.040	11.518	0.009	
4	-0.161	-0.148	14.312	0.006	
5	0.133	0.082	16.232	0.006	
6	0.013	0.027	16.251	0.012	
7	-0.101	-0.037	17.398	0.015	
8	0.170	0.121	20.670	0.008	
9	-0.284	-0.239	29.856	0.000	
10	0.075	-0.021	30.502	0.001	
11	0.076	-0.040	31.180	0.001	
12	-0.304	-0.265	42.088	0.000	
13	0.130	-0.102	44.114	0.000	
14	-0.065	-0.157	44.618	0.000	
15	-0.016	-0.021	44.650	0.000	
16	0.166	0.050	48.054	0.000	
17	-0.154	-0.000	51.009	0.000	
18	0.077	0.032	51.756	0.000	
19	0.061	0.052	52.227	0.000	
20	-0.146	-0.044	54.985	0.000	
21	0.104	-0.132	56.395	0.000	
22	0.005	-0.031	56.399	0.000	
23	0.068	0.054	57.024	0.000	
24	-0.040	-0.149	57.245	0.000	
25	-0.032	0.021	57.385	0.000	
26	0.079	-0.010	58.247	0.000	
27	-0.046	0.005	58.549	0.000	
28	-0.162	-0.151	62.311	0.000	
29	0.180	0.034	67.020	0.000	
30	-0.122	-0.110	69.204	0.000	
31	0.096	0.103	70.568	0.000	
32	0.001	-0.013	70.568	0.000	
33	-0.104	-0.091	72.219	0.000	
34	0.079	0.025	73.182	0.000	
35	0.031	0.111	73.337	0.000	
36	-0.097	-0.101	74.858	0.000	

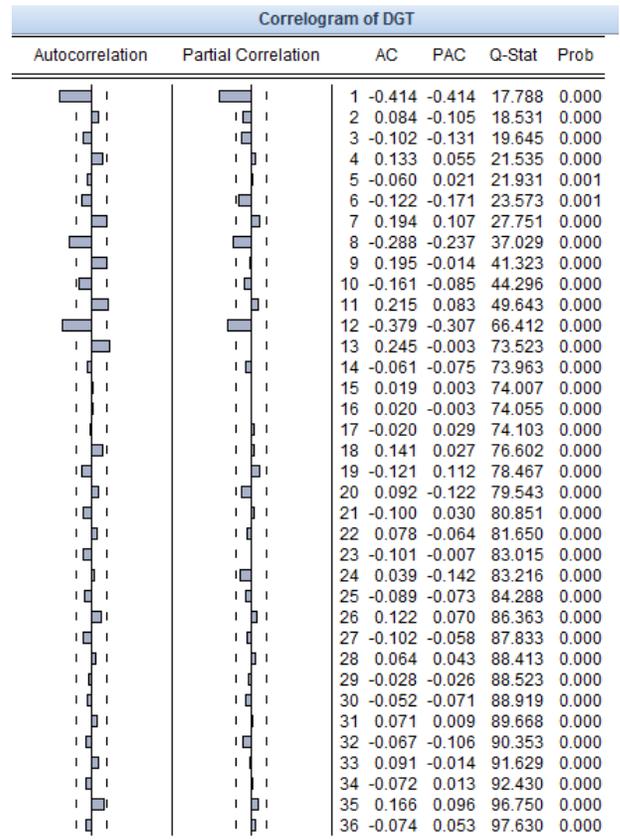
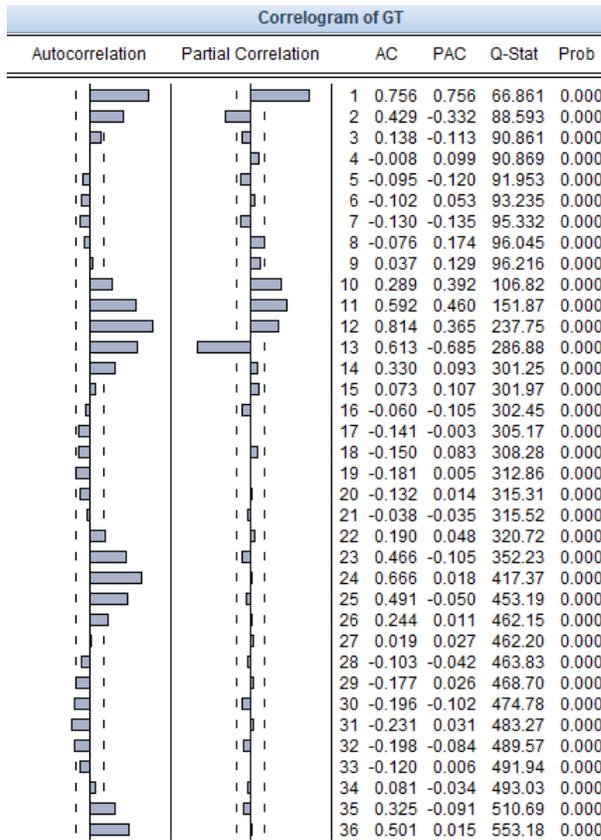
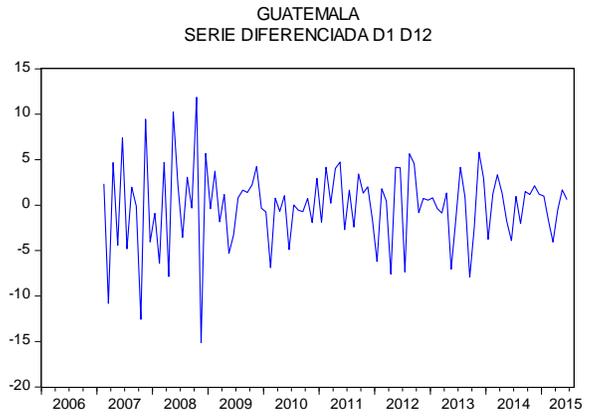
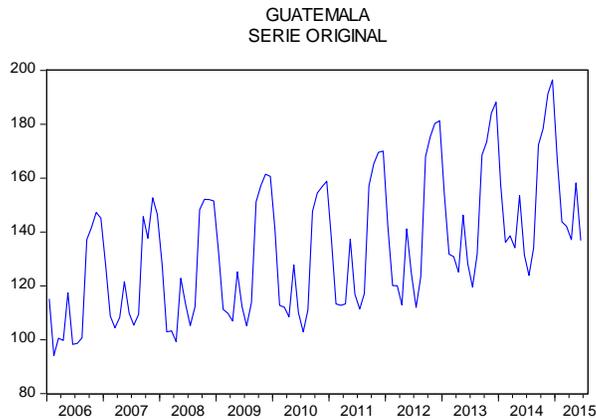
EL SALVADOR
SERIE DIFERENCIADA D12



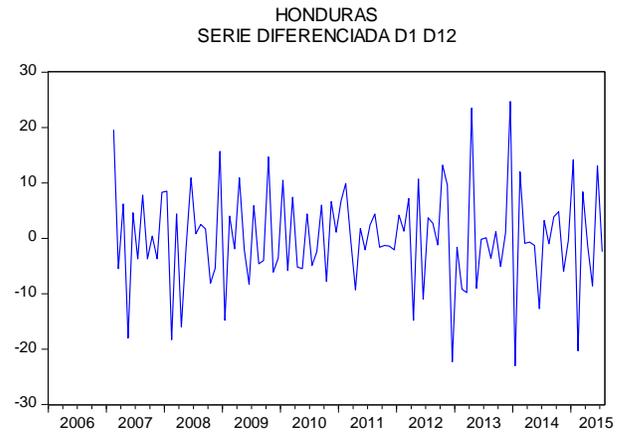
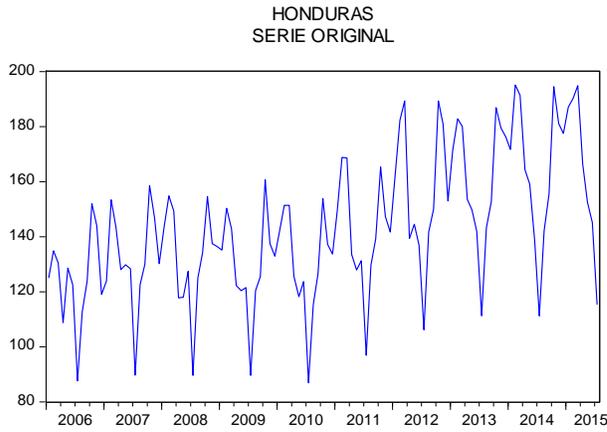
Correlogram of DSV2

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.700	0.700	52.018	0.000
		2	0.565	0.145	86.161	0.000
		3	0.502	0.124	113.39	0.000
		4	0.349	-0.141	126.72	0.000
		5	0.294	0.055	136.24	0.000
		6	0.152	-0.191	138.83	0.000
		7	0.013	-0.126	138.85	0.000
		8	-0.061	-0.071	139.28	0.000
		9	-0.235	-0.241	145.63	0.000
		10	-0.237	0.112	152.14	0.000
		11	-0.287	-0.102	161.84	0.000
		12	-0.382	-0.089	179.22	0.000
		13	-0.286	0.168	189.04	0.000
		14	-0.262	0.042	197.40	0.000
		15	-0.205	0.085	202.57	0.000
		16	-0.137	-0.034	204.91	0.000
		17	-0.169	-0.113	208.51	0.000
		18	-0.113	-0.081	210.14	0.000
		19	-0.106	-0.116	211.59	0.000
		20	-0.124	-0.115	213.59	0.000
		21	-0.056	-0.029	214.01	0.000
		22	-0.057	0.065	214.44	0.000
		23	-0.050	-0.010	214.78	0.000
		24	-0.080	-0.102	215.66	0.000
		25	-0.077	0.132	216.48	0.000
		26	-0.059	-0.052	216.97	0.000
		27	-0.102	-0.061	218.46	0.000
		28	-0.116	-0.086	220.40	0.000
		29	-0.031	0.092	220.55	0.000
		30	-0.044	-0.073	220.84	0.000
		31	0.016	0.080	220.88	0.000
		32	0.003	-0.147	220.88	0.000
		33	-0.010	-0.017	220.89	0.000
		34	0.033	0.059	221.07	0.000
		35	0.027	-0.039	221.19	0.000
		36	0.004	-0.173	221.19	0.000

Gráficos y correlogramas del IMAE agropecuario de Guatemala



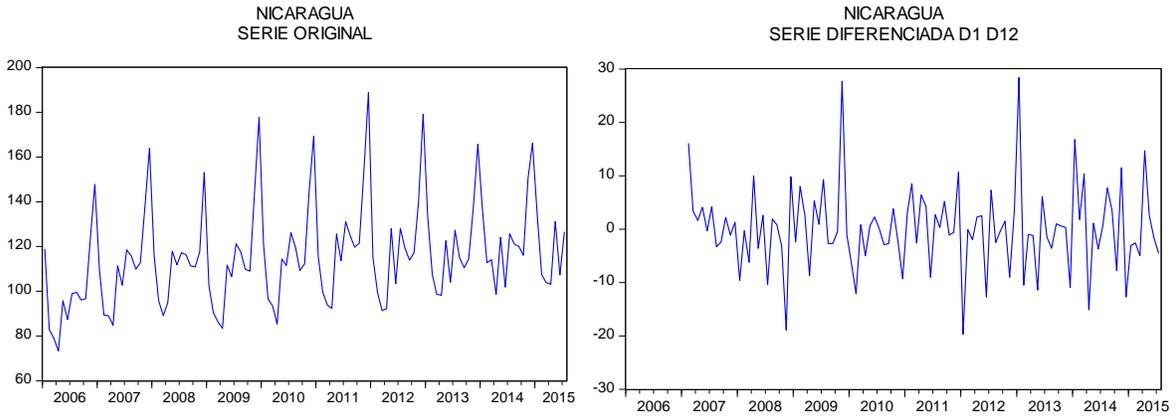
Gráficos y correlogramas del IMAE agropecuario de Honduras



Correlogram of HN					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.662	0.662	51.747	0.000	
2	0.419	-0.034	72.662	0.000	
3	0.243	-0.037	79.783	0.000	
4	0.159	0.037	82.838	0.000	
5	0.094	-0.019	83.924	0.000	
6	-0.006	-0.111	83.928	0.000	
7	0.044	0.175	84.165	0.000	
8	0.095	0.053	85.292	0.000	
9	0.139	0.039	87.743	0.000	
10	0.304	0.322	99.556	0.000	
11	0.519	0.367	134.45	0.000	
12	0.792	0.572	216.32	0.000	
13	0.513	-0.584	251.00	0.000	
14	0.302	-0.100	263.14	0.000	
15	0.151	-0.088	266.21	0.000	
16	0.087	0.086	267.25	0.000	
17	0.007	-0.170	267.26	0.000	
18	-0.084	0.151	268.24	0.000	
19	-0.036	0.063	268.42	0.000	
20	-0.003	-0.104	268.42	0.000	
21	0.042	0.066	268.68	0.000	
22	0.171	-0.167	272.93	0.000	
23	0.353	-0.039	291.13	0.000	
24	0.596	0.049	343.65	0.000	
25	0.359	0.018	362.90	0.000	
26	0.190	-0.013	368.34	0.000	
27	0.050	-0.076	368.73	0.000	
28	-0.005	0.028	368.73	0.000	
29	-0.072	-0.003	369.55	0.000	
30	-0.158	-0.005	373.48	0.000	
31	-0.108	-0.028	375.34	0.000	
32	-0.090	-0.047	376.67	0.000	
33	-0.057	-0.009	377.21	0.000	
34	0.055	0.008	377.71	0.000	
35	0.206	-0.030	384.83	0.000	
36	0.419	-0.035	414.72	0.000	

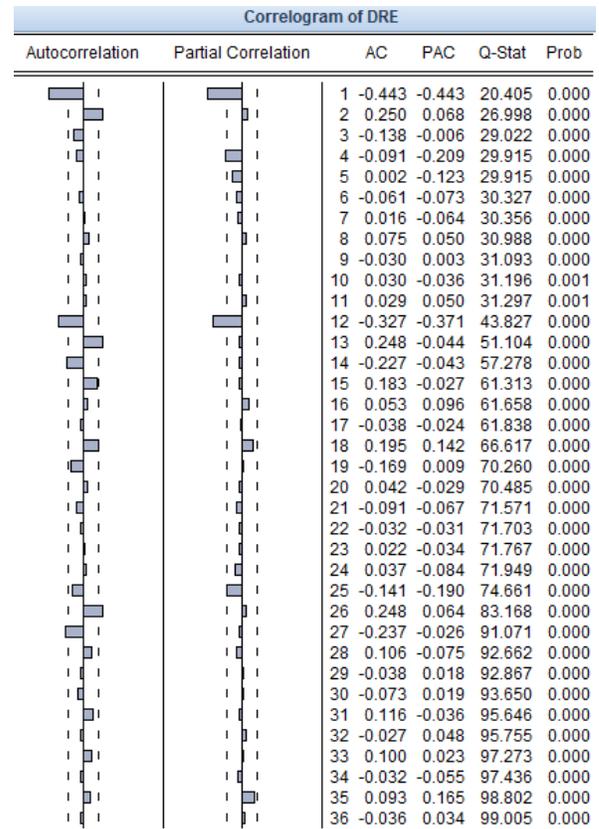
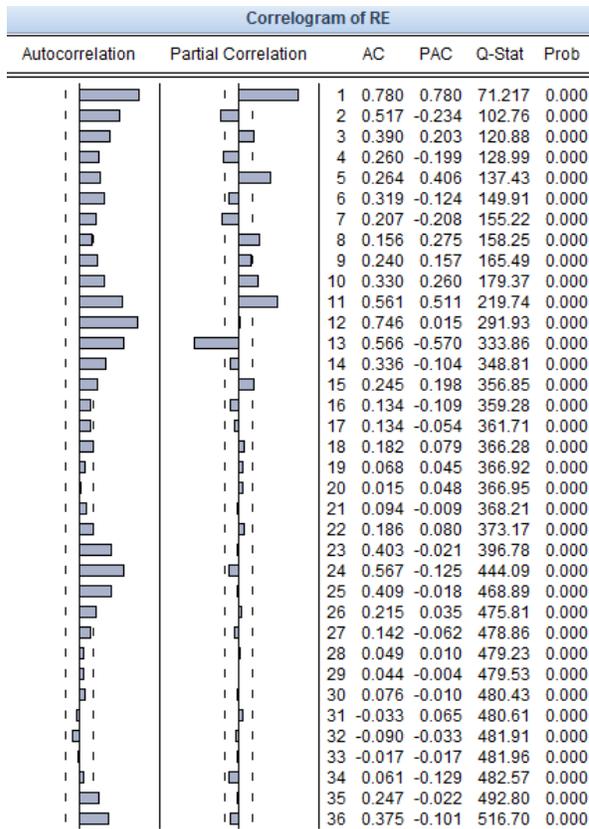
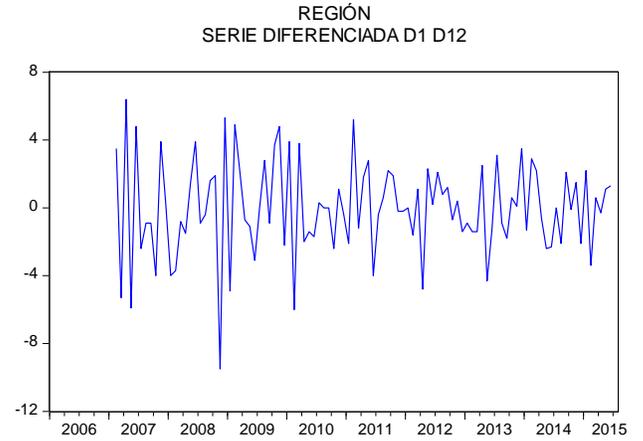
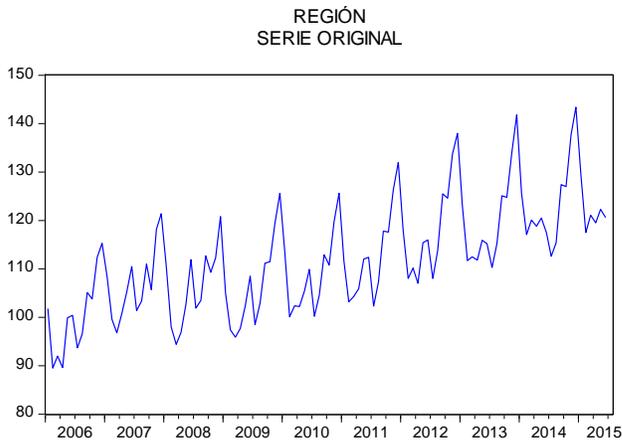
Correlogram of DHN					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	-0.455	-0.455	21.787	0.000	
2	0.060	-0.186	22.173	0.000	
3	0.061	0.012	22.575	0.000	
4	-0.316	-0.349	33.401	0.000	
5	0.155	-0.219	36.042	0.000	
6	0.051	-0.000	36.330	0.000	
7	-0.164	-0.188	39.347	0.000	
8	0.231	-0.043	45.388	0.000	
9	-0.132	-0.052	47.372	0.000	
10	0.006	-0.045	47.376	0.000	
11	0.205	0.176	52.278	0.000	
12	-0.372	-0.204	68.567	0.000	
13	0.300	0.079	79.319	0.000	
14	-0.182	-0.082	83.334	0.000	
15	-0.033	-0.078	83.465	0.000	
16	0.221	0.035	89.513	0.000	
17	-0.171	-0.013	93.147	0.000	
18	0.091	0.054	94.190	0.000	
19	-0.022	-0.126	94.255	0.000	
20	-0.100	0.007	95.550	0.000	
21	0.172	0.098	99.428	0.000	
22	-0.090	0.008	100.50	0.000	
23	-0.006	0.074	100.50	0.000	
24	0.016	-0.156	100.53	0.000	
25	-0.162	-0.082	104.16	0.000	
26	0.237	0.077	112.02	0.000	
27	-0.078	-0.009	112.88	0.000	
28	-0.054	-0.045	113.30	0.000	
29	0.085	-0.137	114.34	0.000	
30	-0.117	0.029	116.36	0.000	
31	0.058	-0.051	116.87	0.000	
32	0.056	-0.035	117.34	0.000	
33	-0.106	-0.011	119.06	0.000	
34	0.085	-0.089	120.19	0.000	
35	-0.056	0.018	120.69	0.000	
36	-0.025	-0.113	120.79	0.000	

Gráficos y correlogramas del IMAE agropecuario de Nicaragua

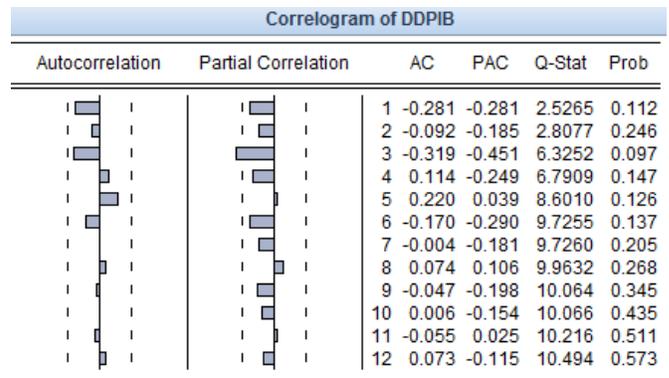
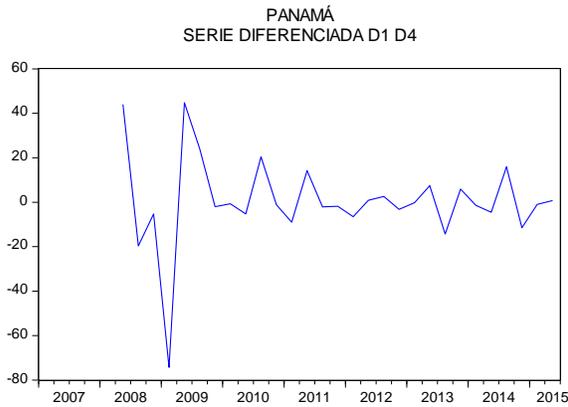
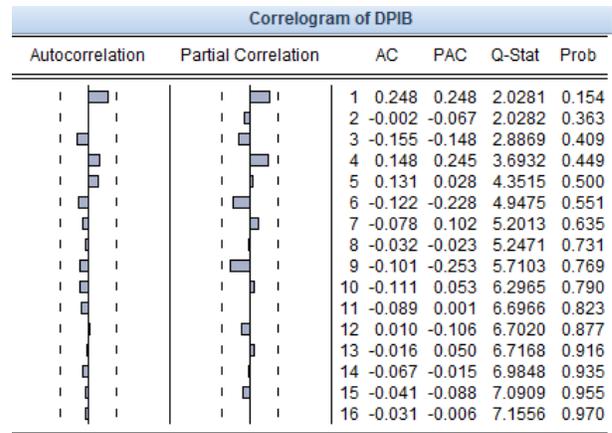
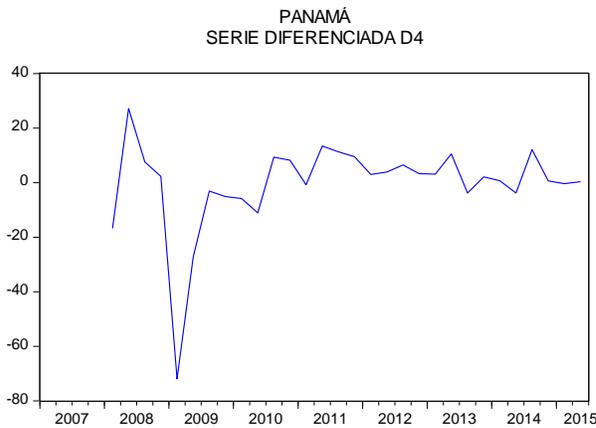
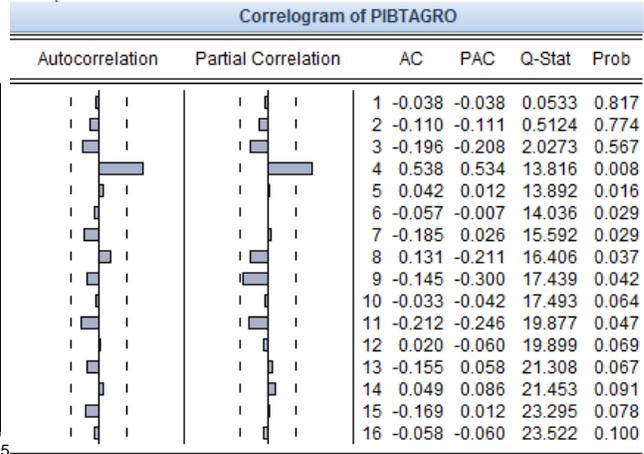
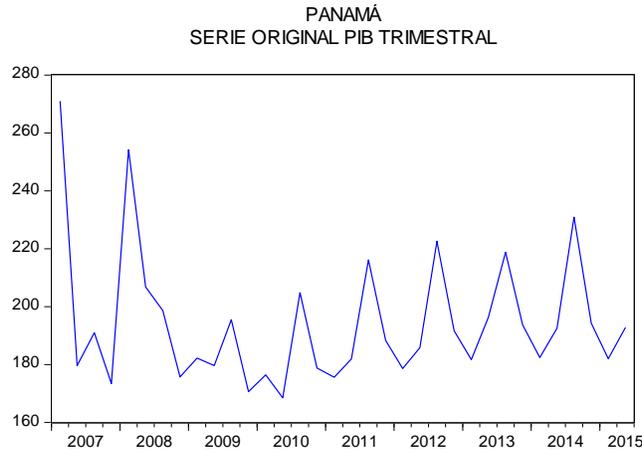


Correlogram of NI						Correlogram of DNI					
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.480	0.480	27.232	0.000		1	-0.248	-0.248	6.4837	0.011	
2	0.049	-0.236	27.515	0.000		2	-0.032	-0.100	6.5914	0.037	
3	-0.188	-0.143	31.778	0.000		3	-0.114	-0.158	7.9745	0.047	
4	-0.142	0.055	34.233	0.000		4	-0.051	-0.141	8.2538	0.083	
5	0.052	0.123	34.559	0.000		5	0.097	0.024	9.2901	0.098	
6	-0.008	-0.204	34.567	0.000		6	0.026	0.031	9.3622	0.154	
7	0.023	0.129	34.635	0.000		7	-0.114	-0.120	10.804	0.147	
8	-0.185	-0.295	38.953	0.000		8	0.074	0.031	11.414	0.179	
9	-0.241	-0.034	46.306	0.000		9	-0.029	0.000	11.512	0.242	
10	-0.034	0.185	46.450	0.000		10	0.084	0.061	12.327	0.264	
11	0.364	0.430	63.623	0.000		11	-0.093	-0.069	13.339	0.272	
12	0.806	0.626	148.52	0.000		12	-0.240	-0.289	20.122	0.065	
13	0.358	-0.506	165.43	0.000		13	0.048	-0.129	20.402	0.086	
14	-0.020	-0.030	165.48	0.000		14	0.084	-0.013	21.252	0.095	
15	-0.227	-0.012	172.43	0.000		15	0.080	0.018	22.039	0.107	
16	-0.183	-0.137	176.98	0.000		16	-0.098	-0.132	23.222	0.108	
17	0.008	-0.016	176.99	0.000		17	0.001	0.003	23.222	0.142	
18	-0.049	0.001	177.33	0.000		18	-0.003	0.002	23.223	0.182	
19	-0.015	0.027	177.36	0.000		19	0.000	-0.079	23.223	0.228	
20	-0.216	-0.003	183.98	0.000		20	0.021	-0.027	23.280	0.275	
21	-0.261	0.046	193.76	0.000		21	-0.080	-0.093	24.113	0.288	
22	-0.074	-0.016	194.56	0.000		22	0.068	0.033	24.720	0.311	
23	0.306	0.066	208.25	0.000		23	0.066	0.005	25.298	0.335	
24	0.710	0.099	282.75	0.000		24	-0.106	-0.211	26.813	0.313	
25	0.333	0.033	299.34	0.000		25	0.094	-0.004	28.031	0.306	
26	-0.006	-0.027	299.35	0.000		26	-0.113	-0.041	29.810	0.276	
27	-0.181	0.108	304.36	0.000		27	0.046	-0.021	30.115	0.309	
28	-0.151	-0.065	307.89	0.000		28	0.078	-0.015	30.984	0.318	
29	0.019	-0.032	307.95	0.000		29	0.016	0.071	31.019	0.365	
30	-0.041	0.016	308.21	0.000		30	-0.009	0.025	31.031	0.414	
31	-0.010	0.013	308.23	0.000		31	-0.078	-0.110	31.939	0.420	
32	-0.192	0.050	314.19	0.000		32	0.008	-0.046	31.949	0.469	
33	-0.237	0.018	323.41	0.000		33	0.132	0.091	34.609	0.391	
34	-0.090	-0.074	324.77	0.000		34	-0.069	0.039	35.353	0.404	
35	0.255	0.006	335.74	0.000		35	-0.029	-0.082	35.484	0.445	
36	0.614	-0.021	399.95	0.000		36	-0.031	-0.108	35.642	0.485	

Gráficos y correlogramas del IMAE agropecuario de la Región



Gráficos y correlogramas del PIB trimestral agropecuario de Panamá



ANEXO 8: PRUEBAS DE INTEGRACIÓN DE LA PRODUCCIÓN AGROPECUARIA

Resultados de las pruebas de integración para el IMAE agropecuario de Costa Rica

Null Hypothesis: CR has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.036076	0.5745
Test critical values:		
1% level	-4.050509	
5% level	-3.454471	
10% level	-3.152909	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(CR)
 Method: Least Squares
 Date: 10/25/15 Time: 19:41
 Sample (adjusted): 2007M02 2015M07
 Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
CR(-1)	-0.361539	0.177567	-2.036076	0.0448
D(CR(-1))	-0.083868	0.189455	-0.442681	0.6591
D(CR(-2))	0.197502	0.183562	1.075944	0.2849
D(CR(-3))	-0.095121	0.169317	-0.561790	0.5757
D(CR(-4))	-0.212477	0.157372	-1.350157	0.1805
D(CR(-5))	-0.004487	0.152064	-0.029508	0.9765
D(CR(-6))	-0.085374	0.133704	-0.638529	0.5248
D(CR(-7))	-0.292828	0.122979	-2.381120	0.0194
D(CR(-8))	-0.130048	0.121863	-1.067166	0.2888
D(CR(-9))	-0.226809	0.105780	-2.144160	0.0348
D(CR(-10))	-0.294421	0.099066	-2.971967	0.0038
D(CR(-11))	-0.048500	0.101063	-0.479897	0.6325
D(CR(-12))	0.418098	0.086599	4.828000	0.0000
C	61.86151	30.12295	2.053634	0.0430
@TREND("2006M01")	0.099939	0.054894	1.820596	0.0721
R-squared	0.739159	Mean dependent var	-0.311765	
Adjusted R-squared	0.697185	S.D. dependent var	13.72274	
S.E. of regression	7.551434	Akaike info criterion	7.016405	
Sum squared resid	4961.101	Schwarz criterion	7.402430	
Log likelihood	-342.8367	Hannan-Quinn criter.	7.172720	
F-statistic	17.60979	Durbin-Watson stat	2.157306	
Prob(F-statistic)	0.000000			

La tendencia es significativa al 10%. Para comprobar los resultados eliminando la tendencia de la ecuación se obtuvieron los mismos resultados, con t-Statistics=-0.900553 y Prob=0.7845.

Null Hypothesis: D(CR) has a unit root

Exogenous: None
 Lag Length: 11 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.391748	0.0000
Test critical values:		
1% level	-2.587831	
5% level	-1.944006	
10% level	-1.614656	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(CR,2)
 Method: Least Squares
 Date: 10/25/15 Time: 21:46
 Sample (adjusted): 2007M02 2015M07
 Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CR(-1))	-3.802249	0.865771	-4.391748	0.0000
D(CR(-1),2)	2.397669	0.801542	2.991320	0.0036
D(CR(-2),2)	2.302873	0.723290	3.183887	0.0020
D(CR(-3),2)	1.937970	0.655202	2.957819	0.0040
D(CR(-4),2)	1.490062	0.585813	2.543579	0.0127
D(CR(-5),2)	1.280992	0.505430	2.534458	0.0130
D(CR(-6),2)	1.019481	0.438134	2.326872	0.0222
D(CR(-7),2)	0.577084	0.372529	1.549097	0.1249
D(CR(-8),2)	0.331212	0.293438	1.128729	0.2620
D(CR(-9),2)	0.017216	0.225915	0.076205	0.9394
D(CR(-10),2)	-0.332642	0.161613	-2.058268	0.0425
D(CR(-11),2)	-0.410304	0.084949	-4.829971	0.0000
R-squared	0.862800	Mean dependent var		-0.536275
Adjusted R-squared	0.846031	S.D. dependent var		19.45159
S.E. of regression	7.632592	Akaike info criterion		7.012863
Sum squared resid	5243.081	Schwarz criterion		7.321683
Log likelihood	-345.6560	Hannan-Quinn criter.		7.137915
Durbin-Watson stat	2.118031			

Resultados de las pruebas de integración para el IMAE agropecuario de El Salvador

Null Hypothesis: SV has a unit root

Exogenous: Constant

Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.643480	0.0877
Test critical values:		
1% level	-3.495677	
5% level	-2.890037	
10% level	-2.582041	

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

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(SV)

Method: Least Squares

Date: 10/25/15 Time: 20:08

Sample (adjusted): 2007M02 2015M07

Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
SV(-1)	-0.455980	0.172492	-2.643480	0.0097
D(SV(-1))	0.107399	0.168937	0.635735	0.5266
D(SV(-2))	0.066872	0.155975	0.428733	0.6692
D(SV(-3))	0.047232	0.143567	0.328992	0.7429
D(SV(-4))	0.006365	0.131454	0.048419	0.9615
D(SV(-5))	-0.046080	0.119930	-0.384223	0.7017
D(SV(-6))	-0.080949	0.109478	-0.739409	0.4616
D(SV(-7))	-0.117714	0.099670	-1.181042	0.2408
D(SV(-8))	-0.149996	0.090228	-1.662418	0.1000
D(SV(-9))	-0.196864	0.082442	-2.387917	0.0191
D(SV(-10))	-0.223439	0.076930	-2.904454	0.0047
D(SV(-11))	-0.265123	0.073303	-3.616809	0.0005
D(SV(-12))	0.689968	0.072846	9.471654	0.0000
C	54.69724	20.58832	2.656712	0.0094
R-squared	0.985583	Mean dependent var		0.516667
Adjusted R-squared	0.983453	S.D. dependent var		34.65968
S.E. of regression	4.458392	Akaike info criterion		5.954327
Sum squared resid	1749.199	Schwarz criterion		6.314618
Log likelihood	-289.6707	Hannan-Quinn criter.		6.100221
F-statistic	462.7685	Durbin-Watson stat		2.283904
Prob(F-statistic)	0.000000			

La tendencia no es significativa para El Salvador. La prueba con constante y con tendencia generó un t-statistics=-2.8525 con Prob=0.1824, que también señala la existencia de una raíz unitaria.

Null Hypothesis: D(SV) has a unit root
 Exogenous: None
 Lag Length: 11 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.876525	0.0002
Test critical values: 1% level	-2.587831	
5% level	-1.944006	
10% level	-1.614656	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(SV,2)
 Method: Least Squares
 Date: 10/25/15 Time: 20:13
 Sample (adjusted): 2007M02 2015M07
 Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(SV(-1))	-3.398790	0.876762	-3.876525	0.0002
D(SV(-1),2)	2.110725	0.804500	2.623649	0.0102
D(SV(-2),2)	1.821154	0.731734	2.488820	0.0147
D(SV(-3),2)	1.550413	0.658489	2.354500	0.0207
D(SV(-4),2)	1.275185	0.585962	2.176225	0.0322
D(SV(-5),2)	0.984286	0.513672	1.916178	0.0585
D(SV(-6),2)	0.696421	0.440452	1.581151	0.1174
D(SV(-7),2)	0.409595	0.366775	1.116747	0.2671
D(SV(-8),2)	0.130506	0.293012	0.445395	0.6571
D(SV(-9),2)	-0.157626	0.219695	-0.717476	0.4749
D(SV(-10),2)	-0.433341	0.146417	-2.959638	0.0039
D(SV(-11),2)	-0.712835	0.073655	-9.678028	0.0000
R-squared	0.993825	Mean dependent var		0.103922
Adjusted R-squared	0.993070	S.D. dependent var		55.13840
S.E. of regression	4.590020	Akaike info criterion		5.995777
Sum squared resid	1896.145	Schwarz criterion		6.304597
Log likelihood	-293.7846	Hannan-Quinn criter.		6.120828
Durbin-Watson stat	2.229914			

Resultados de las pruebas de integración para el IMAE agropecuario de Guatemala

Null Hypothesis: GT has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.230591	0.8984
Test critical values:		
1% level	-4.051450	
5% level	-3.454919	
10% level	-3.153171	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(GT)
 Method: Least Squares
 Date: 10/25/15 Time: 20:15
 Sample (adjusted): 2007M02 2015M06
 Included observations: 101 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
GT(-1)	-0.188649	0.153300	-1.230591	0.2218
D(GT(-1))	-0.258029	0.174212	-1.481120	0.1422
D(GT(-2))	-0.241991	0.164352	-1.472393	0.1446
D(GT(-3))	-0.284374	0.152593	-1.863611	0.0658
D(GT(-4))	-0.281085	0.142857	-1.967597	0.0523
D(GT(-5))	-0.323402	0.132411	-2.442406	0.0166
D(GT(-6))	-0.317705	0.124785	-2.546015	0.0127
D(GT(-7))	-0.335082	0.116286	-2.881530	0.0050
D(GT(-8))	-0.378745	0.108018	-3.506324	0.0007
D(GT(-9))	-0.355246	0.103165	-3.443492	0.0009
D(GT(-10))	-0.433651	0.095342	-4.548385	0.0000
D(GT(-11))	-0.377937	0.095127	-3.972994	0.0001
D(GT(-12))	0.562653	0.090650	6.206882	0.0000
C	21.78074	16.98990	1.281981	0.2033
@TREND("2006M01")	0.087594	0.058805	1.489558	0.1400
R-squared	0.954412	Mean dependent var		0.092328
Adjusted R-squared	0.946990	S.D. dependent var		17.46981
S.E. of regression	4.022225	Akaike info criterion		5.757804
Sum squared resid	1391.333	Schwarz criterion		6.146188
Log likelihood	-275.7691	Hannan-Quinn criter.		5.915033
F-statistic	128.6030	Durbin-Watson stat		2.309554
Prob(F-statistic)	0.000000			

Null Hypothesis: D(GT) has a unit root
 Exogenous: None
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.559230	0.0108
Test critical values: 1% level	-2.588292	
5% level	-1.944072	
10% level	-1.614616	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(GT,2)
 Method: Least Squares
 Date: 10/25/15 Time: 20:19
 Sample (adjusted): 2007M03 2015M06
 Included observations: 100 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(GT(-1))	-1.971823	0.770475	-2.559230	0.0122
D(GT(-1),2)	0.489109	0.742228	0.658975	0.5117
D(GT(-2),2)	0.335626	0.678927	0.494347	0.6223
D(GT(-3),2)	0.174516	0.615121	0.283710	0.7773
D(GT(-4),2)	0.022998	0.552507	0.041625	0.9669
D(GT(-5),2)	-0.161907	0.490105	-0.330353	0.7419
D(GT(-6),2)	-0.319460	0.429144	-0.744412	0.4586
D(GT(-7),2)	-0.482974	0.367873	-1.312884	0.1927
D(GT(-8),2)	-0.660591	0.306794	-2.153205	0.0341
D(GT(-9),2)	-0.816406	0.247707	-3.295852	0.0014
D(GT(-10),2)	-1.016669	0.188950	-5.380615	0.0000
D(GT(-11),2)	-1.159395	0.140097	-8.275676	0.0000
D(GT(-12),2)	-0.331652	0.101978	-3.252196	0.0016
R-squared	0.971318	Mean dependent var		-0.026026
Adjusted R-squared	0.967362	S.D. dependent var		22.46155
S.E. of regression	4.057903	Akaike info criterion		5.759948
Sum squared resid	1432.592	Schwarz criterion		6.098620
Log likelihood	-274.9974	Hannan-Quinn criter.		5.897014
Durbin-Watson stat	1.993129			

Resultados de las pruebas de integración para el IMAE agropecuario de Honduras

Null Hypothesis: HN has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.964499	0.9436
Test critical values:		
1% level	-4.050509	
5% level	-3.454471	
10% level	-3.152909	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(HN)
 Method: Least Squares
 Date: 10/25/15 Time: 20:22
 Sample (adjusted): 2007M02 2015M07
 Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
HN(-1)	-0.141969	0.147195	-0.964499	0.3375
D(HN(-1))	-0.458537	0.171042	-2.680845	0.0088
D(HN(-2))	-0.421468	0.162863	-2.587866	0.0113
D(HN(-3))	-0.478409	0.152164	-3.144041	0.0023
D(HN(-4))	-0.498343	0.145063	-3.435347	0.0009
D(HN(-5))	-0.467687	0.139309	-3.357201	0.0012
D(HN(-6))	-0.538173	0.130179	-4.134112	0.0001
D(HN(-7))	-0.551864	0.123800	-4.457700	0.0000
D(HN(-8))	-0.531771	0.120202	-4.423985	0.0000
D(HN(-9))	-0.588845	0.113794	-5.174658	0.0000
D(HN(-10))	-0.565192	0.110855	-5.098461	0.0000
D(HN(-11))	-0.526120	0.106536	-4.938438	0.0000
D(HN(-12))	0.352469	0.100347	3.512514	0.0007
C	18.29878	17.01511	1.075443	0.2851
@TREND("2006M01")	0.078443	0.069501	1.128655	0.2621
R-squared	0.880783	Mean dependent var		-0.084314
Adjusted R-squared	0.861598	S.D. dependent var		20.89151
S.E. of regression	7.772138	Akaike info criterion		7.074021
Sum squared resid	5255.334	Schwarz criterion		7.460046
Log likelihood	-345.7751	Hannan-Quinn criter.		7.230336
F-statistic	45.91140	Durbin-Watson stat		2.049421
Prob(F-statistic)	0.000000			

Null Hypothesis: D(HN) has a unit root
 Exogenous: None
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.198668	0.0016
Test critical values: 1% level	-2.588059	
5% level	-1.944039	
10% level	-1.614637	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(HN,2)
 Method: Least Squares
 Date: 10/25/15 Time: 20:24
 Sample (adjusted): 2007M03 2015M07
 Included observations: 101 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(HN(-1))	-3.401707	1.063476	-3.198668	0.0019
D(HN(-1),2)	1.834338	1.023032	1.793042	0.0764
D(HN(-2),2)	1.595680	0.937816	1.701484	0.0924
D(HN(-3),2)	1.305282	0.852706	1.530753	0.1294
D(HN(-4),2)	0.995799	0.768752	1.295344	0.1986
D(HN(-5),2)	0.734837	0.683432	1.075216	0.2852
D(HN(-6),2)	0.414574	0.596890	0.694557	0.4892
D(HN(-7),2)	0.122698	0.510275	0.240456	0.8105
D(HN(-8),2)	-0.148477	0.423427	-0.350656	0.7267
D(HN(-9),2)	-0.468925	0.335473	-1.397801	0.1657
D(HN(-10),2)	-0.733337	0.248594	-2.949938	0.0041
D(HN(-11),2)	-0.952695	0.165917	-5.741999	0.0000
D(HN(-12),2)	-0.300362	0.097737	-3.073180	0.0028
R-squared	0.949101	Mean dependent var		-0.587129
Adjusted R-squared	0.942160	S.D. dependent var		31.17178
S.E. of regression	7.496793	Akaike info criterion		6.986470
Sum squared resid	4945.768	Schwarz criterion		7.323069
Log likelihood	-339.8167	Hannan-Quinn criter.		7.122735
Durbin-Watson stat	2.118660			

Resultados de las pruebas de integración para el IMAE agropecuario de Nicaragua

Null Hypothesis: NI has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.474234	0.0476
Test critical values:		
1% level	-4.050509	
5% level	-3.454471	
10% level	-3.152909	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(NI)
 Method: Least Squares
 Date: 10/25/15 Time: 20:26
 Sample (adjusted): 2007M02 2015M07
 Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
NI(-1)	-0.805120	0.231740	-3.474234	0.0008
D(NI(-1))	0.297524	0.229133	1.298481	0.1976
D(NI(-2))	0.264455	0.212600	1.243909	0.2169
D(NI(-3))	0.161501	0.193590	0.834244	0.4064
D(NI(-4))	0.106221	0.177190	0.599472	0.5504
D(NI(-5))	0.076420	0.159917	0.477875	0.6339
D(NI(-6))	-0.012064	0.144585	-0.083441	0.9337
D(NI(-7))	-0.092281	0.128123	-0.720254	0.4733
D(NI(-8))	-0.125779	0.117040	-1.074671	0.2855
D(NI(-9))	-0.223222	0.103515	-2.156425	0.0338
D(NI(-10))	-0.289693	0.094399	-3.068821	0.0029
D(NI(-11))	-0.338994	0.088136	-3.846246	0.0002
D(NI(-12))	0.534593	0.084890	6.297494	0.0000
C	88.20434	24.44799	3.607836	0.0005
@TREND("2006M01")	0.110777	0.048043	2.305807	0.0235
R-squared	0.922806	Mean dependent var		0.169608
Adjusted R-squared	0.910384	S.D. dependent var		22.71994
S.E. of regression	6.801428	Akaike info criterion		6.807195
Sum squared resid	4024.570	Schwarz criterion		7.193221
Log likelihood	-332.1670	Hannan-Quinn criter.		6.963510
F-statistic	74.28788	Durbin-Watson stat		2.138802
Prob(F-statistic)	0.000000			

Resultados de las pruebas de integración para el IMAE agropecuario de la Región

Null Hypothesis: RE has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.537199	0.8102
Test critical values:		
1% level	-4.051450	
5% level	-3.454919	
10% level	-3.153171	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(RE)
 Method: Least Squares
 Date: 10/25/15 Time: 20:32
 Sample (adjusted): 2007M02 2015M06
 Included observations: 101 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RE(-1)	-0.216406	0.140779	-1.537199	0.1279
D(RE(-1))	-0.063277	0.159538	-0.396629	0.6926
D(RE(-2))	-0.206015	0.152703	-1.349120	0.1808
D(RE(-3))	-0.104076	0.141901	-0.733438	0.4653
D(RE(-4))	-0.189061	0.132982	-1.421712	0.1587
D(RE(-5))	-0.217094	0.123838	-1.753048	0.0832
D(RE(-6))	-0.190435	0.116772	-1.630825	0.1066
D(RE(-7))	-0.218376	0.111109	-1.965412	0.0526
D(RE(-8))	-0.296178	0.103612	-2.858530	0.0053
D(RE(-9))	-0.238649	0.098799	-2.415491	0.0178
D(RE(-10))	-0.373130	0.095372	-3.912365	0.0002
D(RE(-11))	-0.180023	0.093310	-1.929297	0.0570
D(RE(-12))	0.537749	0.088988	6.042920	0.0000
C	21.88980	13.77868	1.588672	0.1158
@TREND("2006M01")	0.051955	0.033030	1.572957	0.1194
R-squared	0.901350	Mean dependent var		0.120792
Adjusted R-squared	0.885290	S.D. dependent var		7.470533
S.E. of regression	2.530182	Akaike info criterion		4.830716
Sum squared resid	550.5566	Schwarz criterion		5.219100
Log likelihood	-228.9512	Hannan-Quinn criter.		4.987945
F-statistic	56.12611	Durbin-Watson stat		2.480227
Prob(F-statistic)	0.000000			

Null Hypothesis: D(RE) has a unit root
 Exogenous: None
 Lag Length: 12 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.301674	0.0213
Test critical values:		
1% level	-2.588292	
5% level	-1.944072	
10% level	-1.614616	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(RE,2)
 Method: Least Squares
 Date: 10/25/15 Time: 20:34
 Sample (adjusted): 2007M03 2015M06
 Included observations: 100 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(RE(-1))	-1.582118	0.687377	-2.301674	0.0237
D(RE(-1),2)	0.144524	0.661013	0.218640	0.8274
D(RE(-2),2)	-0.079704	0.607573	-0.131184	0.8959
D(RE(-3),2)	-0.134906	0.548891	-0.245779	0.8064
D(RE(-4),2)	-0.275147	0.494150	-0.556808	0.5791
D(RE(-5),2)	-0.423009	0.438940	-0.963707	0.3379
D(RE(-6),2)	-0.531224	0.385931	-1.376475	0.1722
D(RE(-7),2)	-0.670702	0.333619	-2.010383	0.0475
D(RE(-8),2)	-0.831332	0.278849	-2.981304	0.0037
D(RE(-9),2)	-0.941512	0.226519	-4.156429	0.0001
D(RE(-10),2)	-1.162958	0.176334	-6.595211	0.0000
D(RE(-11),2)	-1.157140	0.131134	-8.824076	0.0000
D(RE(-12),2)	-0.423490	0.094731	-4.470463	0.0000
R-squared	0.951053	Mean dependent var		0.071000
Adjusted R-squared	0.944302	S.D. dependent var		10.10201
S.E. of regression	2.384115	Akaike info criterion		4.696271
Sum squared resid	494.5083	Schwarz criterion		5.034943
Log likelihood	-221.8135	Hannan-Quinn criter.		4.833337
Durbin-Watson stat	1.790184			

*Resultados de las pruebas de integración para el
PIB trimestral agropecuario de Panamá*

Null Hypothesis: PIBTAGRO has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 8 (Automatic - based on SIC, maxlag=8)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.533370	0.0071
Test critical values:		
1% level	-4.374307	
5% level	-3.603202	
10% level	-3.238054	

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

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(PIBTAGRO)
Method: Least Squares
Date: 10/25/15 Time: 20:36
Sample (adjusted): 2009Q2 2015Q2
Included observations: 25 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
PIBTAGRO(-1)	-1.910202	0.421365	-4.533370	0.0005
D(PIBTAGRO(-1))	0.567526	0.269088	2.109072	0.0534
D(PIBTAGRO(-2))	0.070060	0.183674	0.381436	0.7086
D(PIBTAGRO(-3))	-0.261841	0.122878	-2.130897	0.0513
D(PIBTAGRO(-4))	0.346939	0.132034	2.627646	0.0199
D(PIBTAGRO(-5))	0.476633	0.125187	3.807372	0.0019
D(PIBTAGRO(-6))	0.424872	0.097466	4.359157	0.0007
D(PIBTAGRO(-7))	0.315613	0.085694	3.683038	0.0025
D(PIBTAGRO(-8))	0.246066	0.066907	3.677734	0.0025
C	332.7211	71.74119	4.637797	0.0004
@TREND("2007Q1")	1.577707	0.444114	3.552480	0.0032
R-squared	0.976591	Mean dependent var		0.424000
Adjusted R-squared	0.959870	S.D. dependent var		22.52553
S.E. of regression	4.512413	Akaike info criterion		6.151723
Sum squared resid	285.0662	Schwarz criterion		6.688028
Log likelihood	-65.89653	Hannan-Quinn criter.		6.300471
F-statistic	58.40583	Durbin-Watson stat		2.164158
Prob(F-statistic)	0.000000			

ANEXO 9: RESULTADOS MODELOS DE LA PRODUCCIÓN AGROPECUARIA

Resultados del ajuste del modelo ARIMA para el IMAE agropecuario de Costa Rica

MODEL FINALLY CHOSEN :
 (0,1,1)(0,1,1) WITHOUT MEAN
 OUTLIERS
 67 TC (7 2011)
 51 AO (3 2010)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	-0.60615	0.80355E-01	-7.54	1
BTH	-0.46530	0.89428E-01	-5.20	12

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (67)	-18.418	(6.17805)	-2.98	TC (7 2011)
OUT 2 (51)	17.384	(6.28749)	2.76	AO (3 2010)

RESIDUALS STATISTICS

MEAN	-0.5342885
ST.DEV.OF MEAN	0.8093061
T-VALUE	-0.6601810
NORMALITY TEST (CHI-SQUARE(2))	1.904
SKEWNESS	-0.3380(SE = 0.2449)
KURTOSIS	2.9910(SE = 0.4899)
SUM OF SQUARES	6578.310
DURBIN-WATSON	1.9690
STANDARD ERROR OF RESIDUALS	8.193022
MSE OF RESID.	67.12561

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0005	0.1352	-0.0712	-0.1025	-0.0196	0.0043	-0.1214	0.1029	-0.0497	0.0089	0.0346	0.0813
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	0.00	1.90	2.44	3.55	3.59	3.60	5.21	6.38	6.66	6.67	6.81	7.57
PV	-1.00	-1.00	0.12	0.17	0.31	0.46	0.39	0.38	0.47	0.57	0.66	0.67

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.2061	-0.1193	-0.1176	0.1061	0.1243	0.1726	-0.1165	-0.0003	-0.0326	-0.0569	0.0844	-0.0815
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	12.55	14.24	15.90	17.27	19.17	22.87	24.58	24.58	24.72	25.14	26.09	26.98
PV	0.32	0.29	0.25	0.24	0.21	0.12	0.10	0.14	0.17	0.20	0.20	0.21

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.1460	-0.0003	-0.0897	0.0652	0.1216	-0.1199	-0.0196	0.0542	0.0778	0.0555	0.0032	-0.1354
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	29.88	29.88	31.00	31.60	33.73	35.82	35.88	36.32	37.24	37.72	37.72	40.64
PV	0.15	0.19	0.19	0.21	0.17	0.15	0.18	0.20	0.20	0.22	0.26	0.20

LJUNG-BOX Q VALUE OF ORDER 24 IS 26.98 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(22). p-value= 0.2121

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0634	0.0880	-0.0059	-0.0139	0.0520	-0.0294	-0.0058	0.1052	-0.1029	0.3347	-0.0433	0.0221
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	0.41	1.22	1.22	1.25	1.54	1.63	1.63	2.86	4.05	16.74	16.96	17.01
PV	-1.00	-1.00	0.27	0.54	0.67	0.80	0.90	0.83	0.77	0.03	0.05	0.07

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0299	0.0888	0.0813	0.1025	-0.0357	-0.0551	-0.0911	0.0308	0.0468	0.0282	-0.0115	0.2089
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	17.12	18.05	18.85	20.12	20.28	20.66	21.70	21.82	22.11	22.21	22.23	28.08
PV	0.10	0.11	0.13	0.13	0.16	0.19	0.20	0.24	0.28	0.33	0.39	0.17

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0202	0.1010	0.0233	-0.0533	-0.0497	-0.0079	0.0617	-0.0928	-0.0795	-0.0141	-0.0096	0.0650
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	28.14	29.55	29.62	30.02	30.38	30.39	30.95	32.24	33.20	33.23	33.25	33.92
PV	0.21	0.20	0.24	0.27	0.30	0.34	0.37	0.36	0.36	0.41	0.46	0.47

McLEOD-LI Q VALUE OF ORDER 24 IS 28.08 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.2565

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	YES

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IMAE agropecuario de El Salvador

MODEL FINALLY CHOSEN :

(1,0,0)(0,1,1) WITHOUT MEAN

OUTLIERS

37 TC (1 2009)

85 TC (1 2013)

78 TC (6 2012)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
PHI1	-0.70358	0.71250E-01	-9.87	1
BTH	-0.40204	0.91806E-01	-4.38	12

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (37)	-10.502	(2.89470)	-3.63	TC (1 2009)
OUT 2 (85)	-10.589	(2.89957)	-3.65	TC (1 2013)
OUT 3 (78)	10.614	(2.88948)	3.67	TC (6 2012)

RESIDUALS STATISTICS

MEAN	0.4653712
ST.DEV.OF MEAN	0.3382475
T-VALUE	1.3758304
NORMALITY TEST (CHI-SQUARE(2))	1.111
SKEWNESS	0.2463(SE = 0.2449)
KURTOSIS	2.8451(SE = 0.4899)
SUM OF SQUARES	1165.771
DURBIN-WATSON	2.0293
STANDARD ERROR OF RESIDUALS	3.449003
MSE OF RESID.	11.89562

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0537	-0.0705	0.0270	-0.0290	0.0886	0.0939	0.1274	0.0664	-0.2705	0.0079	-0.0358	0.0374
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	0.30	0.81	0.89	0.98	1.82	2.78	4.56	5.05	13.25	13.25	13.40	13.56
PV	-1.00	-1.00	0.34	0.61	0.61	0.60	0.47	0.54	0.07	0.10	0.15	0.19

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0246	-0.0651	0.0129	0.0585	-0.1150	0.0576	0.0662	-0.0364	-0.0534	0.0075	0.0852	-0.0572
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	13.63	14.14	14.16	14.57	16.20	16.61	17.16	17.33	17.70	17.71	18.67	19.11
PV	0.25	0.29	0.36	0.41	0.37	0.41	0.44	0.50	0.54	0.61	0.61	0.64

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0273	-0.0101	-0.0614	-0.1165	0.1170	-0.0581	0.1241	-0.0605	-0.0424	0.0309	0.0761	0.0957
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	19.21	19.23	19.75	21.67	23.64	24.13	26.41	26.96	27.23	27.38	28.29	29.75
PV	0.69	0.74	0.76	0.71	0.65	0.67	0.60	0.63	0.66	0.70	0.70	0.68

LJUNG-BOX Q VALUE OF ORDER 24 IS 19.11 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(22). p-value= 0.6385

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0425	0.1497	-0.1177	-0.0796	0.0950	-0.0151	0.0903	-0.0150	0.1010	0.0093	-0.0827	-0.0382
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	0.19	2.52	3.98	4.65	5.62	5.64	6.54	6.56	7.71	7.72	8.50	8.67
PV	-1.00	-1.00	0.05	0.10	0.13	0.23	0.26	0.36	0.36	0.46	0.48	0.56

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0151	-0.0155	-0.0580	-0.0864	-0.0565	0.0174	0.0426	-0.0663	0.0045	0.0192	0.0298	0.1269
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	8.70	8.72	9.13	10.03	10.43	10.46	10.69	11.25	11.26	11.31	11.42	13.58
PV	0.65	0.73	0.76	0.76	0.79	0.84	0.87	0.88	0.91	0.94	0.95	0.92

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0239	0.1001	0.0263	-0.0434	-0.1154	-0.0301	0.0500	0.0367	0.0552	0.0478	-0.0148	0.0568
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	13.66	15.04	15.14	15.41	17.32	17.45	17.82	18.02	18.49	18.84	18.88	19.39
PV	0.94	0.92	0.94	0.95	0.92	0.94	0.95	0.96	0.96	0.97	0.98	0.98

McLEOD-LI Q VALUE OF ORDER 24 IS 13.58 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.9555

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	YES

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IMAE agropecuario de Guatemala

MODEL FINALLY CHOSEN :

(0,1,1)(0,1,1) WITHOUT MEAN

OUTLIERS

40 AO (4 2012)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	-0.23852	0.12090	-1.97	1
BTH	-0.40219	0.11398	-3.53	12

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (40)	-0.48196E-01	(0.01372)	-3.51	AO (4 2012)

RESIDUALS STATISTICS

MEAN	0.0002358
ST.DEV.OF MEAN	0.0025582
T-VALUE	0.0921779
NORMALITY TEST (CHI-SQUARE(2))	3.573
SKEWNESS	-0.5787(SE = 0.3062)
KURTOSIS	2.9954(SE = 0.6124)
SUM OF SQUARES	0.2680979E-01
DURBIN-WATSON	1.9917
STANDARD ERROR OF RESIDUALS	0.2079461E-01
MSE OF RESID.	0.4324159E-03

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0039	-0.1333	-0.2104	0.0522	0.0949	-0.0545	-0.1130	-0.1876	0.1191	-0.1260	0.1693	0.0063
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	0.00	1.21	4.28	4.47	5.11	5.33	6.28	8.93	10.02	11.26	13.55	13.55
PV	-1.00	-1.00	0.04	0.11	0.16	0.26	0.28	0.18	0.19	0.19	0.14	0.19

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.1233	0.0406	-0.0307	0.1063	0.0094	0.0658	-0.1380	0.0097	0.0277	0.0134	0.0346	-0.0934
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	14.81	14.95	15.03	16.02	16.03	16.43	18.22	18.23	18.30	18.32	18.44	19.37
PV	0.19	0.24	0.31	0.31	0.38	0.42	0.38	0.44	0.50	0.57	0.62	0.62

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0731	-0.1035	0.0431	-0.0342	-0.0593	-0.1358	-0.0284	0.0635	0.0658	0.1595	0.0097	-0.0113
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	19.94	21.14	21.35	21.48	21.91	24.20	24.30	24.83	25.42	29.01	29.02	29.04
PV	0.65	0.63	0.67	0.72	0.74	0.67	0.71	0.73	0.75	0.62	0.67	0.71

LJUNG-BOX Q VALUE OF ORDER 24 IS 19.37 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(22). p-value= 0.6227

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0831	0.0167	-0.0505	-0.1474	0.1184	0.0119	-0.0494	-0.0266	0.1090	-0.1124	-0.0156	-0.0377
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	0.46	0.48	0.66	2.19	3.19	3.20	3.38	3.44	4.35	5.34	5.36	5.47
PV	-1.00	-1.00	0.42	0.33	0.36	0.52	0.64	0.75	0.74	0.72	0.80	0.86

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0238	0.3087	0.1720	-0.0421	-0.0874	-0.1980	-0.0531	0.0185	-0.1711	-0.0648	0.0836	-0.0409
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	5.52	13.57	16.12	16.27	16.96	20.56	20.82	20.86	23.73	24.16	24.88	25.05
PV	0.90	0.33	0.24	0.30	0.32	0.20	0.23	0.29	0.21	0.24	0.25	0.29

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0077	-0.0796	-0.0948	0.0929	0.1017	-0.0558	-0.0479	-0.0650	-0.1192	0.0792	-0.1220	-0.1213
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	25.06	25.76	26.79	27.80	29.05	29.44	29.73	30.29	32.22	33.11	35.27	37.49
PV	0.35	0.37	0.37	0.37	0.36	0.39	0.43	0.45	0.41	0.41	0.36	0.31

McLEOD-LI Q VALUE OF ORDER 24 IS 25.05 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.4029

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	YES
SPECTRAL EVIDENCE	-

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IMAE agropecuario de Honduras

MODEL FINALLY CHOSEN :

(0,1,1)(0,1,1) WITHOUT MEAN

OUTLIERS

83 AO (11 2012)

96 AO (12 2013)

ARMA PARAMETERS				
PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	-0.66376	0.75239E-01	-8.82	1
BTH	-0.38399	0.92882E-01	-4.13	12

ESTIMATES OF REGRESSION PARAMETERS CONCENTRATED OUT OF THE LIKELIHOOD

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (83)	0.86869E-01	(0.03496)	2.49	AO (11 2012)
OUT 2 (96)	0.65544E-01	(0.03565)	1.84	AO (12 2013)

RESIDUALS STATISTICS

MEAN	-0.0021489
ST.DEV.OF MEAN	0.0045362
T-VALUE	-0.4737221
NORMALITY TEST (CHI-SQUARE(2))	0.3306
SKEWNESS	-0.0353(SE = 0.2449)
KURTOSIS	3.2727(SE = 0.4899)
SUM OF SQUARES	0.2062342
DURBIN-WATSON	1.8481
STANDARD ERROR OF RESIDUALS	0.4587407E-01
MSE OF RESID.	0.2104430E-02

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0612	-0.0306	-0.0351	-0.1577	-0.0498	0.0518	-0.0385	-0.0441	-0.0297	-0.0115	0.1437	0.0704
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	0.39	0.48	0.61	3.25	3.52	3.81	3.97	4.19	4.29	4.30	6.67	7.25
PV	-1.00	-1.00	0.43	0.20	0.32	0.43	0.55	0.65	0.75	0.83	0.67	0.70

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0898	0.0374	-0.0337	0.1700	-0.0617	0.0126	-0.0466	-0.0061	-0.0035	-0.1589	-0.0995	-0.0251
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	8.19	8.36	8.49	12.00	12.47	12.49	12.76	12.77	12.77	16.07	17.38	17.47
PV	0.70	0.76	0.81	0.61	0.64	0.71	0.75	0.81	0.85	0.71	0.69	0.74

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0446	0.0850	0.1103	0.0108	-0.0655	0.0077	0.0072	-0.0430	-0.0208	-0.0817	-0.1084	-0.0282
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	17.74	18.73	20.43	20.45	21.07	21.07	21.08	21.36	21.43	22.46	24.30	24.43
PV	0.77	0.77	0.72	0.77	0.78	0.82	0.86	0.88	0.90	0.89	0.86	0.89

LJUNG-BOX Q VALUE OF ORDER 24 IS 17.47 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(22). p-value= 0.7371

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1736	-0.0818	-0.0943	-0.1126	-0.0942	-0.0665	0.1676	0.0556	-0.0573	-0.0932	-0.0099	0.1288
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	3.10	3.80	4.74	6.08	7.04	7.52	10.60	10.94	11.31	12.29	12.31	14.23
PV	-1.00	-1.00	0.03	0.05	0.07	0.11	0.06	0.09	0.13	0.14	0.20	0.16

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.1216	-0.0641	0.0016	-0.0546	-0.0171	-0.0376	-0.0307	0.0717	-0.0119	-0.0393	-0.0999	-0.0202
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	15.96	16.45	16.45	16.81	16.85	17.02	17.14	17.80	17.82	18.02	19.34	19.40
PV	0.14	0.17	0.23	0.27	0.33	0.38	0.44	0.47	0.53	0.59	0.56	0.62

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0538	0.0487	0.0704	-0.0748	-0.0979	-0.0952	-0.1247	0.0891	0.2248	0.1870	-0.0026	-0.0860
SE	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000	0.1000
Q	19.79	20.12	20.81	21.60	22.98	24.30	26.60	27.79	35.49	40.89	40.90	42.07
PV	0.65	0.69	0.70	0.71	0.69	0.67	0.59	0.58	0.26	0.13	0.16	0.16

McLEOD-LI Q VALUE OF ORDER 24 IS 19.40 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.7305

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	YES

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IMAE agropecuario de Nicaragua

MODEL FINALLY CHOSEN :

(1,0,1)(0,1,1) WITHOUT MEAN

WITH EASTER CORRECTION

OUTLIERS

35 TC (11 2008)

73 TC (1 2012)

99 AO (3 2014)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
PHI1	-0.85659	0.66149E-01	-12.95	1
TH1	-0.25232	0.12369	-2.04	1
BTH	-0.20009	0.96936E-01	-2.06	12

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
EAST1	-0.30956E-01	0.01264	-2.45	
OUT 1 (35)	-0.17453	(0.03295)	-5.30	TC (11 2008)
OUT 2 (73)	-0.14451	(0.03294)	-4.39	TC (1 2012)
OUT 3 (99)	0.92696E-01	(0.02999)	3.09	AO (3 2014)

RESIDUALS STATISTICS

MEAN	0.0044741
ST.DEV.OF MEAN	0.0042735
T-VALUE	1.0469292
NORMALITY TEST (CHI-SQUARE(2))	0.3595
SKEWNESS	0.0082(SE = 0.2462)
KURTOSIS	3.2947(SE = 0.4924)
SUM OF SQUARES	0.1809778
DURBIN-WATSON	2.2535
STANDARD ERROR OF RESIDUALS	0.4341872E-01
MSE OF RESID.	0.1885185E-02

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.1345	-0.0032	-0.0421	-0.0419	-0.0410	0.0558	0.0478	-0.0062	-0.1422	0.0539	-0.0285	-0.0910
SE	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005
Q	1.85	1.85	2.03	2.22	2.40	2.73	2.98	2.98	5.23	5.56	5.65	6.60
PV	-1.00	-1.00	-1.00	0.14	0.30	0.43	0.56	0.70	0.51	0.59	0.69	0.68

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0399	-0.0509	0.1227	-0.1084	0.0184	0.0396	-0.1079	0.0241	0.1903	-0.0414	0.0258	-0.1463
SE	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005
Q	6.79	7.09	8.88	10.30	10.34	10.53	11.99	12.06	16.70	16.93	17.01	19.87
PV	0.75	0.79	0.71	0.67	0.74	0.78	0.74	0.80	0.54	0.59	0.65	0.53

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.0400	0.1543	-0.0939	0.1047	-0.0036	-0.0243	-0.0711	0.0333	-0.0421	-0.0692	-0.0232	0.0997
SE	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005
Q	20.09	23.35	24.57	26.12	26.12	26.20	26.95	27.11	27.38	28.12	28.20	29.78
PV	0.58	0.44	0.43	0.40	0.46	0.51	0.52	0.57	0.60	0.62	0.66	0.63

LJUNG-BOX Q VALUE OF ORDER 24 IS 19.87 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(21). p-value= 0.5296

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	-0.0962	-0.0034	-0.0739	-0.0348	-0.0596	-0.1385	0.1080	-0.0860	-0.0379	0.0219	0.0078	0.1773
SE	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005
Q	0.94	0.94	1.51	1.64	2.02	4.08	5.35	6.16	6.32	6.38	6.38	10.00
PV	-1.00	-1.00	-1.00	0.20	0.36	0.25	0.25	0.29	0.39	0.50	0.60	0.35

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	-0.0553	0.0490	-0.0789	-0.0500	0.0044	-0.0742	0.2039	-0.0780	0.0745	0.0133	-0.0049	-0.1342
SE	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005
Q	10.35	10.63	11.38	11.68	11.68	12.36	17.56	18.32	19.04	19.06	19.06	21.46
PV	0.41	0.47	0.50	0.55	0.63	0.65	0.35	0.37	0.39	0.45	0.52	0.43

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.0185	-0.0105	-0.0701	-0.0090	-0.0103	-0.0482	0.1543	-0.0668	0.1309	-0.0916	0.0380	-0.0215
SE	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005	0.1005
Q	21.51	21.52	22.20	22.22	22.23	22.57	26.07	26.73	29.33	30.62	30.84	30.92
PV	0.49	0.55	0.57	0.62	0.68	0.71	0.57	0.59	0.50	0.49	0.52	0.57

McLEOD-LI Q VALUE OF ORDER 24 IS 21.46 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.6114

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	YES

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	NO

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el PIB trimestral agropecuario de Panamá

MODEL FINALLY CHOSEN :

(0,0,1)(0,1,1) WITHOUT MEAN

OUTLIERS

9 AO (1 2009)

ARMA PARAMETERS				
PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	0.34874	0.17253	2.02	1
BTH	0.43907	0.16540	2.65	4

ESTIMATES OF REGRESSION PARAMETERS				
PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (9)	-0.13637	(0.03248)	-4.20	AO (1 2009)

RESIDUALS STATISTICS	
MEAN	0.0025984
ST.DEV.OF MEAN	0.0113628
T-VALUE	0.2286743
NORMALITY TEST (CHI-SQUARE(2))	3.749
SKEWNESS	-0.6687(SE = 0.4549)
KURTOSIS	4.1465(SE = 0.9097)
SUM OF SQUARES	0.1087792
DURBIN-WATSON	1.6265
STANDARD ERROR OF RESIDUALS	0.6347329E-01
MSE OF RESID.	0.4028858E-02

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.0866	0.0489	0.0693	-0.2027	-0.1452	-0.1405	-0.3028	0.0417	-0.0040	0.0303	0.0523	0.0820
SE	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857
Q	0.24	0.32	0.49	1.97	2.75	3.53	7.27	7.35	7.35	7.39	7.53	7.89
PV	-1.00	-1.00	0.49	0.37	0.43	0.47	0.20	0.29	0.39	0.49	0.58	0.64

LJUNG-BOX Q VALUE OF ORDER 12 IS 7.89 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(10). p-value= 0.6400

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1991	-0.1693	0.4141	0.4802	-0.0008	-0.0567	0.1491	0.0101	-0.0359	-0.0695	-0.0947	-0.0700
SE	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857	0.1857
Q	1.27	2.23	8.16	16.45	16.45	16.57	17.48	17.49	17.54	17.77	18.22	18.48
PV	-1.00	-1.00	0.00	0.00	0.00	0.00	0.00	0.01	0.01	0.02	0.03	0.05

McLEOD-LI Q VALUE OF ORDER 12 IS 18.48 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(12). p-value= 0.1019

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	-

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : MILDLY POOR FIT

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	POOR
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Number of outliers	GOOD

Resultados del ajuste del modelo ARIMA para el IMAE agropecuario de la Región

MODEL FINALLY CHOSEN :

(0,1,1)(0,1,1) WITHOUT MEAN

OUTLIERS

62 TC (2 2014)

ARMA PARAMETERS

PARAMETER	ESTIMATE	STD ERROR	T RATIO	LAG
TH1	-0.38522	0.11526	-3.34	1
BTH	-0.35254	0.11688	-3.02	12

ESTIMATES OF REGRESSION PARAMETERS

PARAMETER	VALUE	STANDARD ERROR	T VALUE	
OUT 1 (62)	0.28544E-01	(0.01274)	2.24	TC (2 2014)

RESIDUALS STATISTICS

MEAN	-0.0010672
ST.DEV.OF MEAN	0.0020065
T-VALUE	-0.5318935
NORMALITY TEST (CHI-SQUARE(2))	1.023
SKEWNESS	-0.2715(SE = 0.3062)
KURTOSIS	2.7020(SE = 0.6124)
SUM OF SQUARES	0.1656297E-01
DURBIN-WATSON	1.7000
STANDARD ERROR OF RESIDUALS	0.1634456E-01
MSE OF RESID.	0.2671447E-03

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1388	0.0585	-0.1248	-0.1780	-0.1067	-0.0864	-0.0890	0.0245	-0.0834	-0.1040	-0.0476	0.0309
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	1.29	1.53	2.60	4.83	5.65	6.19	6.78	6.82	7.36	8.20	8.38	8.46
PV	-1.00	-1.00	0.11	0.09	0.13	0.19	0.24	0.34	0.39	0.41	0.50	0.58

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0298	0.0088	-0.0041	-0.0044	0.1452	0.1906	0.0253	-0.0749	-0.0604	-0.1567	-0.0200	-0.0308
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	8.53	8.54	8.54	8.54	10.44	13.77	13.83	14.37	14.73	17.20	17.24	17.34
PV	0.66	0.74	0.81	0.86	0.79	0.62	0.68	0.70	0.74	0.64	0.70	0.74

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	-0.1785	0.1240	-0.0794	0.0851	0.1030	0.0208	-0.0296	-0.0044	-0.0879	0.1541	0.1357	0.1582
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	20.79	22.50	23.22	24.07	25.35	25.40	25.52	25.52	26.57	29.92	32.60	36.37
PV	0.59	0.55	0.56	0.57	0.55	0.61	0.65	0.70	0.69	0.57	0.49	0.36

LJUNG-BOX Q VALUE OF ORDER 24 IS 17.34 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(22). p-value= 0.7443

SQUARED RESIDUALS

AUTOCORRELATIONS. Lags 1 To 12

	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5	Lag 6	Lag 7	Lag 8	Lag 9	Lag 10	Lag 11	Lag 12
ACF	0.1382	-0.0748	0.0970	0.0223	-0.1666	-0.1807	-0.1864	-0.0162	-0.1023	-0.0103	0.0992	0.0598
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	1.28	1.66	2.31	2.35	4.33	6.71	9.29	9.31	10.11	10.12	10.90	11.19
PV	-1.00	-1.00	0.13	0.31	0.23	0.15	0.10	0.16	0.18	0.26	0.28	0.34

AUTOCORRELATIONS. Lags 13 To 24

	Lag 13	Lag 14	Lag 15	Lag 16	Lag 17	Lag 18	Lag 19	Lag 20	Lag 21	Lag 22	Lag 23	Lag 24
ACF	0.0846	0.1004	0.0048	-0.2360	-0.1303	-0.0664	-0.1203	-0.0432	-0.1080	0.1054	0.0923	-0.0538
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	11.79	12.64	12.64	17.54	19.07	19.47	20.83	21.01	22.16	23.27	24.15	24.46
PV	0.38	0.40	0.48	0.23	0.21	0.24	0.23	0.28	0.28	0.28	0.29	0.32

AUTOCORRELATIONS. Lags 25 To 36

	Lag 25	Lag 26	Lag 27	Lag 28	Lag 29	Lag 30	Lag 31	Lag 32	Lag 33	Lag 34	Lag 35	Lag 36
ACF	0.1713	0.1535	-0.0719	0.0068	-0.0751	-0.1290	-0.0706	0.0513	0.0428	-0.0484	0.0293	0.2246
SE	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250	0.1250
Q	27.64	30.25	30.84	30.85	31.53	33.60	34.24	34.58	34.83	35.16	35.29	42.90
PV	0.23	0.18	0.19	0.23	0.25	0.21	0.23	0.26	0.29	0.32	0.36	0.14

McLEOD-LI Q VALUE OF ORDER 24 IS 24.46 AND IF RESIDUALS ARE RANDOM IT SHOULD BE DISTRIBUTED AS CHI-SQUARE(24). p-value= 0.4357

Overall test for identifiable seasonality

AUTOCORRELATION FUNCTION EVIDENCE	YES
NON-PARAMETRIC EVIDENCE	YES
F-TEST	-
SPECTRAL EVIDENCE	-

IDENTIFIABLE SEASONALITY FOUND IN SERIES

Overall test for seasonality in residuals

AUTOCORRELATION FUNCTION EVIDENCE	NO
NON-PARAMETRIC EVIDENCE	NO
F-TEST	NO
SPECTRAL EVIDENCE	-

NO IDENTIFIABLE SEASONALITY FOUND IN RESIDUALS

ARIMA MODEL : GOOD FIT

ALL TEST ARE PASSED

QUALITY ARIMA MODEL TESTS

Mean in residuals	GOOD
Autocorrelation in residuals	GOOD
Normality of residuals	GOOD
Skewness of residuals	GOOD
Kurtosis of residuals	GOOD
Randomness of residual sign	GOOD
Instability of residual mean	GOOD
Instability of residual variance	GOOD
Seasonality in residuals	GOOD
Trading day in residuals	GOOD
Out-of-sample forecast errors	GOOD
Number of outliers	GOOD