



COLEGIO DE POSTGRADUADOS

INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS AGRÍCOLAS

CAMPUS MONTECILLO

POSGRADO DE SOCIOECONOMÍA, ESTADÍSTICA E INFORMÁTICA
ECONOMÍA

“PREDICTOR DE PRECIOS DE MAÍZ EN MÉXICO”

JOSÉ DE JESÚS GARCÍA JUÁREZ

T E S I S

PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:

DOCTOR EN CIENCIAS

MONTECILLO, TEXCOCO, ESTADO DE MÉXICO

2017

La presente tesis titulada: “Predictor de Precios de Maíz en México”, realizada por el alumno: JOSÉ DE JESÚS GARCÍA JUÁREZ bajo la dirección del consejo particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

**DOCTOR EN CIENCIAS
SOCIOECONOMÍA, ESTADÍSTICA E INFORMÁTICA
ECONOMÍA**

CONSEJO PARTICULAR

CONSEJERO



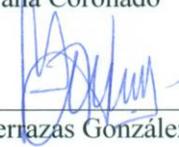
Dr. Miguel Ángel Martínez Damián

Asesor



Dr. José Jaime Arana Coronado

Asesor



Dr. Gerardo H. Terrazas González

Asesor



Dr. Daniel Barrera Islas

Asesor



Dra. Graciela M. Bueno Aguilar

Asesor



Dra. Mercedes Borja Bravo

Montecillo, Texcoco, Estado de México, Enero de 2017

PREDICTOR DE PRECIOS DE MAÍZ EN MÉXICO

**José De Jesús García Juárez, D.C.
Colegio de Postgraduados, 2017**

RESUMEN

Los mercados de futuros, entre sus funciones, proporcionan previsiones de precios de commodities (productos agrícolas y materias primas), lo que permite a los productores ajustar por anticipado su oferta. En México, los usuarios de coberturas de precios recurren, en su mayoría, a las bolsas de valores en los Estados Unidos, como la Bolsa de Futuros de Chicago (CBOT). No obstante, estos mercados podrían proporcionar previsiones inadecuadas de precios al comercializarse coberturas de productos estandarizados. El objetivo de este trabajo es construir un modelo predictor del precio esperado de maíz que respresente una alternativa de previsión de precios para la toma de decisiones por parte de productores y comercializadores de maíz blanco en México. Para el estudio se construyen predictores, bajo la metodología de series de tiempo, tales como los modelos ARIMA, VAR y VCE que son comparados y discriminados estadísticamente a fin de determinar el mejor predictor que cumpla con la función de previsión de precios. Los resultados indican que los modelos VAR y VCE proporcionan mejores predicciones frente a los modelos ARIMA que resultan subóptimos al no incluir información de Estados Unidos.

Palabras clave: ARIMA, previsión de precios, serie de tiempo, VAR, VCE.

CORN PRICE PREDICTOR IN MÉXICO

**José De Jesús García Juárez, D.C.
Colegio de Postgraduados, 2017**

ABSTRACT

Futures markets, among its functions, provide forecasts of commodity prices, allowing producers to adjust their offer in advance. In Mexico, users resort to price hedging securities exchanges, mostly, to the stock exchanges in the United States, as the Chicago Futures Exchange (CBOT). However, these markets could provide inadequate forecasts coverage price of standardized products marketed. The objective of this work is to construct a predictive model of the expected price of corn that represent an alternative of forecasting prices for the decision making by the producers and traders of white corn in Mexico. For the study predictors are built, under the methodology of time series, such as ARIMA, VAR and VCE models are compared and discriminated statistically to determine the optimal predictor that meets the price forecast function. The results indicate that the VAR and VCE models produce better predictions compared to ARIMA models which are sub-optimal because not include information from the United States.

Keywords: ARIMA, price forecast, time series, VAR, VCE.

AGRADECIMIENTOS ACADÉMICOS

A mi Consejero, Dr. Miguel Ángel Martínez Damián, por dirigir este trabajo, así como, su asesoría y apoyo en todo momento; y por los conocimientos y consejos brindados durante mi formación académica.

A mis asesores de tesis, Dr. José Jaime Arana, Dra. Mercedes Borja Bravo, Dr. Daniel Barrera Islas, Dra. Graciela M. Bueno Aguilar y Dr. Gerardo H. Terrazas, por su apoyo y asesoría para la realización de la investigación y mi formación académica.

Al Consejo Nacional de Ciencia y Tecnología, (CONACYT), por el apoyo económico brindado para poder realizar mis estudios a través del Programa de Fomento, Formación, Desarrollo y Vinculación de Recursos Humanos de Alto Nivel.

Al Colegio de Posgraduados, por brindarme la oportunidad de realizar mis estudios de posgrado, así como, proporcionarme la capacitación necesaria en la realización de la presente investigación.

AGRADECIMIENTOS PERSONALES

A mi familia, en especial a mis padres; Jesús y Nena, mis hermanos Miriam, Jaír y Carlos, por todo su amor y apoyo incondicional.

A Andrea por su apoyo y cariño.

A mis amigos y compañeros de escuela y de vida.

A mi equipo fiel G3, a mi equipo USANA y en general a todas las personas con las que he compartido proyectos y trabajo en equipo.

CONTENIDO

CAPITULO I: INTRODUCCIÓN

1.1 Introducción.....	1
1.2 Objetivo General.....	3
1.3 Objetivos Específicos.....	3
1.4 Hipótesis.....	3

CAPITULO II: SITUACIÓN ACTUAL DEL MAÍZ

2.1 El Mercado Internacional de Maíz.....	4
2.2 La Importancia del Maíz en México.....	6
2.3 El Mercado Nacional de Maíz.....	7
2.4 Producción y Comercialización Agrícola en México.....	9

CAPITULO III: EL PREDICTOR DE PRECIOS Y LA HIPÓTESIS DE EFICIENCIA

3.1 Predictor de Precios.....	11
3.2 Mercados Spot, Futuros y Opciones.....	11
3.2.1 Función y Características del Mercado de Futuros y Opciones.....	12
3.3 La Hipótesis de Eficiencia Aplicada al Mercado de Futuros.....	13

CAPITULO IV: ENFOQUE TEÓRICO METODOLÓGICO Y MATERIALES

4.1 Construcción de las Series de Precios.....	15
4.2 Regresiones Espurias.....	16
4.3 Estacionariedad, Prueba de Raíz Unitaria y Cointegración.....	17
4.3.1 Prueba Dickey-Fuller (DF) y Dickey-Fuller Aumentada (ADF).....	19
4.3.2 Cointegración de Variables I(1).....	20
4.3.3 Análisis de Cointegración. Método de Johansen.....	21

4.4 Metodología de Series de Tiempo.....	22
4.4.1 Metodología de Box y Jenkins (Modelos AR, MA, ARMA o ARIMA).....	23
4.4.2 Modelos de Vectores Autorregresivos (VAR).....	24
4.4.3 Modelos Vectoriales de Corrección del Error (VCE).....	25
4.5 Capacidad Predictiva de los Modelos.....	28
 CAPITULO V: ANÁLISIS DE RESULTADOS Y DISCUSIÓN	
5.1 Especificación de los Modelos Box y Jenkins.....	30
5.2 Raíces Unitarias.....	31
5.3 Contraste de Cointegración.....	32
5.4 Especificación de los VAR y VCE.....	32
5.5 Evaluación de los Modelos de Predicción.....	34
5.6 Discusión.....	39
 CAPITULO VI: CONCLUSIONES	
6.1 Conclusiones.....	40
LITERATURA CITADA.....	41
ANEXOS.....	44

LISTA DE CUADROS Y FIGURAS

Cuadro 1. Contexto nacional del maíz blanco.....	7
Cuadro 2. Estadísticos de los Modelos ARIMA.....	30
Cuadro 3. Raíces Unitarias.....	31
Cuadro 4. Contraste de Cointegración.....	32
Cuadro 5. Modelos VAR y VCE.....	33
Cuadro 6. Evaluación de los Modelos de Predicción.....	34
Figura 1. Principales Países Exportadores e Importadores de Maíz (2014/15 – 2015/16).....	5
Figura 2. Comparativo de los modelos en la predicción fuera de muestra.....	35
Figura 3. Gráficos de las Series de Tiempo vs Modelos de Predicción.....	36

1. INTRODUCCIÓN

A nivel mundial el maíz es el commodity agrícola que más se produce. Debido a sus cualidades alimenticias para la producción de proteína animal, el consumo humano y el uso industrial se ha convertido en uno de los productos más importantes en los mercados internacionales (FIRA, 2015). En México, su volumen de producción y consumo, así como, la superficie sembrada y número de productores revelan que es el maíz el cultivo más importante de todo el sector agrícola.

Uno de los problemas que más les preocupa a los productores agrícolas es la incertidumbre respecto a las variaciones futuras del precio del producto que eligen cultivar. La expectativa de precio que asumen los productores al momento de la siembra es decisiva para determinar el tipo de producto y la superficie a sembrar. En las últimas dos décadas, con el fin de protegerse de los altibajos en las cotizaciones de los principales cultivos, en casi todo el mundo se hace uso de instrumentos financieros, (ASERCA, 2010). Los contratos de futuros, conocidos comúnmente sólo como futuros, son instrumentos financieros mediante los cuales las partes involucradas acuerdan llevar a cabo en una fecha futura, la compra-venta de un producto a un precio estipulado, evitando con ello, el riesgo por fluctuaciones en los precios. El precio pactado entre las partes refleja la expectativa de valor que creen que tendrá el precio en el futuro, es decir, el precio futuro del mercado. De esta manera, los mercados de futuros cumplen 2 funciones importantes; por un lado, facilitan la administración de riesgo por variaciones de precio, y, por otro, proporcionan previsiones de precios de esos productos. Las previsiones de precios de productos básicos y materias primas (commodities) permiten a los productores ajustar por anticipado su oferta. En México, dado que no existe un mercado de futuros para commodities, los usuarios de coberturas de precios recurren a las bolsas de valores en otros países principalmente en los Estados Unidos, como la Bolsa de Futuros de Chicago (CBOT). Sin embargo, aun cuando estas coberturas cubren el riesgo por variación de precios de los commodities; no proporcionan previsiones adecuadas de precios al comercializarse coberturas de productos estandarizados.

En este trabajo, con el objetivo de que productores y comercializadores de maíz blanco en México, puedan contar con una herramienta de previsión de precios para la toma de decisiones, se construyen modelos predictores bajo la metodología de series de tiempo. Los modelos utilizados

son; un modelo construido bajo la metodología Box y Jenkins (AR, MA, ARMA o ARIMA), un Vector Autorregresivo (VAR) y un Vector de Corrección de Errores (VCE). El procedimiento empleado para determinar en cada Estado el modelo predictor de precios a utilizar dentro de las 3 categorías fue, primeramente, validar cada uno de los modelos especificados. Como segundo paso, una vez elegido el modelo de cada categoría se procedió a llevar a cabo la predicción de precios. Finalmente, con el objetivo de determinar el mejor modelo predictor de precios que les permita a productores y comercializadores llevar a cabo una mejor planeación y control sobre sus cultivos, se evaluó la capacidad predictiva de los modelos discriminándolos conforme a los resultados de 2 estadísticos: la raíz del error cuadrático medio (RECM) y el Coeficiente de desigualdad de Theil (CDT).

Fama (1970 y 1991) sostiene que de acuerdo a la hipótesis de mercado eficiente, el precio futuro es un predictor insesgado del precio spot para un periodo y lugar dado. Con información de precios en el periodo 2000 al 2015 de los principales estados productores en México, la hipótesis del estudio sugiere que el modelo predictor del precio físico promedio mensual de maíz blanco que no incluya información de los mercados físicos y de futuros de los Estados Unidos es subóptimo.

1.2. Objetivo General:

Construir un modelo predictor del precio esperado de maíz blanco que respresente una alternativa de previsión de precios para la toma de decisiones por parte de productores y comercializadores de maíz blanco en México.

1.3. Objetivos Específicos:

Determinar el mejor modelo predictor de precios futuros de maíz a partir de la evaluación de su desempeño de precisión mediante la comparación de los estadísticos; Raíz del Error Cuadrático Merdido (RECM) y el Coeficiente de Desigualdad de Theil (CDT).

Construir un modelo predictor de precios de maíz, con un rango de error de +/- 5%, que sirva como una herramienta alternativa de previsión de los precios futuros.

Examinar si la hipótesis del mercado eficiente se cumple para el caso del intercambio comercial de maíz entre México y Estados Unidos.

1.4. Hipótesis

Mediante la metodología de series de tiempo, es posible construir un modelo predictor del precio físico promedio mensual de maíz blanco para los principales estados productores en México como: Sinaloa, Jalisco, Estado de México, Michoacán y Guanajuato con una precisión de +/- 5%.

2. SITUACIÓN ACTUAL DEL MAÍZ

2.1. El Mercado Internacional de Maíz

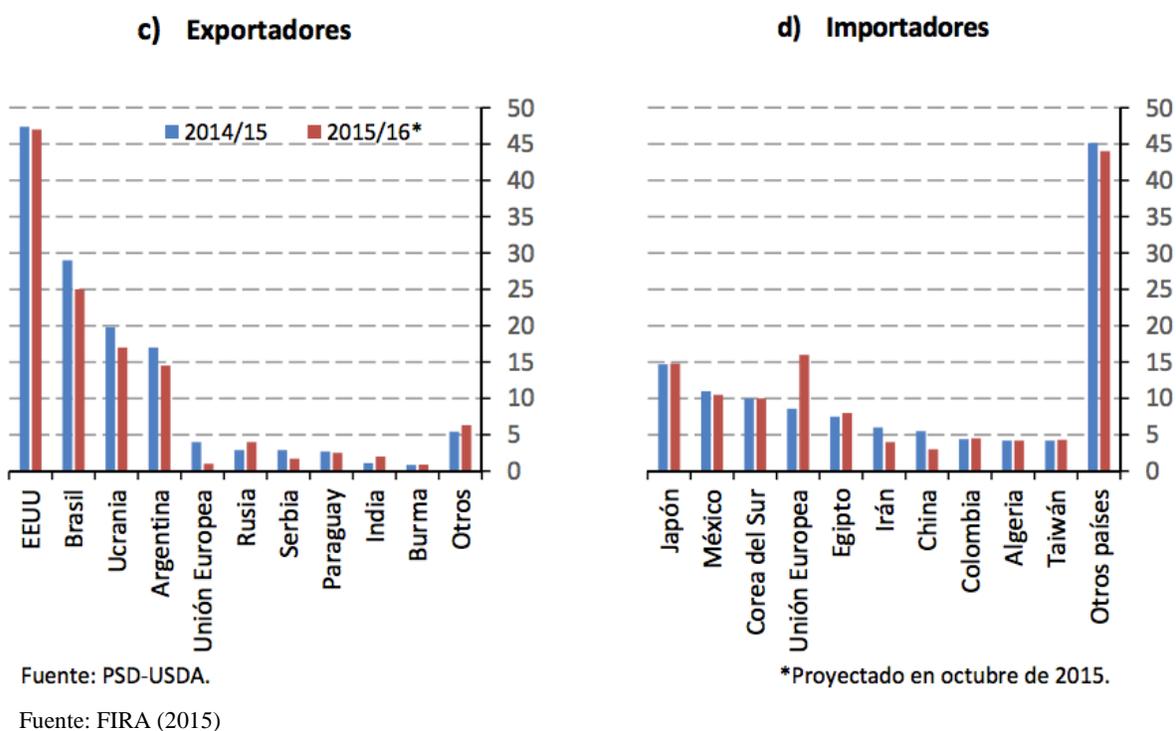
El maíz es el commodity agrícola que más se produce en el mundo. Debido a sus cualidades alimenticias para la producción de proteína animal, el consumo humano y el uso industrial se ha convertido en uno de los productos más importantes en los mercados internacionales. Actualmente, el mercado mundial de maíz atraviesa un periodo de recuperación, la producción, consumo e inventarios finales del grano presentaron niveles récord durante el ciclo 2014/15. En los últimos años el dinamismo de la producción y consumo mundial ha provocado una acumulación de inventarios importante para los últimos ciclos comerciales. Durante el ciclo comercial 2014/15 se observó el nivel de producción mundial más alto de la historia, al totalizar 1,009 millones de toneladas. Dicho volumen de producción se explica por los volúmenes de producción récord obtenidos en los principales países productores, Estados Unidos, Brasil y la Unión Europea. Por ejemplo, el volumen de producción histórico alcanzado en 2014/15 derivó de una superficie cosechada de 178.8 millones de hectáreas y rendimientos promedio de 5.64 toneladas por hectárea, mismos que se ubican como el rendimiento más alto de la historia. Las exportaciones mundiales de maíz observaron un incremento significativo durante los últimos ciclos comerciales, ante la marcada disponibilidad del grano. No obstante, la producción estimada para el ciclo 2015/16 en los principales países productores se ubica a la baja, con excepción de la producción en China, la cual se estima crecerá en 4.3% (FIRA, 2015).

Actualmente, el consumo mundial de maíz continúa creciendo de manera sostenida impulsado por crecimientos tanto en el consumo forrajero como en el consumo humano e industrial. Entre los ciclos comerciales 2004/05 y 2014/15 el consumo total del grano ha crecido a una tasa media anual de 3.6 por ciento; desagregado por tipo de consumo, el consumo forrajero ha crecido a una tasa media anual de 2.3 por ciento mientras que el consumo humano e industrial ha crecido 4.9 por ciento en promedio en el mismo periodo.

Ocho países concentran el 75.6 por ciento del consumo total mundial, entre los que se encuentran por orden de importancia; Estados Unidos, China, Unión Europea, Brasil, México, India, Japón y Egipto. Considerando la evolución y expectativas de la producción y consumo de maíz durante los

últimos ciclos comerciales, se observa una marcada recuperación en los inventarios finales mundiales del grano de los principales países productores y consumidores (FIRA, 2015). La composición de los principales países exportadores e importadores se muestra en la **Figura 1**.

FIGURA 1
PRINCIPALES PAÍSES EXPORTADORES E IMPORTADORES DE MAÍZ
(2014/15 – 2015/16)
(Millones de Ton)



En relación al precio internacional del maíz, este se ve reflejado a través del contrato de maíz amarillo no. 2 FOB (free-on-board) puesto en el Golfo que cotiza en la bolsa de valores de Chicago (Chicago Mercantile Exchange). Así, el contrato de maíz amarillo FOB en el Golfo refleja los fundamentales actuales del mercado, pues muestra de un nivel de cotización deprimido por la amplia disponibilidad del grano en Estados Unidos y el mundo. Los futuros de maíz amarillo con vencimientos en diciembre-15, marzo-16 y mayo-16 presentan un nivel de precios por debajo del precio spot, lo cual refleja una amplia disponibilidad en el mercado en el corto y mediano plazo (FIRA, 2015).

2.2. La Importancia del Maíz en México

El maíz es el cultivo más importante de México por varias razones: el consumo por persona es 6 veces mayor que el promedio mundial y se eleva lentamente (OCDE, 2007), para 2015 se produjeron alrededor de 24.7 millones de toneladas de maíz grano en una superficie aproximada de 7.6 millones de hectáreas. Alrededor del 90 por ciento de la producción es de maíz blanco y se destina al consumo humano (SIAP, 2016). México es el principal productor de maíz blanco en el mundo con una participación de alrededor del 40% de la oferta total. Asimismo, éste es el cultivo más importante del país ya que representa aproximadamente el 35% de la superficie sembrada durante un año agrícola, tanto para cultivos cíclicos como perennes. Además, se consumen anualmente alrededor de 20 millones de toneladas de maíz (SAGARPA, 2011).

La producción de maíz grano en México presenta una marcada recuperación a partir del año agrícola 2011, cuando la producción cayó a su nivel más bajo de los últimos 10 años (FIRA, 2015). Durante el año 2015 la producción de maíz alcanzó los 24.7 millones de toneladas, cifra que representa un incremento del 23% a la registrada en el año 2001 (**Cuadro 1**). El rendimiento promedio de este cultivo del año 2000 al 2015 se ubica en 3.02 ton./ha. cifra superior en 22% a la observada en el año 2000 (SIAP, 2016).

En el año 2015 México pasó a ser el séptimo productor de maíz en el mundo. Aunque se cubre prácticamente la totalidad de la demanda de maíz blanco con la producción nacional, el país es deficitario en maíz amarillo, que tiene diversos usos, principalmente pecuario. Los requerimientos de importación han ido fluctuando a la alza año con año, por ejemplo, en el año 2008 se importaban 9.2 millones de toneladas, mientras que para el año 2015 las importaciones fueron de 11.9 millones de toneladas de maíz provenientes de Estados Unidos (ITA-DOC, 2016).

CUADRO 1

CONTEXTO NACIONAL DEL MAÍZ BLANCO

Año	Producción/ ¹	Superficie/ ²		Rendimiento	Precio medio rural/ ³
		Sembrada	Cosechada		
2000	17.56	8.44	7.13	2.46	1495.52
2001	20.13	8.40	7.81	2.58	1488.01
2002	19.30	8.27	7.12	2.71	1553.31
2003	20.70	8.13	7.52	2.75	1644.66
2004	21.69	8.40	7.70	2.82	1699.62
2005	19.34	7.98	6.61	2.93	1639.23
2006	21.89	7.81	7.29	3.00	2173.52
2007	23.51	8.12	7.33	3.21	2451.96
2008	24.41	7.94	7.34	3.32	2817.04
2009	20.14	7.73	6.22	3.24	2802.05
2010	23.30	7.86	7.15	3.26	2816.48
2011	17.63	7.75	6.07	2.91	4077.81
2012	22.07	7.37	6.92	3.19	4009.63
2013	22.66	7.49	7.10	3.19	3365.77
2014	23.27	7.43	7.06	3.30	3115.96
2015	24.69	7.60	7.10	3.48	3422.84

Fuente: Elaboración propia con base en datos del SIAP (2016).
/1 Millones de Ton, /2 Millones de Ha, /3 Pesos por Ton.

De acuerdo a la balanza de disponibilidad de maíz (SIAP 2010), cerca de la tercera parte (29.2%) del maíz blanco es de autoconsumo, independientemente de esta proporción, un 50.3% se destina al consumo humano. El principal proveedor de maíz grano requerido por México es Estados Unidos. El sector pecuario ha sido el principal beneficiario de las importaciones de maíz amarillo (64.3%), seguido de la industria almidonera con casi la cuarta parte del total (24.9%).

2.3. El Mercado Nacional de Maíz

El maíz es el cultivo nacional presente en todos los estados, los climas y en todas las altitudes. Se siembran diversas variedades y se consume de distintas formas. Es el principal cultivo tanto por la superficie que se siembra como por el volumen de producción que se obtiene. En México ningún otro cultivo tiene tanta importancia como el maíz. Desde la perspectiva productiva, se ubica como el principal cultivo en comparación con el sorgo, trigo, cebada, arroz y avena, los cereales más

cultivados en el territorio mexicano. El maíz grano representa 85% del volumen nacional de cereales y 2.8 de la producción mundial (SAGARPA, 2013).

En México existen dos ciclos productivos en el cultivo del maíz: el de primavera-verano (PV) y el de otoño-invierno (OI). El periodo de siembras, tanto de riego como de temporal, se concentra en los meses de junio y julio para el ciclo PV y de noviembre a enero para el ciclo OI.

En el ciclo primavera-verano (PV), los principales estados productores son: Jalisco, Estado de México, Michoacán, Guanajuato y Chiapas; cuya producción se cosecha en los meses de octubre a diciembre.

En el ciclo otoño-invierno (OI), la producción se concentra fundamentalmente en los estados del norte del país como Sinaloa, Sonora y Chihuahua; cuya cosecha de este ciclo se realiza durante los meses de marzo y julio.

De acuerdo a la Encuesta Nacional Agropecuaria (ENA) del 2014 se reportó una superficie de 109.3 millones de hectáreas de las unidades de producción a nivel nacional; sin embargo, sólo 4 de cada 10 hectáreas se destinan a la producción de alimentos, sea para consumo humano o para la alimentación de animales domésticos. De esta superficie, el 24 % está ocupada por maíz blanco, de la cual se obtiene una producción anual de 21.1 millones de toneladas. Con esto, se estima que cada habitante de México cuenta para su consumo, con 188 kilogramos al año de este grano, lo que equivale a poco más de medio kg por día, considerando diferentes presentaciones como son harinas, tortillas y botanas, entre otras. El frijol y el maíz representan la base de la alimentación de los mexicanos. Anualmente, los productores de frijol obtienen 1.4 millones de toneladas, de 1.9 millones de hectáreas que se siembran en el territorio nacional. A partir de las variables de producción y población total, se observa que cada habitante consume en promedio 12.8 kg de frijol al año.

Según cifras oficiales de la SAGARPA (2015), entre los principales estados productores de maíz de los últimos 15 años se encuentran: Sinaloa, Jalisco, Estado de México, Michoacán y

Guanajuato, cuyo promedio anual en conjunto supera el 50% de la producción nacional de maíz. Desde hace 10 años, el estado de Sinaloa ha sido el mayor productor de este grano.

De acuerdo a la información del SNIIM (Sistema Nacional de Información e Integración de Mercados) de la Secretaría de Economía, los 3 principales estados productores de maíz en México distribuyen su producción a través de las centrales de abasto de sus principales ciudades. Sin embargo, la producción excedente se comercializa en el resto del país. Sinaloa satisface la demanda principalmente de las centrales de abasto de Coahuila, Durango, Querétaro, Oaxaca, San Luis Potosí, Aguascalientes, Distrito Federal, Puebla y Yucatán; Jalisco abastece a las centrales de abasto de Baja California, Baja California Sur, Querétaro, San Luis Potosí, Nayarit y Aguascalientes; el Estado de México abastece principalmente a la central de abasto del Distrito Federal.

2.4. Producción y Comercialización Agrícola en México

Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), la producción de alimentos a cielo abierto en países como México depende en gran medida de la cantidad disponible de tierra arable y cultivos perennes establecidos, a nivel mundial México ocupa el lugar decimotercero, con una superficie de 25.6 millones de hectáreas.

En tecnología, el 72.6% de unidades de producción en México cuenta con menos de 5 hectáreas tecnificadas.

Los productores nacionales solos o aislados, con un promedio nacional 8 hectáreas, no pueden lograr economías de escala para disminuir sus costos de producción, como la compra de insumos, realizar análisis de suelo y planta para una nutrición más balanceada, contratar asistencia técnica productiva, adquirir maquinaria y equipo; tampoco, ofrecerle al mercado el volumen y, en muchas ocasiones, la calidad requerida (FIRA, 2015)¹.

¹ En total, la agricultura es la industria que emplea a la mayor cantidad de personas a nivel mundial, con más de 1,000 millones de trabajadores, aunque el porcentaje del empleo total del sector ha disminuido en las últimas dos décadas desde el 45 por ciento hasta alrededor del 34 por ciento en la actualidad. En muchos países en desarrollo el porcentaje es mucho mayor. Por ejemplo, en India, más del 60 por ciento de la población activa del país participa de algún tipo

El proceso de comercialización del maíz y de los cultivos básicos en general en México, ha sufrido cambios relevantes en las últimas dos décadas. Con el fin de protegerse de los altibajos de las cotizaciones, en casi todo el mundo, se hace uso de instrumentos financieros, que se negocian en bolsas de futuros organizadas, para administrar los riesgos del mercado, permitiendo evitar pérdidas o maximizar ganancias (ASERCA, 2010).

En México, desde hace más de dos décadas ASERCA² ha venido implementando distintos esquemas de cobertura de precios para productores, comercializadores y consumidores nacionales de Maíz y otros productos agropecuarios. El objetivo de estos programas es proteger el ingreso esperado de los productores y/o el costo de compra de productos agropecuarios, así como, fomentar una cultura financiera de administración de riesgos comerciales en el sector. Las "coberturas de precios" son operadas con instrumentos del mercado de futuros, principalmente opciones, que son colocadas en los mercados de futuros de Chicago Board of Trade (CBOT - Bolsa de Comercio de Chicago) y Chicago Mercantile Exchange (CME - Bolsa Mercantil de Chicago)³, su funcionamiento es como un "seguro" contra movimientos adversos en los precios. De esta manera, los poseedores de estos instrumentos financieros tienen la alternativa de vender o comprar un contrato a futuro al precio de ejercicio durante la vigencia de la opción (ASERCA, 2016).

de actividad agrícola, y en Mali, el 83 por ciento de los trabajadores depende de la agricultura para cubrir parte o el total de sus ingresos (ASERCA, 2014).

² ASERCA (Apoyos y Servicios a la Comercialización Agropecuaria) se creó en 1991 con el objetivo de compensar temporalmente las asimetrías en los apoyos y las condiciones de producción de los competidores extranjeros.

³ Después de la fusión entre Chicago Board of Trade y Chicago Mercantile Exchange, realizada en 2007, se le ha denominado CME Group Inc.

3. EL PREDICTOR DE PRECIOS Y LA HIPÓTESIS DE EFICIENCIA

3.1. Predictor de Precios

Un predictor de precios es una función o variable aleatoria que asigna un valor monetario (precio), al resultado del comportamiento de otras variables y sus componentes. La predicción estadística de datos y series de datos temporales es un proceso de estimación realizada a través de modelos econométricos causales o de series de tiempo. Para determinar la calidad o eficacia del modelo predictor se hace uso de métricas de precisión que indican el grado de cercanía entre el valor estimado y el valor real.

3.2. Mercados Spot, Futuros y Opciones

Un **mercado spot** es una transacción de compra-venta de un producto tangible, para un envío inmediato que se realiza mediante un “CONTRATO DE FÍSICOS” (CASH), cuyos términos son acuerdos que se establecen entre comprador y vendedor en forma privada y fuera de bolsa. Por otro lado, un **mercado de futuros** es una transacción de mercancías estandarizada en calidad y cantidad, cuyas operaciones se realizan en la bolsa, que es el organismo que controla y autoriza el buen manejo de las operaciones, mismas que se liquidan sin consentimiento de la contraparte, con la entrega física de las mercancías en lugares específicos y en plazos preestablecidos (FIRA, 2011).

Los mercados de futuros existen para facilitar la transferencia de riesgos financieros, lo cual es utilizado por algunos miembros de la comunidad Bancaria. Particularmente, los prestamistas agropecuarios se han enfocado en el uso de los **mercados de futuros y opciones** para desarrollar mejores métodos de administración de riesgo. El factor riesgo crece en importancia a medida que el mundo se expone a la creciente volatilidad de precios y tasas de interés fluctuantes. La industria agrícola de los Estados Unidos ha aprendido quizás mejor que cualquier otra, a manejar la incertidumbre, pero en los últimos años se ha acentuado esta incertidumbre y esto se debe en parte

a los efectos de la inflación y a la emergencia de un mercado global para las mercancías agropecuarias (FIRA, 2011).

Un mercado de opciones es un convenio para comprar y vender “CONTRATOS” a un precio y a una fecha específica. Las opciones funcionan como un seguro que protege a quien las adquiere sobre movimientos adversos en los precios; al adquirir una opción se paga una “PRIMA” con lo que se asegura un precio tope que puede ser “PISO” o “TECHO”, además de que el riesgo máximo es igual al monto de la prima (FIRA, 2011).

3.2.1. Función y Características del Mercado de Futuros y Opciones

Las Bolsas de Futuros, independientemente de como estén organizadas y administradas, existen porque proporcionan dos funciones económicas vitales en el mercado, la determinación de los precios y la transferencia del riesgo (FIRA, 2011). Por su funcionamiento y estructura estos mercados alcanzan tres objetivos económicamente importantes: En primer lugar son una aproximación muy cercana a los mercados perfectamente competitivos. En segundo lugar son un sistema eficiente para el manejo del riesgo asociado a las oscilaciones de precios de determinados productos mediante la transferencia de ese riesgo a terceros. Finalmente, al existir un importante volumen de transacciones y, por ende, ser sumamente líquidos; se convierten en un punto importante de concentración y propagación de información pública sobre las perspectivas a futuro del precio de cierto producto, colaborando con la toma de decisiones de los agentes.

La función de la administración de riesgos es en esencia un método racional y sistemático para entender los riesgos, medirlos y controlarlos en un entorno en el que prevalecen instrumentos financieros sofisticados, mercados financieros que se mueven con gran rapidez y avances tecnológicos en los sistemas de información. Con la ayuda de la administración de riesgos no sólo se convierte la incertidumbre en oportunidad, sino que se evita el suicidio financiero y las catástrofes de graves consecuencias (De Lara, 2003).

En lo referente a la eficiencia de los mercados de futuros, estos mercados sirven para reducir o compensar las fuentes potenciales de desequilibrio y/o ineficiencia del mercado de bienes ya que

los precios futuros se hacen observables, con lo que el mercado spot encuentra su equilibrio más rápidamente y con una asignación más eficiente. En una economía que cuenta solamente con mercados spot es necesario reproducir varias veces la información relevante del mercado para que los agentes la incorporen en sus decisiones presentes y planes a futuro. En cambio, en una economía que cuenta además con mercados de futuros se publica la información diaria sobre precios futuros (que puede ser privada) y de esta manera los agentes incorporan inmediatamente dicha información en sus decisiones presentes y futuras (Díaz y Venegas, 2001).

3.3. La Hipótesis de Eficiencia Aplicada al Mercado de Futuros

Es posible decir que un mercado de valores es eficiente cuando la competencia entre los distintos agentes económicos que intervienen en el mismo (inversores), son guiados por el principio del máximo beneficio, lo que conduce a una situación de equilibrio en la que el precio de mercado de cualquier título constituye una buena estimación de su valor intrínseco (Fama, 1970).

Para Fama el mercado se comporta como un juego equitativo o juego limpio en el que los precios reflejan completa e instantáneamente toda la información disponible; de modo que los inversores no deberán preocuparse por la valoración de los títulos, puesto que éstos estarán perfectamente valorados. No obstante, el hecho de que el mercado recoja toda la información disponible no significa que todos los que intervienen en el mismo estén informados de todo y sepan interpretar toda la información y determinar sus consecuencias, sino que lo que se resalta es el comportamiento agregado del mercado.

La “paradoja del mercado eficiente” consiste en que para que los agentes económicos se comporten de forma eficiente, es necesario que no crean en la eficiencia del mercado, de modo que traten de descubrir la existencia de ineficiencias. Esa actuación provoca que éstas desaparezcan, empujando los precios hacia su valor objetivo y con ello a la eficiencia del mercado.

El concepto de **eficiencia aplicado al mercado de futuros** no dista del concepto aplicado con anterioridad para el mercado de capitales. Se considera un mercado eficiente, desde el punto de

vista de la información, si utiliza toda la información disponible para la fijación de precios futuros. La idea intuitiva detrás de esta definición es que los inversores procesan la información que está disponible y toman posiciones en respuesta, tanto a esa información como a sus preferencias específicas. El mercado realiza la agregación de la información y la refleja en el precio (Palma, 2004).

El que un mercado de futuros sea eficiente desde el punto de vista de la información, implica que es posible obtener beneficios positivos negociando sobre la base de dicha información.

El papel de los **precios futuros como predictores de los precios al contado** esperados en el futuro, fue analizado por Samuelson, para quien bajo ciertos supuestos la secuencia de precios futuros de un contrato de futuros dado sigue una martingala; en otras palabras, los precios futuros corrientes son los mejores predictores insesgados de los precios futuros de mañana. Y por otro lado, a consecuencia de que el arbitraje iguala al vencimiento del contrato de futuros los precios al contado y a futuros, los precios futuros son también los mejores predictores insesgados (estimador insesgado) del precio spot futuro (Samuelson, 1965) citado en (Palma, 2004).

4. ENFOQUE TEÓRICO METODOLÓGICO Y MATERIALES

4.1. Construcción de las Series de Precios

La información empleada en el estudio consistió en promedios mensuales de los precios semanales de maíz blanco⁴ que fueron obtenidos del portal de información en internet del Sistema Nacional de Información e Integración de Mercados (SNIIM), los datos del precio internacional⁵ y precio futuro de maíz amarillo⁶, se obtuvieron del portal en internet del Departamento de Agricultura de los Estados Unidos (USDA). El periodo de análisis fue de enero de 2000 a agosto de 2015. Para el cálculo en pesos del precio internacional y precio futuro de maíz amarillo, se utilizó el promedio mensual del tipo de cambio fix diario peso-dólar que se obtuvo del sitio web del Banco de México (Banxico).

Las series de precios mensuales de maíz blanco representan a los principales estados productores de maíz en México, los datos considerados corresponden al promedio mensual de los precios semanales frecuentes al mayoreo de las centrales de abasto de Culiacán (Sinaloa), Guadalajara (Jalisco), Ecatepec (Estado de México), Morelia (Michoacán) y León (Guanajuato), resultando en un tamaño de muestra de 188 observaciones para cada modelo correspondiente a cada estado. Para la evaluación del desempeño de los modelos de series temporales de tipo ARIMA, se eligió un modelo de al menos 8 que se formularon para cada uno de los principales estados productores de maíz, identificando el de mejor desempeño mostrado a través de sus estadísticos de prueba y precisión. La selección de los modelos VAR y VEC, para cada uno de los estados, después de llevar a cabo las pruebas de raíz unitaria y de cointegración; se realizó de acuerdo a la prueba estandar de exclusión de rezagos.

⁴ Precios semanales de maíz blanco en pesos por kilogramo comercializado en bultos de 50 kg.

⁵ Precios mensuales de maíz amarillo (U.S. No. 2 Yellow), FOB Gulf of Mexico, en dólares por tonelada métrica.

⁶ Precios promedio mensuales de liquidación de los contratos cercanos de futuros de maíz comercializados por año, en dólares por bushel.

4.2. Regresiones Espurias

La regresión de una variable de serie de tiempo sobre una o más variables de series de tiempo, frecuentemente puede dar resultados sin sentido o espurios. Este fenómeno se conoce como regresión espuria (Gujarati, 2004).

Las regresiones espurias o "sin sentido" se obtienen cuando, aún no existiendo relación real alguna entre las variables involucradas en el modelo propuesto (generalmente series temporales), la correlación obtenida entre ellas aparece como alta, de modo que las pruebas estadísticas y el R^2 del ajuste indican, equivocadamente, que el modelo es estadísticamente correcto. El problema de las regresiones espurias fue analizado por primera vez por Granger y Newbold (1974)⁷ y puede sintetizarse diciendo que cuando se llevan a cabo regresiones entre series temporales económicas expresadas en niveles, es muy probable encontrar relaciones con un valor elevado del coeficiente de determinación y valor pequeño del estadístico de Durbin-Watson, lo que puede invalidar la relación estimada en el modelo. Ante esta situación los estimadores mínimo cuadráticos de los coeficientes del modelo pueden ser ineficientes y los estimadores de los errores estándar pueden resultar inconsistentes (Pérez, 2006).

El problema de correlación serial en modelos estáticos puede llevar a la consideración de introducir un retardo, es decir, un componente dinámico en el modelo. En general, el problema de las regresiones espurias aparece frecuentemente cuando se halla la regresión estática entre series económicas afectadas por tendencias comunes. Este problema ocurre de forma muy frecuente cuando las variables del modelo son no estacionarias (integradas), ya que es posible que posean una tendencia temporal similar, que es el origen de la alta correlación observada (Pérez, 2006).

La mayoría de las series que se utilizan en economía resultan ser no estacionarias, ya que crecen o decrecen en el tiempo, de manera que la media varía en el tiempo. La regresión de una variable con tendencia sobre otra por lo general produce un R^2 muy alto y estadísticos t muy significativos, sin embargo, con un estadístico Durbin-Watson bajo.

⁷ Para mayores detalles véase: Granger, C.W.J., and Newbold, P. 1974. "Spurious Regressions in Econometrics", *Journal of Econometrics*, Vol. 2, 111-120.

4.3. Estacionariedad, Prueba de Raíz Unitaria y Cointegración

Ante algún shock externo, se puede preguntar si los precios, las tasas de interés, el producto interno bruto (PIB) o cualquier otra variable económica tiende a revertirse a su tendencia normal de largo plazo o si, por el contrario, sigue una ruta aleatoria. Desde el punto de vista del mercado de productos, si los precios se mueven aleatoriamente, no se podría crear un modelo económico que pueda predecir los precios a futuro y, por lo tanto, es imposible que los productores o los comercializadores anticipen los precios al momento de la cosecha. Esta es una razón que justifica la existencia de los mercados de futuros, en los cuales se reúnen compradores y vendedores, quienes, a partir de sus expectativas y de la información de que disponen sobre el mercado local y la economía mundial, anticipan y especulan sobre los precios futuros (Arias y Segura, 2001).

Las variables que siguen una ruta aleatoria son no estacionarias o integradas, (Pindyck y Rubinfeld, 1991). Sin embargo, es posible encontrar que entre dos variables que son integradas (no estacionarias), como los precios de disponibles y los precios de futuros, resulte una combinación lineal que entre ellas sea estacionaria. Si ese fuera el caso, se dice que las series están cointegradas, o que entre ellas se establece una relación de equilibrio de largo plazo. Dicho de otra forma, las dos variables se mueven juntas en el tiempo. El factor de cointegración en este caso, con la transformación pertinente, representa la elasticidad con que se transmiten los precios de un mercado a otro (Arias y Segura, 2001).

Una variable aleatoria o proceso estocástico⁸ es estrictamente estacionario si su distribución de probabilidad no depende del tiempo. Estadísticamente, en términos generales una variable es estacionaria (o débilmente estacionaria) si posee media y varianza constantes en el tiempo y si la covarianza entre dos períodos no depende del nivel de rezagos utilizados para calcularla.

De manera general se utilizará el término estacionario para los "*procesos débilmente estacionarios*". Se tiene entonces que una serie y_t es estacionaria si:

$$\text{Media:} \quad E(y_t) = \mu$$

⁸ Un proceso estocástico o aleatorio es una colección de variables aleatorias ordenadas en el tiempo.

$$\text{Varianza: } \quad \text{Var}(y_t) = E(Y_t - \mu)^2 = \sigma^2$$

$$\text{Covarianza: } \quad \text{Cov}(y_t, y_s) = E[(Y_t - \mu)(Y_s - \mu)] = f(t-s)$$

donde μ y σ^2 son constantes para todo t , y donde $f(t-s)$ es una función que depende exclusivamente de la diferencia $(t-s)$ y no del tiempo.

Una prueba estadística de estacionariedad en las series es la **prueba de raíz unitaria**. Una forma de introducir esta prueba es considerando el siguiente modelo:

$$Y_t = Y_{t-1} + u_t$$

donde u_t es el término de error estocástico con ruido blanco, es decir: media cero, varianza constante, y no está autocorrelacionado.

La ecuación es una regresión de primer orden, o AR(1), en la cual se relaciona el valor de Y_t sobre su valor rezagado Y_{t-1} . Si el coeficiente de Y_{t-1} , es igual a 1, surge lo que se conoce como raíz unitaria. Entonces el modelo se indica como:

$$Y_t = \rho Y_{t-1} + u_t \quad (\text{caminata aleatoria})$$

donde $\rho=1$ y u_t es el término de error con ruido blanco.

Para efectos teóricos, la ecuación puede reescribirse como:

$$Y_t - Y_{t-1} = \rho Y_{t-1} - Y_{t-1} + u_t$$

$$= (\rho - 1)Y_{t-1} + u_t$$

$$\Delta Y_t = \delta Y_{t-1} + u_t$$

donde $\delta = (\rho - 1)$ y Δ , es el operador de la primera diferencia⁹. De esta manera, la hipótesis (nula) es $\delta = 0$. Si $\delta = 0$, entonces $\rho = 1$, es decir, existe raíz unitaria. Esta ecuación indica que, dado que u_t es ruido blanco, las primeras diferencias de una serie de tiempo de caminata aleatoria son estacionarias (Gujarati, 2004).

⁹ Puesto que $\delta = (\rho - 1)$, por tanto para que exista estacionariedad, ρ debe ser menor que uno. Para que esto suceda, δ debe ser negativa.

4.3.1. Prueba Dickey-Fuller (DF) y Dickey-Fuller Aumentada (ADF)

A fin de permitir distintas posibilidades en el proceso de raíz unitaria, la prueba Dickey - Fuller (DF) se calcula en tres modelos diferentes, es decir, bajo tres distintas hipótesis nulas:

Y_t es una caminata aleatoria: $\Delta Y_t = \delta Y_{t-1} + u_t$

Y_t es una caminata aleatoria con variaciones: $\Delta Y_t = \beta_1 + \delta Y_{t-1} + u_t$

Y_t es una caminata aleatoria con variaciones alrededor de una tendencia estocástica: $\Delta Y_t = \beta_1 + \beta_2 T + \delta Y_{t-1} + u_t$

donde T es el tiempo o la variable de tendencia. En cada caso, la *hipótesis nula* es que $\delta = 0$; es decir, existe una raíz unitaria: la serie de tiempo es no estacionaria. La hipótesis alternativa es que δ es menor que cero; es decir, la serie de tiempo es estacionaria. Si se rechaza la hipótesis nula, esto significa que Y_t es una serie de tiempo estacionaria (Gujarati, 2004).

Dickey-Fuller Aumentada (ADF)

Cuando el término de error u_t está autocorrelacionado se utiliza la prueba aumentada de Dickey y Fuller ADF (Augmented Dickey Fuller Test). Para contrarrestar la autocorrelación, a las tres ecuaciones anteriores, se les aumentan las diferencias rezagadas de la variable dependiente ΔY_t , la ecuación de regresión sería:

$$\Delta Y_t = \alpha + \delta Y_{t-1} + \beta \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t$$

donde ε_t es un término de error puro con ruido blanco y $\Delta Y_{t-1} = (Y_{t-1} - Y_{t-2})$, $\Delta Y_{t-2} = (Y_{t-2} - Y_{t-3})$, etc. El número de términos de diferencia rezagados que se debe incluir, con frecuencia se determina de manera empírica, siendo la idea incluir los términos suficientes para que el término de error no esté serialmente relacionado. En la ADF¹⁰ se sigue probando $\delta = 0$ y además la estadística ADF sigue la misma distribución asintótica que el estadístico DF, por lo que se pueden utilizar los mismos valores críticos (Gujarati, 2004).

¹⁰ Para verificar la hipótesis nula de que Y_t no es estacionaria, basta con verificar que $\rho = 1$ frente a la hipótesis alternativa de que $\rho \neq 1$. Si $\rho = 1$, Y_t resulta ser un paseo aleatorio (proceso no estacionario).

4.3.2. Cointegración de Variables I(1)

Desde el punto de vista de la econometría, dos o más series de tiempo que son no estacionarias de orden I(1) están cointegradas si existe una combinación lineal de esas series que sea estacionaria o de orden I(0). El vector de coeficientes que crean esta serie estacionaria es el vector cointegrante. El tipo de series no estacionarias más habituales son las series integradas de orden 1 ó series I(1), cuyas primeras diferencias son estacionarias. El método estadístico para estas series exige precauciones, debido a que los estadísticos de contraste de regresión no siguen las distribuciones estándar correspondientes a procesos estacionarios, lo que da lugar a las denominadas regresiones espurias (Hamilton, 1994).

Una forma de abordar las series I(1) es tomar diferencias, para trabajar con series estacionarias. Sin embargo, si existe una relación a largo plazo entre los niveles de las series estudiadas (cointegración), tomar diferencias hace perder esa relación. La cointegración corresponde a una relación a largo plazo entre variables I(1), relación que no se detecta bien con los contrastes habituales de regresión.

Sean y_t , z_t series no estacionarias I(1). Sea la diferencia $\varepsilon_t = y_t - \beta z_t$. En general, esta diferencia ε_t será también no estacionaria I(1), pero puede que exista un β tal que ε_t sea I(0). Si es así, la diferencia $y_t - \beta z_t$ es estacionaria, “estable” alrededor de una media fija. Se dice entonces que las dos series están cointegradas, con vector de cointegración $[1, -\beta]'$.

Esto nos permite estudiar una relación a largo plazo definida por el vector de cointegración y una relación a corto plazo marcada por la serie estacionaria de residuos. Como ya se mencionó, diferenciar las dos series haría perder la relación a largo plazo. Además, si hay cointegración, la representación VAR¹¹ de las series diferenciadas contiene infinitos términos (si no incluimos niveles, sólo diferencias. Hamilton 1994, p. 573), por lo que no es práctico diferenciar.

Un ejemplo de sistema cointegrado es:

$$y_{1t} = \gamma y_{2t} + \varepsilon_{1t}$$

¹¹ La metodología de los vectores autorregresivos (VAR) puede consultarse en Hamilton, J. D. 1994. Time Series Analysis. Princeton University Press. United States of America.

$$y_{2t} = \gamma y_{2, t-1} + \varepsilon_{2t}$$

donde, ε_{1t} , ε_{2t} son ruidos blancos independientes y γ es una constante. Aquí las dos series son $I(1)$, pero la relación $y_{1t} - \gamma y_{2t}$ es estacionaria.

Intuitivamente, que dos series cointegran quiere decir que podemos conseguir que se muevan “casi” juntas si a una de ellas le cambiamos la escala y le sumamos un valor constante.

A modo de ejemplo se han representado distintas realizaciones del sistema cointegrado:

$$y_{1t} = b + \gamma y_{2t} + \varepsilon_{1t}$$

$$y_{2t} = \pi + y_{2, t-1} + \varepsilon_{2t}$$

que incluye una deriva π y un desplazamiento b , también llamado “término constante de la relación de cointegración” (Hamilton, 1994).

Cointegración multivariable

Con carácter más general que el caso de dos variables, considerando un vector \mathbf{y}_t de m variables no estacionarias $I(d)$, si existe un vector $\beta \neq \mathbf{0}$ tal que $\beta' \mathbf{y}_t$ es $I(d-b)$ para algún $b > 0$, entonces se dice que las variables \mathbf{y}_t están cointegradas $CI(d,b)$. A β se le denomina vector de cointegración. Con más de dos variables no estacionarias, puede ser que existan varios vectores linealmente independientes de cointegración.

El caso más habitual es el de series $I(1)$. Siendo \mathbf{y}_t el vector de m variables $I(1)$, podemos tener r vectores independientes de cointegración ($0 \leq r < m$) agrupables en filas en la matriz Γ de dimensiones $r \times m$, de modo que $\Gamma \mathbf{y}_t = \mathbf{u}_t$, donde \mathbf{u}_t es $I(0)$. A r se le denomina rango de cointegración, y es el rango de la matriz Γ (Hamilton, 1994).

4.3.3. Análisis de Cointegración. Método de Johansen

El procedimiento de cointegración de S. Johansen (1988 y 1995) consiste en probar la existencia de cointegración en variables $I(1)$ e $I(0)$, en donde $I(1)$ y $I(0)$ indican integración de primer y cero orden, respectivamente. En este procedimiento, es necesario analizar las series previamente con el fin de conocer si presentan o no raíces unitarias. Las series que presenten raíces unitarias se

colocan en un vector autorregresivo a partir del cual se puede probar la existencia de una o más combinaciones lineales $J(U)$ o vectores de cointegración.

El análisis de cointegración para series $I(1)$ consiste en:

1. Determinar el orden de integración a cada una de las series incluidas en el modelo.
2. Especificar un Vector Autorregresivo (VAR) con las series que resulten integradas de orden $I(1)$.
 - Seleccionar las Variables del Modelo.
 - Determinar el retardo óptimo del VAR para asegurar que los residuos sean ruido blanco (white noise).
 - Diagnóstico del VAR estimado.
3. Aplicar el procedimiento de Máxima Verosimilitud al vector autorregresivo con el fin de determinar el rango (r) de cointegración del sistema:
 - Prueba de la Traza.
 - Prueba del Eigenvalue Máximo (valor propio).
4. Estimar el modelo Vector de Corrección de Errores.
5. Determinar la relación causal entre las variables del modelo (mediante MCO).

4.4. Metodología de Series de Tiempo

Los modelos de series de tiempo se construyen teniendo en cuenta que las series temporales tienen una historia estadística recurrente que puede ser modelada y explotada para fines de predicción o pronóstico. Detrás de esta metodología se encuentra la idea de que no podemos conocer lo suficiente acerca de la estructura de una economía como para construir un modelo estructural detallado que permita la obtención de buenos pronósticos (Sims, 1980). En este trabajo se construyen y examinan modelos de series temporales univariadas y multivariadas, para fines predictivos de precios de maíz.

4.4.1. Metodología de Box y Jenkins (Modelos AR, MA, ARMA o ARIMA)

De acuerdo a la metodología de Box-Jenkins (2008), si bien teóricamente existe un número infinito de modelos $ARIMA(p,d,q)$ ¹², empíricamente se puede comprobar que para valores pequeños de (p,d,q) se pueden obtener modelos ARIMA que se ajustan con precisión a la serie de datos.

Bajo esta metodología, el análisis de series de tiempo se lleva a cabo mediante las siguientes etapas: (i) verificación de estacionariedad de las series y diferenciación (ii) Identificación, (iii) Estimación, (iv) Verificación y, (v) Predicción (Pronóstico). Si la serie es débilmente estacionaria, se procede con la etapa (ii); caso contrario, la serie debe ser transformada en estacionaria. Asumiendo que se cuenta con series estacionarias, la identificación tiene por objeto determinar el tipo de modelo a aplicar (AR, MA ó ARMA) y el orden de los parámetros "p" y "q". Para ello se examinan los gráficos de las funciones de autocorrelación (FAC) y autocorrelación parcial (FACP) con el fin de identificar qué componentes autorregresivos o de media móvil utilizar en la estimación del modelo. Tras la identificación del modelo, (iii) se estiman los coeficientes que mejor ajustan al modelo ARIMA mediante máxima verosimilitud o mínimos cuadrados ordinarios. En la etapa (iv) Verificación, se revisa que los residuos sean independientes entre sí y cuenten media y varianza constantes en el tiempo (es decir, ruido blanco). Si la estimación no es adecuada, se reinicia el proceso desde la etapa (i). Finalmente en la etapa (v), se realizan las predicciones y se evalúa la capacidad predictiva del modelo estimado.

En síntesis, la estimación del modelo ARIMA óptimo consiste en realizar un proceso de búsqueda iterativa (a prueba y error) de valores para los parámetros tanto autorregresivos como para los del componente de media móvil.

De manera generalizada, conforme a la metodología Box y Jenkins, el modelo autorregresivo integrado de media móvil (ARIMA) formulado para predecir el precio físico de maíz se define de la siguiente manera:

¹² Los parámetros p, d y q denotan el orden de la parte autorregresiva del proceso, el grado de diferenciación requerida para transformar una serie no-estacionaria en estacionaria y el orden del promedio móvil del proceso, respectivamente.

$$\Delta P_t = c_1 + \sum_{i=1}^p \phi_{1i} \Delta P_{t-i} + a_t - \sum_{i=1}^q \theta_{1i} a_{t-i}$$

donde:

P = Precio físico de maíz blanco.

Δ = Operador de primera diferencia aplicada a la variable.

a = Error de predicción.

La c_1 representa el cambio en los niveles de la variable en cuestión, ϕ_{1i} y θ_{1i} , son los parámetros para cada variable del modelo, donde p y q indican el orden autorregresivo y de media móvil, respectivamente, para cada parámetro.

4.4.2. Modelos de Vectores Autorregresivos (VAR)

El modelo de vectores autorregresivos (VAR) es un sistema de ecuaciones en donde cada variable es explicada tanto por los retardos de sí misma, que es el caso de los modelos AR, como también por los retardos de las demás variables, a diferencia de los modelos de ecuaciones simultaneas en el caso de los VAR no se distingue entre variables endógenas y exógenas (todas se consideran variables endógenas). La formulación de un modelo VAR es similar al de un modelo de ecuaciones simultáneas, pero con un sistema de ecuaciones en su forma reducida y sin restringir. Por lo que, el conjunto de variables explicativas de cada ecuación está constituido por un bloque de retardos de cada una de las variables del modelo. La no restricción de las ecuaciones significa que aparece en cada una de ellas el mismo grupo de variables explicativas.

En base a la literatura, de manera general, la formulación del modelo de vectores autorregresivos (VAR) de 3 variables, sin restricciones, considerado para predecir el precio físico de maíz se define de la siguiente manera:

$$\begin{bmatrix} P \\ F \\ I \end{bmatrix}_t = \begin{bmatrix} \alpha_P \\ \alpha_F \\ \alpha_I \end{bmatrix}_t + \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \\ \theta_{31} & \theta_{32} & \theta_{33} \end{bmatrix}_1 \begin{bmatrix} P \\ F \\ I \end{bmatrix}_{t-1} + \dots + \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \\ \theta_{31} & \theta_{32} & \theta_{33} \end{bmatrix}_p \begin{bmatrix} P \\ F \\ I \end{bmatrix}_{t-p} + \begin{bmatrix} \varepsilon_P \\ \varepsilon_F \\ \varepsilon_I \end{bmatrix}_t$$

$$t = 1, \dots, T$$

donde:

P = Precio físico de maíz blanco.

F = Precio futuro de maíz (amarillo - EU).

I = Precio internacional de maíz (amarillo - EU).

ε = Término de error (innovaciones o impulsos) de cada uno de los modelos.

Del lado izquierdo se tiene el vector (3x1) de variables del sistema en el periodo t. Del lado derecho se encuentra un vector (3x1) de términos constantes α , la siguiente matriz (3x3) es de los coeficientes autorregresivos θ que multiplican al vector (3x1) de variables rezagadas desde t-1 hasta t-p, y finalmente, el vector (3x1) de ε corresponde a los términos de error (innovaciones o impulsos), en el periodo t. Los elementos de la pueden estar correlacionados contemporáneamente pero no correlacionados a través de diferentes períodos. La especificación es irrestricta en el sentido de que todas las variables (P, F, I) tienen el mismo orden de rezago p (evidentemente dependiendo del modelo de cada estado) y ninguno de los coeficientes θ se supone cero a priori. El número de retardos óptimo “ p ”, que es el orden del modelo VAR, o número de retardos de las variables en cada modelo, se define de acuerdo a los criterios de información: Razón de verosimilitud (LR), Akaike information criterion (AIC), Schwarz information criterion (SC) y Hannan-Quinn information criterion (HQ).

En los modelos de vectores autorregresivos el término de error en cada una de las ecuaciones o vectores cumple con el supuesto de ruido blanco (homocedasticidad y no autocorrelación), por lo que pueden ser estimados mediante MCO (mínimos cuadrados ordinarios).

Dado que es muy común que las variables de series de tiempo sean no estacionarias, hacer una regresión de una variable de serie de tiempo sobre una o más variables de series de tiempo, puede dar como resultado regresiones espurias o sin sentido. Sin embargo, cuando las variables están

cointegradas¹³ no solo no son espurias sino que entre ellas guardan una relación de equilibrio de largo plazo.

4.4.3. Modelos Vectoriales de Corrección del Error (VCE)

El criterio estadístico, de acuerdo a Engle-Granger (1987), es que si las variables están cointegradas se debe preferir por utilizar el modelo de corrección del error. Esto debido a que se pueden utilizar los residuos de la regresión de equilibrio para estimar el modelo de corrección de errores y analizar los efectos a largo y a corto plazo de las variables, así como también estimar el coeficiente de ajuste, el cual es el coeficiente del término residual retardado de la relación de equilibrio a largo plazo identificado en la prueba de cointegración. No obstante, al final se debe revisar para ver si el modelo realiza pruebas adecuadas de diagnóstico (Gujarati, 2004).

Conforme a Engle-Granger, un VAR que presenta estacionariedad podría ser estimado en niveles, y los resultados serían confiables.

En el caso en el que se encuentre que el VAR es inestable o no estacionario, es posible proceder en dos sentidos; el primero consiste en estimar el VAR con series estacionarias; esto es, se tendrían que diferenciar las series que son no-estacionarias de tal forma que se obtuvieran series estacionarias y estimar el VAR en primeras diferencias. Este escenario no es muy atractivo pues se perdería información importante sobre la dinámica de largo plazo.

La segunda posibilidad consiste en identificar la existencia de cointegración entre las series. En este caso la posibilidad de identificar relaciones de cointegración en el VAR sigue el argumento presentado por Engle y Granger, que muestra que cuando una combinación lineal de variables $I(1)$ puede representarse como una combinación lineal que es en sí misma $I(0)$, entonces ese conjunto de variables puede representarse por medio de un modelo de corrección de error. Este argumento, en términos generales, es conocido como el teorema de representación de Granger¹⁴.

¹³ El concepto de cointegración fue introducido por Engel y Granger (1987), su análisis radica en la existencia de un equilibrio a largo plazo entre un conjunto de variables.

¹⁴ No obstante, los modelos de corrección de error (MCE) tienen interés práctico, incluso en el caso de regresiones no espurias que no superan los contrastes de cointegración, si se consideran en su versión contemporánea, la cual tiene

El modelo vectorial de corrección del error (VCE) puede ser resumido como un modelo VAR en primeras diferencias, donde la existencia de cointegración del sistema admite una formulación en forma de corrección del error.

Granger muestra también que si existe cointegración, y por consiguiente mecanismo de corrección del error, existe también causalidad en el sentido de Granger, por lo que al menos una de las variables causa a la otra en el sentido de que tenerla en cuenta aporta información para explicar a la otra variable.

Conforme al Teorema de Engle y Granger, la representación del modelo vectorial de corrección del error (VEC) de 3 variables, sin restricciones, considerado para predecir el precio físico de maíz se define de la siguiente manera:

$$\begin{aligned} \begin{bmatrix} \Delta P \\ \Delta F \\ \Delta I \end{bmatrix}_t &= \begin{bmatrix} \alpha_P \\ \alpha_F \\ \alpha_I \end{bmatrix} + \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \\ \theta_{31} & \theta_{32} & \theta_{33} \end{bmatrix}_1 \begin{bmatrix} \Delta P \\ \Delta F \\ \Delta I \end{bmatrix}_{t-1} + \dots \\ &\dots + \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \\ \theta_{31} & \theta_{32} & \theta_{33} \end{bmatrix}_p \begin{bmatrix} \Delta P \\ \Delta F \\ \Delta I \end{bmatrix}_{t-p} - \begin{bmatrix} \Pi_{11} & \Pi_{12} & \Pi_{13} \\ \Pi_{21} & \Pi_{22} & \Pi_{23} \\ \Pi_{31} & \Pi_{32} & \Pi_{33} \end{bmatrix} \begin{bmatrix} P \\ F \\ I \end{bmatrix}_{t-1} + \begin{bmatrix} \varepsilon_P \\ \varepsilon_F \\ \varepsilon_I \end{bmatrix}_t \\ &t = 1, \dots, T \end{aligned}$$

donde:

Δ = Operador de primera diferencia aplicada a la variable.

P = Precio físico de maíz blanco.

F = Precio futuro de maíz (amarillo - EU).

I = Precio internacional de maíz (amarillo - EU).

ε = Término de error (innovaciones o impulsos) de cada uno de los modelos.

en cuenta la relación causal contemporánea entre el incremento de la variable explicativa y la variable explicada. Sus resultados son generalmente buenos si la relación causal está bien especificada, y existen otras especificaciones alternativas que también proporcionan resultados similares [Engle-Yoo, 1991].

Del lado izquierdo se tiene el vector (3x1) de variables en diferencia del sistema en el periodo t. Del lado derecho se encuentra un vector (3x1) de términos constantes α , la siguiente matriz (3x3) es de los coeficientes autorregresivos θ que multiplican al vector (3x1) de variables en diferencia rezagadas desde t-1 hasta t-p. La siguiente matriz de coeficientes Π de (3x3), que representa el producto del vector α (coeficientes de ajuste) y el vector β (cointegrante), multiplica al vector de variables en niveles en el periodo t-1. Este vector denota la desviación del periodo anterior respecto a la relación de equilibrio de largo plazo entre las variables de esta manera, las propiedades de equilibrio se caracterizan por el rango de la matriz de coeficientes Π . Finalmente, el vector (3x1) de ε corresponde a los términos de error (innovaciones o impulsos), en el periodo t. La especificación es irrestricta y ninguno de los coeficientes θ se supone cero a priori. El número de retardos óptimo “p”, que es el orden del modelo VEC, de igual manera que en el VAR, se define de acuerdo a los criterios de información estándar (prueba de exclusión de rezagos).

El modelo vectorial de corrección del error (VCE) parte de una relación de equilibrio de largo plazo, sin embargo, dado que en el corto plazo pueden haber desequilibrios, estos pueden ser corregidos mediante un mecanismo de ajustes parciales de corto plazo (corrección del error). En general, el modelo vectorial de corrección del error incluye la prueba de raíz unitaria, la prueba de cointegración y la modelación del VEC.

4.5. Capacidad Predictiva del Modelo

La precisión de un pronóstico es el grado de cercanía entre el valor estimado y su valor observado. El valor real generalmente no puede medirse en el momento en el que se realiza el pronóstico, porque la expresión se refiere al futuro. La precisión, cuando se calcula, proporciona una estimación cuantitativa de la calidad esperada de los pronósticos. En el análisis de series de tiempo se vuelve fundamental elegir, entre la especificación de un modelo y otro, en base a la evaluación de la capacidad predictiva. Para determinar cuál de los 3 modelos o métodos de pronóstico resulta ser el más efectivo, se comparan los resultados de estadísticos, comúnmente utilizados para evaluar la capacidad predictiva, estos son:

$$RECM = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad \text{Raíz del Error Cuadrático Medio}$$

$$CDT = \frac{\sqrt{\sum_{i=1}^n (\hat{y}_i - y_i)^2 / n}}{\sqrt{\sum_{i=1}^n \hat{y}_i^2 / n} + \sqrt{\sum_{i=1}^n y_i^2 / n}} \quad \text{Coef. de Desigualdad de THEIL}$$

Donde n es el número de observaciones, e_i el error de predicción que registra la diferencia entre cada valor observado de la serie y_i (P_t : Precio de físico de maíz blanco) y su valor estimado. La raíz del error cuadrático medio (RECM) es una estandarización del error cuadrático medio de la variable dependiente y es considerada la medida más común para evaluar la exactitud del pronóstico. Por otra parte, el coeficiente de desigualdad de Theil (CDT) es un estadístico más complejo, que de igual manera mide la calidad del modelo para predecir. Sin embargo, a diferencia de la raíz del error cuadrático medio (RECM), el coeficiente de desigualdad de Theil (CDT) no es sensible a las unidades de medida en la que se encuentren los datos (kg, ton, miles, millones, etc); y sus valores se encuentran acotados entre cero y uno. En ambos casos, cuanto más cercano a cero sea el valor del estadístico indicará mejor capacidad predictiva.

5. ANÁLISIS DE RESULTADOS Y DISCUSIÓN

5.1. Especificación de los Modelos Box y Jenkins

Tras la identificación y validación¹⁵ de los modelos AR, MA, ARMA o ARIMA, conforme a la metodología de Box y Jenkins, se elige el modelo que arroje los mejores estadísticos de t y F, así como, los mejores resultados en relación al margen de error de las estimaciones, siendo para este caso la suma de cuadrados del error. Algunos de los resultados estadísticos de los modelos elegidos se muestran en el Cuadro 2:

Cuadro 2. Estadísticos de Modelos ARIMA

Modelo ARIMA	Pr > t Statistic ¹	Pr > F Statistic	Autocorrel Chi-Square ²	S C E
Sinaloa (0,1,1)	0.0052	0.0106	0.5894	19.3782
Jalisco (1,1,1)	0.0263	0.0168	0.3605	4.7578
Edomex (3,1,2)	0.0179	0.0001	0.4526	7.2440
Michoacan (2,1,1)	0.0000	0.0000	0.3096	5.5943
Guanajuato(1,1,1)	0.0499	0.0261	0.3117	8.6583

¹ En el cuadro solo aparece el valor (Pr >t) del primer parámetro, sin embargo, los resultados del estadístico de t para todos los coeficientes AR y MA considerados en los modelos indican significancia estadística al nivel de $\alpha=0.05$.

² Además de la prueba de X^2 (Chi-Square), todos los modelos también superan la prueba del correlograma, siendo en todos los casos, modelos en donde los residuales siguen un proceso de ruido blanco.

La especificación de los componentes AR, I y MA de los modelos que se muestra en el cuadro anterior es: Sinaloa AR(0), I(1), MA(1), Jalisco AR(15), I(1), MA(1), Estado de México AR(20, 27, 29), I(1), MA(1,5), Michoacán AR(1,11), I(1), MA(3) y Guanajuato AR(4), I(1), MA(16), como se muestra en el cuadro 2 los modelos elegidos superan las pruebas de t, F y Chi-cuadrada (χ^2) autocorrelación serial de los errores; el estadístico suma de cuadrados de los errores (SCE) también es considerado para decidir la elección de los modelos.

¹⁵ La identificación en los modelos de series de tiempo consiste en encontrar o identificar los componentes autorregresivos, de media móvil e integración de la serie. La validación, se refiere a evaluar la confiabilidad de los resultados de los parámetros estimados a partir de diversos estadísticos de prueba. También aquí los coeficientes de autocorrelación deben ser cero, es decir, los residuales del modelo estimado no tienen estructura de dependencia y siguen un proceso de ruido blanco.

5.2. Raíces Unitarias

Para determinar si las series son o no estacionarias se utiliza la Prueba de Dickey Fuller Aumentada (ADF), en este caso los modelos que se ponen a prueba, incluyen en cada una de las series una constante. En el cuadro 3 se muestran los resultados que indican que no se rechaza la presencia de raíz unitaria en ninguna de las variables, es decir, son no estacionarias (integradas).

Cuadro 3. Pruebas aumentadas de la raíz unidad de Dickey-Fuller

Variable	Tipo	t-Statistic	Prob<t
Precio Sinaloa	Constante	-2.4258	0.1361
Precio Jalisco	Constante	-0.9642	0.7656
Precio Edomex	Constante	-1.0549	0.7331
Precio Michoacan	Constante	-1.5937	0.4838
Precio Guanajuato	Constante	-1.5399	0.5113
Precio USA	Constante	-1.0542	0.7333
Precio Futuro USA	Constante	-1.2887	0.6347

H0: Existe raíz unitaria
H1: No existe raíz unitaria

De acuerdo a los valores de la probabilidad asociada al estadístico de t (**Prob<t**), no se rechaza la presencia de raíz unitaria en ninguna de las variables, al ser estos mayores a 0.05, por lo que las series de tiempo son no estacionarias (integradas).

Como se ha comentado, es posible que dos o más series que son no estacionarias resulten estar cointegradas si una combinación lineal de ellas es estacionaria, esto implica que las series guardan una relación de equilibrio de largo plazo. En el cuadro 4 se presenta el contraste de cointegración entre las series de precios de los modelos especificados. En todos los casos se asumió tendencia lineal en los datos, e intercepto en la ecuación de cointegración. Esto es, se supuso que la ecuación de cointegración no presenta tendencia. Como se aprecia, tanto el test de la traza como

el test del máximo eigen valor rechazan con un nivel de significatividad del 5% la existencia de cero ecuaciones de cointegración (en el caso de Sinaloa $63.85 > 29.80$ y $43.57 > 21.13$). Al mismo tiempo, no fue posible rechazar las hipótesis nulas que imponen máximo 2 relaciones de cointegración (en el caso de Sinaloa $2.92 < 3.84$ y $2.92 < 3.84$). Por lo tanto, los test indican que existe una ecuación de cointegración para las variables utilizadas en cada uno de los modelos.

5.3. Contraste de Cointegración

Cuadro 4. Contraste de Cointegración de Johansen

Modelo de cointegración	Retardo Optimo (p) ¹	H ₀ : Rango=r ²	Traza	Valor crítico 5%	Eigen Max	Valor crítico 5%
PS PUSA PFUSA (Sinaloa)	4	0	63.85	29.80	43.57	21.13
		1	20.28	15.49	17.36	14.26
		2*	2.92	3.84	2.92	3.84
PJ PUSA PFUSA (Jalisco)	2	0	83.88	29.80	63.64	21.13
		1	20.24	15.49	18.64	14.26
		2*	1.61	3.84	1.61	3.84
PMex PUSA PFUSA (Edo de Mex)	8	0	64.98	29.80	51.34	21.13
		1*	13.64	15.49	11.85	14.26
		2*	1.79	3.84	1.79	3.84
PMich PUSA PFUSA (Michoacán)	15	0	52.75	29.80	34.93	21.13
		1	17.82	15.49	15.76	14.26
		2*	2.07	3.84	2.07	3.84
PGto PUSA PFUSA (Guanajuato)	(4)(8)	0	71.20	29.80	48.45	21.13
		1	22.75	15.49	21.28	14.26
		2*	1.47	3.84	1.47	3.84

Para todos los casos en la especificación del test de cointegración se asume una tendencia lineal determinista en los datos.

¹ El retardo óptimo es determinado mediante la prueba de exclusión de rezagos (en primeras diferencias).

² La hipótesis indica el número de ecuaciones de cointegración sin restricciones.

* Indica el rango de cointegración (número de ecuaciones cointegrantes) de acuerdo a las prueba de la traza y del máximo eigen-valor.

En la prueba los modelos de Sinaloa, Jalisco, Michoacán y Guanajuato no rechazan la hipótesis de que existan máximo 2 ecuaciones o vectores cointegrantes, mientras que el modelo del Estado de México no rechaza la hipótesis de que existan 1 y 2 ecuaciones cointegrantes.

5.4. Especificación de los VAR y VCE

La estimación de los modelos VAR, se hace ecuación por ecuación mediante mínimos cuadrados ordinarios, que en ausencia de restricciones como es este caso, produce estimadores eficientes. El

número de retardos óptimo se define de acuerdo a los criterios de información estándar (prueba de exclusión de rezagos)¹⁶. Al igual que en los modelos ARIMA, la ausencia de autocorrelación o proceso de ruido blanco en los errores es fundamental para contar con un estimador consistente. En el cuadro 5 se muestra la especificación y algunos de los resultados estadísticos de los modelos VAR y VCE elegidos para el propósito de predicción de precios.

Cuadro 5. Modelos VAR Y VCE

Modelo VAR	Retardo Optimo ¹	Pr > F Statistic	Autocorrel Chi-Square ²	S C E
Sinaloa	4	0.0000	0.9970	15.5526
Jalisco	2	0.0000	0.0857	4.1408
Edomex	8	0.0000	0.7703	6.5319
Michoacan	15	0.0000	0.7804	3.6397
Guanajuato	8	0.0000	0.4344	7.1776
Modelo VCE	Retardo Optimo ¹	Pr > F Statistic	Autocorrel Chi-Square ²	S C E
Sinaloa	4	0.0021	0.7998	15.5522
Jalisco	2	0.0000	0.2294	4.1941
Edomex	8	0.0337	0.5588	6.7886
Michoacan	15	0.0003	0.8228	3.6469
Guanajuato	4	0.0848	0.6928	8.0192

¹ El retardo óptimo es determinado mediante la prueba de exclusión de rezagos (en primeras diferencias).
² Además de la prueba de X² (Chi-Square), todos los modelos también superan la prueba del correlograma, siendo en todos los casos, modelos en donde los residuales siguen un proceso de ruido blanco.

El modelo de vector de corrección del error VCE, que es un VAR estándar pero definido en primeras diferencias y aumentado por un término de corrección de errores (Hoffman y Rashe, 1997 citado por Arias, 2001), al igual que el VAR; una vez especificado el orden del rezago del modelo y asegurándose que los residuos son ruido blanco, se prueba la existencia de cointegración y se estima el modelo teniendo en consideración los términos de corrección del error.

¹⁶ La prueba de exclusión de rezagos considera los criterios: LR (sequential modified LR test statistic), AIC Akaike information criterion, (SC) Schwarz information criterion y (HQ) Hannan-Quinn information criterion.

5.5. Evaluación de los Modelos de Predicción

Es importante señalar que los mejores modelos de cada tipo son seleccionados conforme a los valores de sus estadísticos. Ahora en el cuadro 6 se comparan los resultados que evalúan la capacidad de predicción de todos los modelos elegidos. Las medidas de evaluación corresponden a la raíz del error cuadrático medio (RECM) y al coeficiente de desigualdad de Theil.

En el caso de la raíz del error cuadrático medio (RECM) cuanto más pequeño sea su valor mejor sería la capacidad del modelo para pronosticar, mientras que en el caso del coeficiente de desigualdad de Theil (entre cero y uno) un valor cercano a cero estaría indicando un ajuste perfecto.

Cuadro 6. Evaluación de los modelos de predicción

Estado	Modelo	RECM	THEIL
Sinaloa	ARIMA (0,1,1)	0.3219	0.0428
	VAR (4)	0.2907*	0.0385*
	VCE (4)	0.3007	0.0397
Jalisco	ARIMA (1,1,1)	0.1663	0.0227
	VAR (2)	0.1492*	0.0210*
	VCE (2)	0.1505	0.0212
Edomex	ARIMA (3,1,2)	0.2141	0.0279
	VAR (8)	0.1905*	0.0260*
	VCE (8)	0.1947	0.0265
Michoacan	ARIMA (2,1,1)	0.1783	0.0240
	VAR (15)	0.1450*	0.0194*
	VCE (15)	0.1456	0.0194*
Guanajuato	ARIMA (1,1,1)	0.2175	0.0298
	VAR (8)	0.2000*	0.0272*
	VCE (4)	0.2093	0.0287
	VCE (8)	0.2042	0.0277

* Indica el resultado menor en comparación con el resto.

Como se observa los modelos VAR presentan los valores más bajos de la RECM y del coeficiente de desigualdad de Theil para las predicción dentro de la muestra, sin embargo, al practicar una predicción fuera de muestra, los resultados indican que tan solo en el caso del modelo VAR de Sinaloa la predicción del valor es más cercana al dato observado, mientras que en los casos de Jalisco, Estado de México, Michoacán y Guanajuato; la predicción del valor obtenido de los

modelos VCE es más cercano al dato observado del precio de maíz. En ambos casos, tanto conforme a los estadísticos de las predicciones dentro de muestra como a la predicción obtenida fuera de muestra, los modelos VAR y VCE sin restricciones arrojan los mejores resultados a los obtenidos con los modelos ARIMA.

En la Figura 2 se muestra que el modelo VEC presenta mejor desempeño en el comparativo de la diferencia en porcentaje del valor predicho (septiembre de 2015) fuera de muestra.

Figura 2. Comparativo de los modelos en la predicción fuera de muestra

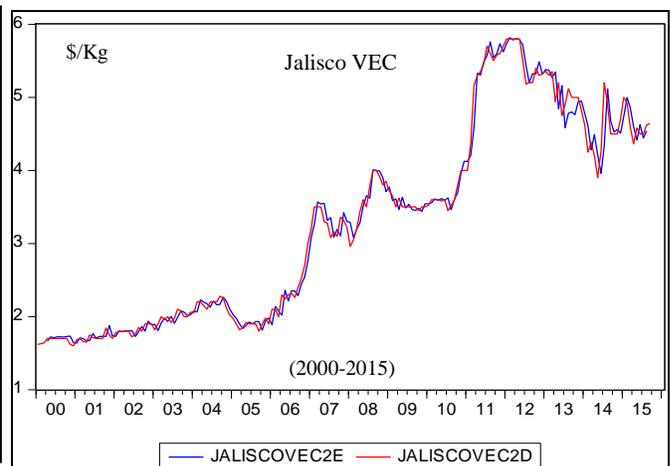
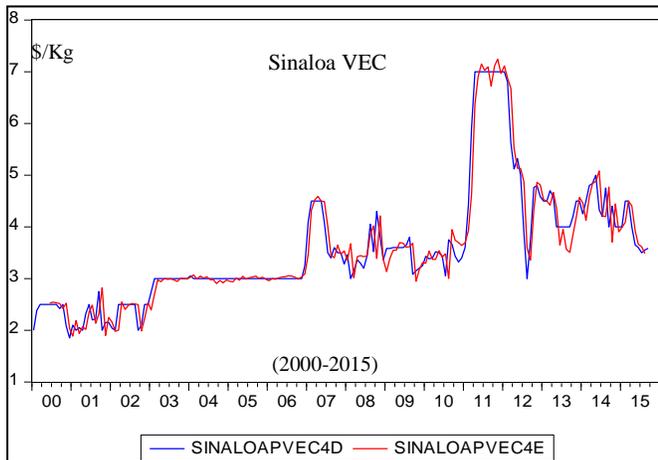
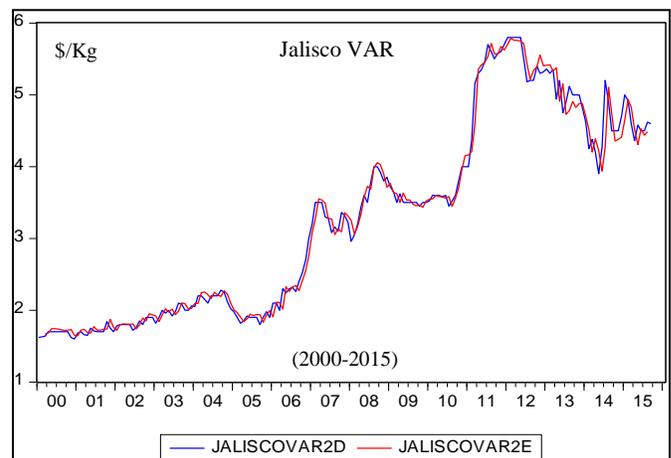
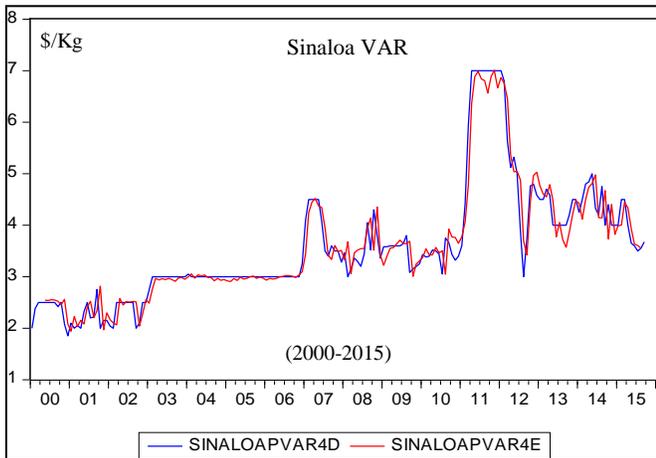
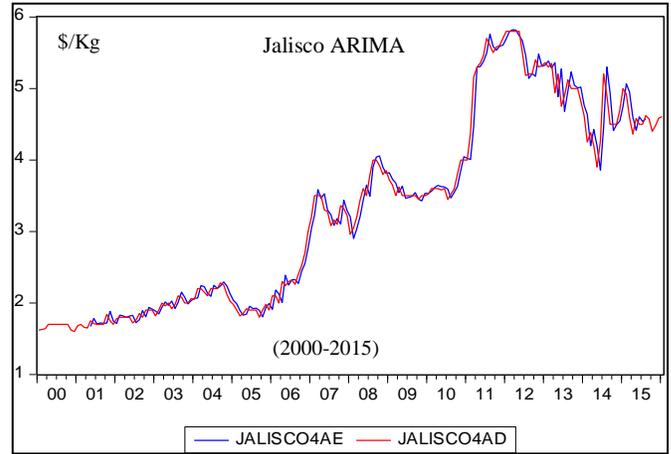
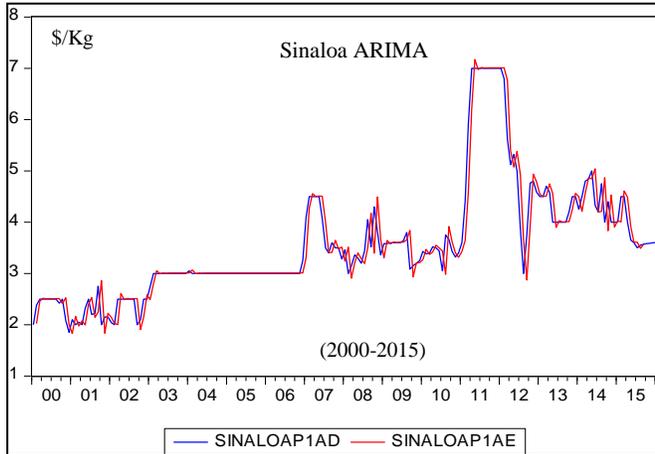
<i>sep-15</i>			
SINALOAP	ARIMA (0, 1, 1)	VAR	VEC
Observado	3.64	3.64	3.64
Predicho	3.57	3.67	3.58
Diferencia	-1.88%	0.92%	-1.54%
JALISCO	ARIMA (1, 1, 1)	VAR	VEC
Observado	5.00	5.00	5.00
Predicho	4.57	4.60	4.64
Diferencia	-8.57%	-8.03%	-7.12%
EDO MEX	ARIMA (3, 1, 2)	VAR	VEC
Observado	4.90	4.90	4.90
Predicho	4.77	4.78	4.904
Diferencia	-2.61%	-2.49%	0.07%
MICHOACAN	ARIMA (2, 1, 1)	VAR	VEC
Observado	4.28	4.28	4.28
Predicho	4.40	4.19	4.22
Diferencia	2.87%	-2.04%	-1.50%
GTO	ARIMA (1, 1, 1)	VAR	VEC
Observado	4.00	4.00	4.00
Predicho	4.17	4.07	4.00
Diferencia	4.18%	1.76%	-0.12%

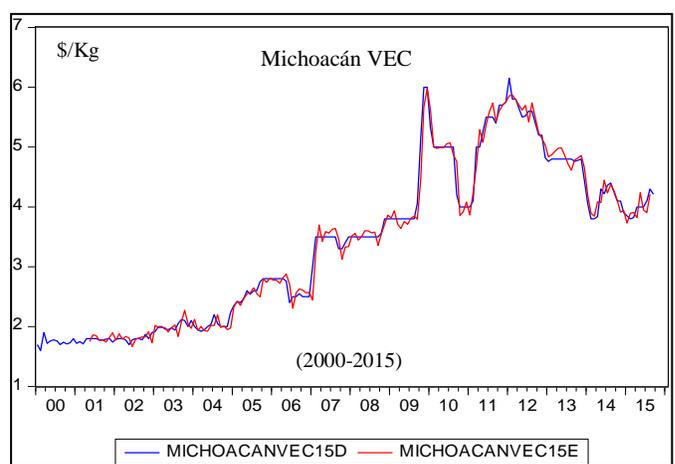
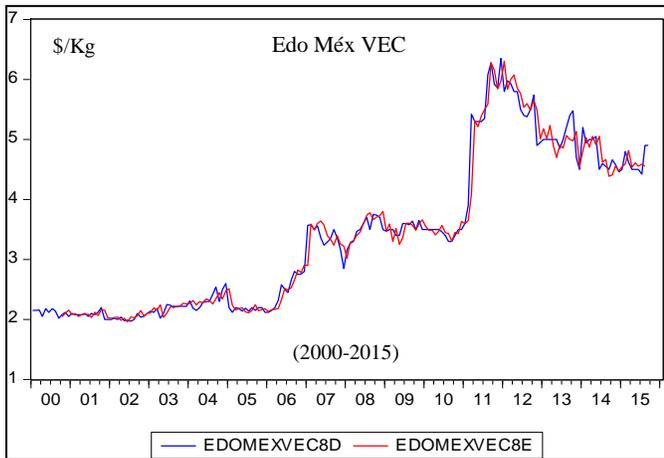
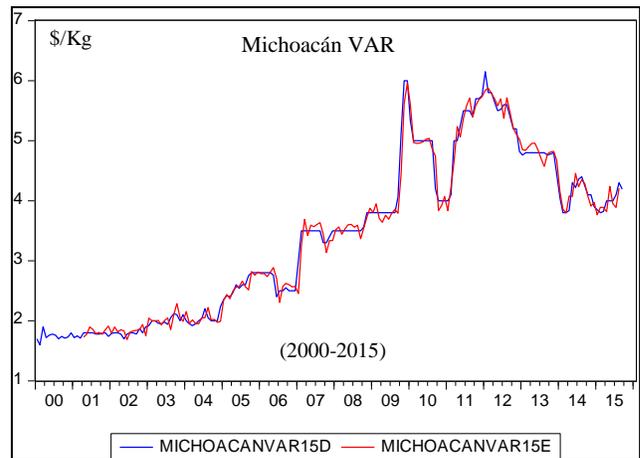
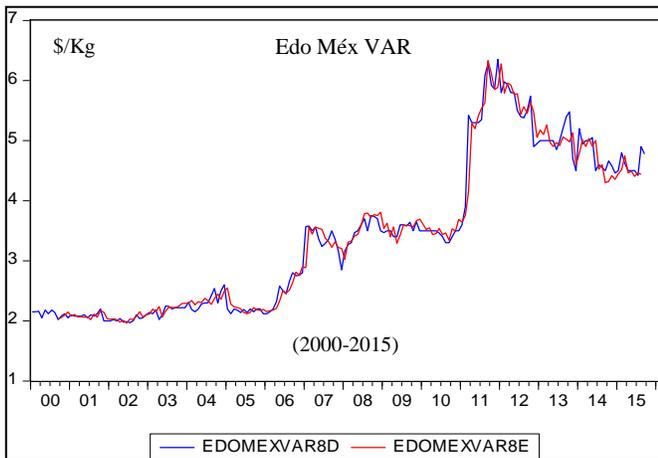
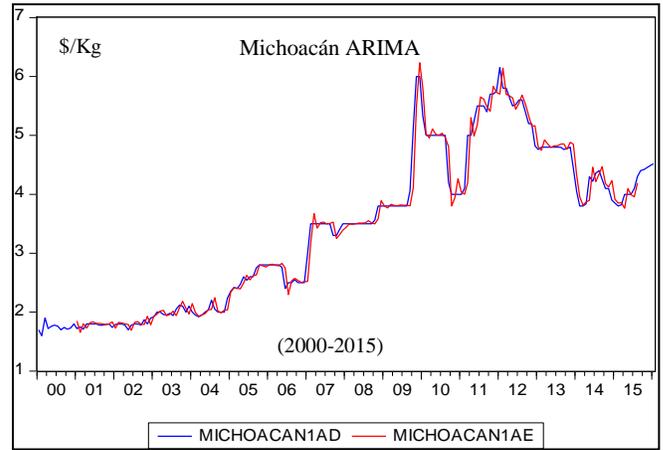
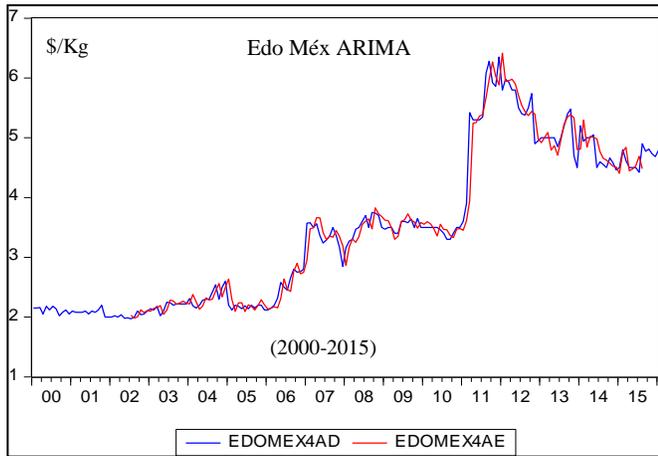
Predicción de una observación fuera de muestra

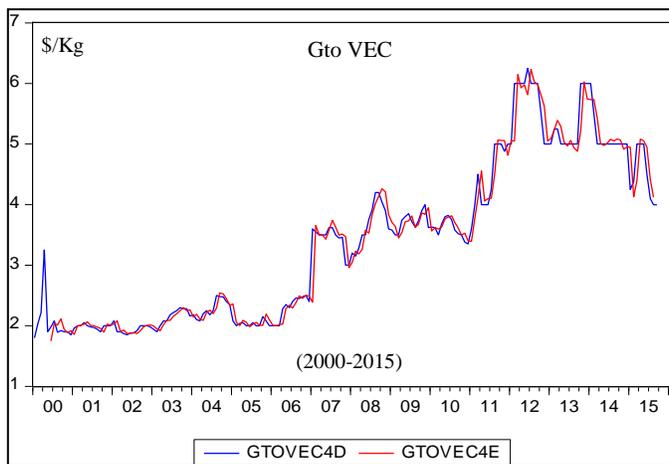
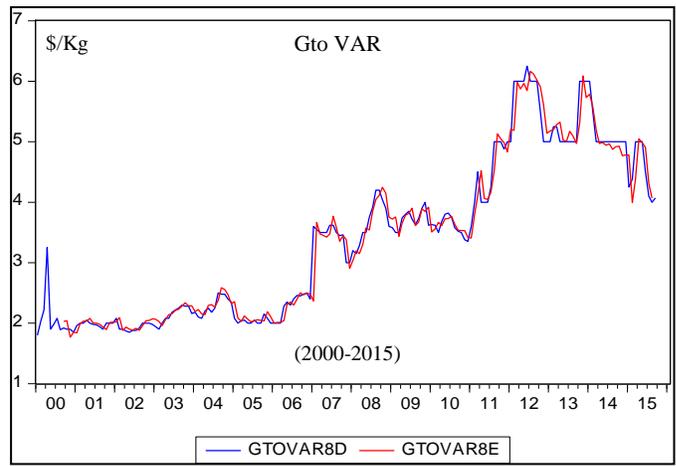
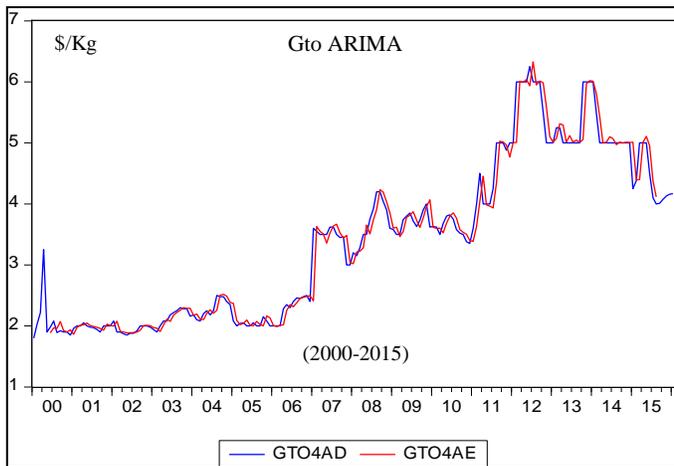
A continuación en la Figura 3 se muestran los gráficos que describen el comportamiento de los precios observados y predichos para cada uno de los estados modelados.

Figura 3. Gráficos de las Series de Tiempo vs Modelos de Predicción

(— Observado — Predicho)







En los gráficos se observa el ajuste los modelos ARIMA, VAR y VEC para las series de tiempo de los precios maíz blanco de los principales estados productores en Mexico.

5.6. Discusión

En investigaciones empíricas sobre predicciones de precios de productos agropecuarios Sanders and Baker (2012) encontraron que en el corto plazo, tanto para maíz como para soja de Estados Unidos, los modelos de series de tiempo proporcionan mejores predicciones de precio que el modelo comúnmente utilizado de promedios móviles de cinco años. Colino et al. (2011) determinan que la combinación de un simple VAR sin restricciones con las previsiones de precios publicadas por la Universidad Estatal de IOWA, mejoran la precisión de pronóstico en precios de cerdo de Estados Unidos. Timmerman y Granger (2004) citado en Henkel et al. (2011) sostienen que la innovación en los métodos de pronóstico es un componente integral de la eficiencia del mercado, en el sentido de que los mercados siempre están en una "carrera por la innovación" para adoptar nuevas generaciones de métodos de pronóstico. Goodwin (1992) obtiene que las predicciones de los modelos VARs y ARIMA son bastante similares para el caso de precios de ganado de Estados Unidos.

6. CONCLUSIONES

Existe evidencia de que los modelos de Vectores Autorregresivos (VAR) y Vectores de corrección del error (VCE) sin restricciones representan una buena alternativa, además de práctica, para la realización de pronósticos de precios de maíz blanco para el caso de los estados de Sinaloa, Jalisco, Estado de México, Michoacán y Guanajuato. Los resultados sugieren que confirmando la hipótesis de mercado eficiente, donde el precio futuro es un predictor insesgado del precio spot para un periodo y lugar dado, los modelos predictores de precio spot de maíz blanco en México que no incluyen información del mercado de futuros de los Estados Unidos resultan ser subóptimos.

Los modelos presentados resultan de utilidad para ser utilizados como una herramienta en la previsión de precios de maíz en México, buscando mejorar la planeación y control de los cultivos, así como, corregir las decisiones o realizar cambios en materia de política agrícola. Además, el trabajo puede ser de utilidad para investigadores que estén buscando realizar pronósticos de precios de los principales commodities en México.

LITERATURA CITADA

Akaike, H. 1974. "A new look at the statistical model identification". IEEE Transactions on Automatic Control (Japón) , Vol. 19, No. 6: 716–723.

Arias, J., O. Segura. 2001. Los Mercados de Futuros y La Cobertura de Riesgos: "Factibilidad de su uso en Bolsas de Físicos de América Latina". Ed. AGROAMERIICA, Instituto Interamericano para la Agricultura (IICA). Costa Rica. pp 18-21, 41-43, 59-61.

ASERCA (Apoyos y Servicios a la Comercialización Agropecuaria). 2010. "Cobertura de riesgos en el sector agropecuario". En: Revista Claridades Agropecuarias, num. 201, Mayo 2010. 17 p Disponible: <http://www.aserca.gob.mx/sicsa/claridades/marcos.asp?numero=201>.

ASERCA (Apoyos y Servicios a la Comercialización Agropecuaria). 2014. "Hacia el Desarrollo Sostenible". En: Revista Claridades Agropecuarias, num. 249, Mayo 2014. 41 p Disponible: <http://www.infoaserca.gob.mx/claridades/revistas/249/ca249-40.pdf>

ASERCA (Apoyos y Servicios a la Comercialización Agropecuaria). 2016. Consulta. Disponible: <http://www.aserca.gob.mx/riesgos/Coberturas/Paginas/default.aspx>

Box, G.E.P.; Jenkins, G.M. and Reinsel, G.C. 2008. Time Series Analysis: Forecasting and Control. Ed. Wiley, Fourth Edition. USA. pp 746.

Colino, E.V.; Irwin, S.H. and Garcia, P. 2011. Improving the accuracy of outlook price forecasts. Agricultural Economics (USA). Vol. 42, No. 3: 357–371.

De Lara Haro, Alfonso. 2003. Medición y Control de Riesgos Financieros, Ed. Limusa, tercera edición, México pp. 11-13.

Díaz, T. J. y Venegas, M. F. 2001. Política Agrícola y Contratos de Futuros: Un Modelo de Arbitraje. Momento Económico (México), Núm. 115, Mayo-Junio de 2001: 2-21.

Dickey, D. A., and Fuller, W. A. 1979. Distribution of the estimators for autoregressive time series with a unit root. J.A.S.A. 74: 427-431.

Engle, R., and Granger, C. W. J. 1987. "Cointegration and Error Correction, Representation, Estimation and Testing", Econometrica, vol. 55, núm. 2.: 251-276.

Fama, E. F. 1970. Efficient Capital Markets: A Review of Theory and Empirical Work. The Journal of Finance (USA). Vol. 46, No. 5: 1575–1617.

Fama, E. F. 1991. Efficient Capital Markets: II. The Journal of Finance (USA). Vol. 25, No. 2: 383–417.

FINANCIERA RURAL. 2014. Dirección General Adjunta de Planeación Estratégica, Análisis Sectorial y Tecnologías de la Información. Mayo 2014, Disponible: <http://www.financierarural.gob.mx/informacionsectorrural/Panoramas/Ficha%20Ma%C3%ADz.pdf>

FIRA (Fideicomisos Instituidos en Relación con la Agricultura). 2015. Dirección de Investigación y Evaluación Económica y Sectorial. Octubre 2015, Disponible: https://www.gob.mx/cms/uploads/attachment/file/61952/Panorama_Agroalimentario_Ma_z_2015.pdf

Goodwin, B. K. 1992. "Forecasting Cattle Prices in the Presence of Structural Change." *Am. J. Agr. Econ.*, pp. 11-22.

Gujarati, D. N. 2004. *Econometría*. Ed. Mc Graw Hill, Cuarta Edición. México. pp 804.

Hamilton, J. D. 1994. *Time Series Analysis*. Princenton University Press. United States of America. 818 p.

Henkel, S. J., Martin, J. S. and Nardari F. 2011. "Time-varying short-horizon predictability". *Journal of Financial Economics*, 99: 560-580.

International Trade Administration (ITA-DOC). 2016. Consulta. Disponible: <http://www.trade.gov/mas/ian/tradestatistics/index.asp>

Johansen, S. 1988. "Statistical Analysis of Cointegration Vectors", *Journal of Economic Dynamics and Control*. Research Department of Statistics (Norway), 12: 231-254, 129.

Johansen, S. 1994. "The Role of the Constant and Linear Terms in Cointegration Analysis of Nonstationary Variables", *Econometric Reviews* 13(2): 205-229.

Martínez D., M. A. y García J., J. J. 2010. "Política de Coberturas de Precios de maíz en México". *Rev. Méx. de Ec. Agríc. y de los Rec. Nat. (México)*, Vol. 3, Núm. 2 (julio-diciembre 2010): 69-76.

Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO).2007. *Perspectivas Alimentarias. Análisis de los Mercados Mundiales*. Noviembre 2007. Disponible: <http://www.fao.org/docrep/010/ah876s/ah876s04.htm>

Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO). 2011. *Volatilidad de precios en los mercados agrícolas (2000-2010): "Implicaciones para América Latina y opciones de políticas"*. Disponible: www.rlc.fao.org/es/politicas/pdf/boletines/bol01.pdf

Organización para la Cooperación y el Desarrollo Económicos (OCDE). 2007. *Agricultural and Fisheries Policies in Mexico. "RECENT ACHIEVEMENTS, CONTINUING THE REFORM AGENDA"* Disponible: <http://www.sourceoecd.org/agriculture/9789264030268>

OECD/FAO (2014), OCDE-FAO Perspectivas Agrícolas 2014, OECD Publishing.
http://dx.doi.org/10.1787/agr_outlook-2014-es

Palma, M. M. L. 2004. Análisis económico de los mercados de futuros en el proceso de globalización financiera. Una aplicación al caso español (1990-1998). Volumen 143 de Tesis Doctorales. Universidad Almería. España. 840 p.

Pindyck, R., Rubinfeld, D. 1998. *Econometric Models and Economic Forecasts*. Fourth Edition. Boston, Mass: Irwin/McGraw-Hill. United States. 634 p.

Piot-Lepetit, I., M'Barek, R. 2011. *Methods to Analyse Agricultural Commodity Price Volatility*. Springer. New York, USA. 228 p.

SAGARPA (Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación). 2013. "Agricultura de autoconsumo", Consulta Disponible: www.sagarpa.gob.mx. Abril 2013.

SAGARPA-SFA (Subsecretaría de Fomento a los Agronegocios). 2011. *Perspectivas de largo plazo para el sector agropecuario de México 2011-2020*. Disponible: http://www.sagarpa.gob.mx/agronegocios/Documents/estudios_economicos/escenariobase/perspectivalp_11-20.pdf

Sims, C. A. 1980. *Macroeconomics and Reality*. *Econometrica* (USA). Vol. 48, No. 1: p 1–48.

Sanders, D. J. and Baker, T. G. 2012. "Forecasting Corn and Soybean Basis Using Regime-Switching Models" *Proceedings of the NCCC-134 Conference on Applied Commodity Price Analysis, Forecasting, and Market Risk Management* (St. Louis, MO, USA) [<http://www.farmdoc.illinois.edu/nccc134>]: pp. 1-18

Samuelson, P. A. 1965. "Proof That Properly Anticipated Prices Fluctuate Randomly" *Industrial Management Review* (USA). 6:2, p. 41
[http://lib.cufe.edu.cn/upload_files/file/20140522/3_20140522_4.Proof%20that%20Properly%20Anticipated%20Prices%20Fluctuate%20Randomly.pdf]

Trevor, A. R. and Vigfusson, R. J. 2011. "Evaluating the Forecasting Performance of Commodity Futures Prices", Board of Governors of the Federal Reserve System *International Finance Discussion Papers*. No.1025: pp. 1-19

ANEXOS

Serie de precios al mayoreo de maíz blanco, precio físico de maíz amarillo* y precio futuro de maíz amarillo**.

Mes	SINALOA	JALISCO	EDO MEX	MICHOACAN	GTO	USA*	FUSA**	Tc
jan-00	2.00	1.62	2.15	1.70	1.80	0.7238	0.8185	9.6253
feb-00	2.38	1.63	2.15	1.60	2.02	0.7301	0.8100	9.3662
mar-00	2.50	1.64	2.16	1.90	2.22	0.7420	0.8432	9.2845
apr-00	2.50	1.70	2.05	1.72	3.25	0.7523	0.8430	9.4127
may-00	2.50	1.70	2.18	1.76	1.90	0.7901	0.8968	9.5110
jun-00	2.50	1.70	2.12	1.78	1.98	0.7388	0.8042	9.8243
jul-00	2.50	1.70	2.18	1.76	2.08	0.6048	0.6810	9.3667
aug-00	2.50	1.70	2.14	1.70	1.89	0.5505	0.6458	9.1995
sep-00	2.42	1.70	2.02	1.74	1.92	0.5987	0.7176	9.4459
oct-00	2.50	1.70	2.08	1.71	1.90	0.6552	0.7688	9.5642
nov-00	2.08	1.62	2.12	1.73	1.90	0.6895	0.7809	9.4155
dec-00	1.85	1.60	2.05	1.80	1.85	0.7453	0.8410	9.6098
jan-01	2.10	1.68	2.10	1.72	1.96	0.7548	0.8348	9.6828
feb-01	2.00	1.70	2.08	1.75	2.00	0.7487	0.8072	9.7025
mar-01	2.05	1.66	2.08	1.71	2.00	0.7326	0.8010	9.4933
apr-01	2.00	1.65	2.08	1.80	2.05	0.6886	0.7490	9.2537
may-01	2.32	1.75	2.10	1.80	2.00	0.6580	0.7209	9.1835
jun-01	2.50	1.71	2.05	1.80	1.98	0.6285	0.6882	9.0708
jul-01	2.20	1.70	2.10	1.80	1.97	0.6730	0.7757	9.1408
aug-01	2.22	1.70	2.08	1.78	1.94	0.6882	0.7859	9.2000
sep-01	2.75	1.70	2.12	1.78	1.90	0.7151	0.8300	9.5098
oct-01	2.00	1.84	2.20	1.79	2.00	0.6704	0.7594	9.2542
nov-01	2.15	1.75	2.00	1.80	2.00	0.6750	0.7477	9.2681
dec-01	2.15	1.70	2.00	1.74	2.00	0.7148	0.7771	9.1695
jan-02	2.04	1.78	2.00	1.79	2.08	0.7094	0.7563	9.1463
feb-02	2.00	1.80	2.02	1.80	1.90	0.6938	0.7354	9.1303
mar-02	2.50	1.80	2.00	1.80	1.90	0.6886	0.7341	9.0160
apr-02	2.50	1.80	2.04	1.78	1.87	0.7047	0.7334	9.3720
may-02	2.50	1.80	1.98	1.70	1.85	0.7337	0.7919	9.6562
jun-02	2.50	1.72	1.99	1.78	1.88	0.7722	0.8309	9.9568
jul-02	2.50	1.76	1.97	1.80	1.88	0.8206	0.9069	9.7861
aug-02	2.50	1.85	2.00	1.80	1.92	0.9287	1.0121	9.9109
sep-02	2.00	1.80	2.10	1.78	2.00	0.9948	1.0960	10.2299

oct-02	2.10	1.90	2.04	1.87	2.00	0.9356	1.0092	10.1552
nov-02	2.50	1.90	2.05	1.80	2.00	0.9108	0.9695	10.1465
dec-02	2.50	1.90	2.10	1.90	1.98	0.9535	0.9712	10.4393
jan-03	2.74	1.82	2.14	1.92	1.94	1.0005	1.0125	10.9069
feb-03	3.00	1.90	2.12	2.00	1.90	1.0164	1.0381	11.0324
mar-03	3.00	2.00	2.18	2.00	2.00	0.9897	0.9909	10.7889
apr-03	3.00	1.96	2.02	1.96	2.08	0.9489	0.9672	10.3000
may-03	3.00	2.00	2.10	1.95	2.08	0.9687	0.9963	10.3377
jun-03	3.00	1.92	2.25	1.98	2.18	0.9615	0.9837	10.4370
jul-03	3.00	1.98	2.24	1.94	2.22	0.8991	0.8799	10.5243
aug-03	3.00	2.10	2.20	2.05	2.25	0.9351	0.9586	11.0475
sep-03	3.00	2.08	2.22	2.12	2.30	0.9539	1.0033	11.0133
oct-03	3.00	2.00	2.22	2.10	2.28	0.9225	0.9817	11.0525
nov-03	3.00	2.00	2.22	2.00	2.28	0.9873	1.0636	11.3985
dec-03	3.00	2.06	2.22	2.10	2.16	1.0220	1.0963	11.2372
jan-04	3.05	2.05	2.31	2.00	2.18	1.0371	1.1572	11.0214
feb-04	3.00	2.20	2.19	1.95	2.10	1.1365	1.2319	11.0606
mar-04	3.00	2.20	2.15	1.92	2.08	1.2099	1.3432	11.1748
apr-04	3.00	2.15	2.20	1.95	2.20	1.2981	1.4176	11.4093
may-04	3.00	2.10	2.28	2.00	2.25	1.2898	1.3576	11.4147
jun-04	3.00	2.20	2.30	2.04	2.18	1.2660	1.2987	11.5258
jul-04	3.00	2.20	2.30	2.20	2.25	1.1273	1.0662	11.4079
aug-04	3.00	2.20	2.42	2.05	2.50	1.0485	1.0068	11.3807
sep-04	3.00	2.28	2.54	2.00	2.48	0.9864	0.9775	11.3884
oct-04	3.00	2.25	2.30	2.00	2.48	0.9722	0.9312	11.5390
nov-04	3.00	2.12	2.50	2.00	2.40	0.9069	0.8801	11.2373
dec-04	3.00	2.02	2.60	2.24	2.35	0.8955	0.9001	11.1495
jan-05	3.00	1.98	2.20	2.35	2.08	0.9360	0.8836	11.2141
feb-05	3.00	1.90	2.12	2.42	2.00	0.8519	0.8752	11.0965
mar-05	3.00	1.82	2.20	2.40	2.04	0.8890	0.9564	11.1783
apr-05	3.00	1.85	2.18	2.47	2.05	0.8727	0.9071	11.0832
may-05	3.00	1.92	2.14	2.60	2.00	0.8509	0.9109	10.9160
jun-05	3.00	1.90	2.19	2.54	2.00	0.8612	0.9411	10.7752
jul-05	3.00	1.90	2.14	2.60	2.05	0.8810	1.0025	10.6057
aug-05	3.00	1.90	2.20	2.60	2.00	0.8291	0.9148	10.7995
sep-05	3.00	1.80	2.15	2.75	2.00	0.8072	0.8916	10.7907
oct-05	3.00	1.90	2.20	2.80	2.15	0.7728	0.8580	10.7857
nov-05	3.00	1.98	2.20	2.80	2.08	0.7372	0.8038	10.5793
dec-05	3.00	1.90	2.12	2.80	2.00	0.8039	0.8721	10.6344

jan-06	3.00	2.10	2.12	2.80	2.00	0.8223	0.8774	10.4433
feb-06	3.00	2.10	2.15	2.80	2.00	0.8315	0.9178	10.4560
mar-06	3.00	2.00	2.20	2.80	2.00	0.8835	0.9773	10.8935
apr-06	3.00	2.30	2.32	2.80	2.28	0.9213	1.0340	11.0903
may-06	3.00	2.24	2.58	2.76	2.35	0.9651	1.1117	11.2966
jun-06	3.00	2.30	2.50	2.40	2.30	0.9497	1.0568	11.2723
jul-06	3.00	2.32	2.45	2.50	2.40	0.9199	1.0683	10.9181
aug-06	3.00	2.26	2.66	2.50	2.46	0.8972	0.9864	10.9037
sep-06	3.00	2.40	2.80	2.55	2.45	0.9522	1.0757	10.9935
oct-06	3.00	2.52	2.75	2.50	2.48	1.0806	1.2852	10.7640
nov-06	3.00	2.70	2.76	2.50	2.50	1.2470	1.5406	10.9975
dec-06	3.25	3.00	2.80	2.50	2.40	1.2812	1.6019	10.8116
jan-07	4.10	3.20	3.57	3.00	3.60	1.3255	1.6985	11.0382
feb-07	4.50	3.50	3.58	3.50	3.55	1.5125	1.8081	11.1682
mar-07	4.50	3.50	3.50	3.50	3.50	1.4898	1.7662	11.0322
apr-07	4.50	3.50	3.56	3.50	3.50	1.4585	1.5564	10.9278
may-07	4.50	3.30	3.36	3.50	3.50	1.4763	1.5836	10.7445
jun-07	4.08	3.28	3.24	3.50	3.62	1.5002	1.6191	10.7946
jul-07	3.50	3.08	3.29	3.50	3.62	1.4283	1.4178	10.9273
aug-07	3.40	3.16	3.35	3.50	3.50	1.4167	1.4379	11.0378
sep-07	3.60	3.10	3.50	3.30	3.45	1.4116	1.5434	10.9315
oct-07	3.50	3.36	3.36	3.30	3.46	1.3862	1.5078	10.7023
nov-07	3.50	3.32	3.17	3.40	3.00	1.4758	1.6369	10.8968
dec-07	3.28	3.22	2.85	3.50	3.00	1.6202	1.8584	10.9157
jan-08	3.46	2.96	3.16	3.50	3.20	1.6964	2.0824	10.8262
feb-08	3.00	3.05	3.27	3.50	3.15	1.9169	2.1790	10.7243
mar-08	3.15	3.20	3.30	3.50	3.28	1.9703	2.3189	10.6482
apr-08	3.36	3.44	3.47	3.50	3.50	2.1267	2.4551	10.5095
may-08	3.30	3.60	3.50	3.50	3.50	2.1434	2.4525	10.3306
jun-08	3.20	3.50	3.60	3.50	3.75	2.2196	2.8360	10.3069
jul-08	3.44	3.79	3.70	3.50	3.92	2.0742	2.5530	10.0353
aug-08	4.05	4.00	3.50	3.50	4.20	2.1298	2.2243	10.2847
sep-08	3.52	4.00	3.75	3.50	4.20	2.1703	2.3619	10.9814
oct-08	4.30	3.92	3.74	3.56	4.04	2.1872	2.0652	12.7125
nov-08	3.80	3.80	3.70	3.80	3.90	2.2344	1.9607	13.3225
dec-08	3.36	3.85	3.50	3.80	3.60	2.2328	2.0114	13.8325
jan-09	3.58	3.72	3.47	3.80	3.58	2.4563	2.2026	14.3097
feb-09	3.58	3.65	3.50	3.80	3.50	2.2961	2.1470	15.0698
mar-09	3.60	3.50	3.50	3.80	3.50	2.1450	2.1198	14.1517

apr-09	3.60	3.62	3.40	3.80	3.74	2.0984	2.1106	13.8443
may-09	3.60	3.50	3.40	3.80	3.80	2.0528	2.1854	13.1667
jun-09	3.60	3.50	3.60	3.80	3.85	2.0795	2.1390	13.1722
jul-09	3.64	3.50	3.60	3.80	3.72	1.8726	1.7037	13.2125
aug-09	3.80	3.50	3.58	3.80	3.63	1.7455	1.7148	13.3140
sep-09	3.08	3.50	3.64	4.06	3.73	1.7264	1.7268	13.4928
oct-09	3.15	3.45	3.50	5.13	3.90	1.8687	1.9257	13.1479
nov-09	3.20	3.50	3.65	6.00	4.00	1.8560	1.9828	12.9157
dec-09	3.25	3.50	3.50	6.00	3.62	1.8519	2.0703	13.0659
jan-10	3.43	3.52	3.50	5.33	3.63	1.8746	1.9764	13.0098
feb-10	3.38	3.60	3.50	5.00	3.62	1.7857	1.8249	12.7769
mar-10	3.40	3.60	3.50	5.00	3.50	1.7234	1.7874	12.3306
apr-10	3.52	3.60	3.50	5.00	3.68	1.6463	1.7092	12.2626
may-10	3.50	3.58	3.50	5.00	3.80	1.7694	1.8720	12.9146
jun-10	3.44	3.60	3.46	5.00	3.82	1.7243	1.7536	12.8441
jul-10	3.05	3.45	3.40	5.00	3.75	1.7375	1.8837	12.6455
aug-10	3.75	3.52	3.30	5.00	3.58	1.8922	2.1183	13.1676
sep-10	3.66	3.60	3.30	4.20	3.52	2.0239	2.4265	12.5998
oct-10	3.43	3.80	3.40	4.00	3.50	2.0986	2.6501	12.3387
nov-10	3.32	4.00	3.50	4.00	3.38	2.2332	2.7105	12.4664
dec-10	3.40	4.00	3.50	4.00	3.35	2.3435	2.8784	12.3496
jan-11	3.60	4.00	3.60	4.00	3.60	2.3634	3.0391	12.1519
feb-11	4.42	4.38	3.90	4.10	4.00	2.6929	3.2908	12.1062
mar-11	5.92	5.16	5.42	5.00	4.50	2.5927	3.2180	11.9084
apr-11	7.00	5.30	5.30	5.00	4.00	2.8865	3.4179	11.5278
may-11	7.00	5.35	5.30	5.25	4.00	2.8808	3.2979	11.5780
jun-11	7.00	5.46	5.30	5.50	4.00	2.9446	3.3265	11.7230
jul-11	7.00	5.70	5.35	5.50	4.25	2.9264	3.0889	11.7425
aug-11	7.00	5.60	6.08	5.50	5.00	3.3447	3.4681	12.3480
sep-11	7.00	5.50	6.28	5.40	5.00	3.4661	3.7697	13.7994
oct-11	7.00	5.58	5.92	5.70	5.00	2.9733	3.2801	13.1802
nov-11	7.00	5.60	5.86	5.70	4.88	3.1239	3.3598	13.6100
dec-11	7.00	5.70	6.35	5.75	5.00	3.2178	3.3273	13.9476
jan-12	7.00	5.80	5.80	6.15	5.00	3.1085	3.2307	13.0077
feb-12	6.80	5.80	5.98	5.80	6.00	3.1620	3.2244	12.7891
mar-12	5.62	5.80	5.93	5.80	6.00	3.2023	3.2656	12.8093
apr-12	5.12	5.80	5.80	5.65	6.00	3.2434	3.2432	12.9942
may-12	5.32	5.80	5.80	5.50	6.00	3.5705	3.3848	14.3047
jun-12	5.00	5.50	5.50	5.52	6.25	3.3627	3.1842	13.4084

jul-12	3.88	5.18	5.40	5.60	6.00	3.7340	3.9707	13.2833
aug-12	3.00	5.20	5.38	5.60	6.00	3.9823	4.1940	13.2571
sep-12	3.75	5.20	5.50	5.40	6.00	3.4910	3.8679	12.8695
oct-12	4.76	5.40	5.74	5.20	5.50	3.4944	3.8661	13.0911
nov-12	4.80	5.30	4.90	5.20	5.00	3.5676	3.7666	12.9268
dec-12	4.58	5.32	4.95	4.82	5.00	3.5069	3.6790	12.9658
jan-13	4.50	5.36	5.00	4.76	5.00	3.4826	3.5759	12.7094
feb-13	4.50	5.30	5.00	4.80	5.25	3.5420	3.5572	12.7795
mar-13	4.70	5.35	5.00	4.80	5.25	3.4699	3.4815	12.3612
apr-13	4.58	4.94	5.00	4.80	5.00	3.3329	3.1010	12.1456
may-13	4.00	5.20	5.00	4.80	5.00	3.5134	3.2839	12.8035
jun-13	4.00	4.75	4.85	4.80	5.00	3.5750	3.3968	13.0279
jul-13	4.00	4.90	5.00	4.80	5.00	3.4341	2.6704	12.8464
aug-13	4.00	5.12	5.20	4.80	5.00	3.2618	2.5379	13.3415
sep-13	4.00	5.00	5.40	4.76	5.00	2.8009	2.3835	13.1747
oct-13	4.20	5.00	5.48	4.78	6.00	2.3709	2.2488	13.0067
nov-13	4.50	5.00	4.70	4.80	6.00	2.2556	2.1833	13.1101
dec-13	4.50	4.82	4.50	4.44	6.00	2.2717	2.2175	13.0843
jan-14	4.25	4.62	5.20	4.05	6.00	2.3278	2.2500	13.3769
feb-14	4.50	4.25	4.94	3.80	5.50	2.2671	2.3312	13.2379
mar-14	4.80	4.38	5.00	3.80	5.00	2.3232	2.4953	13.0549
apr-14	4.84	4.20	5.00	3.84	5.00	2.4273	2.5871	13.0901
may-14	5.00	3.90	5.05	4.30	5.00	2.3848	2.4818	12.8609
jun-14	4.33	4.27	4.50	4.22	5.00	2.2980	2.2810	12.9712
jul-14	4.20	5.20	4.60	4.36	5.00	2.1142	1.9731	13.2269
aug-14	4.75	4.90	4.55	4.40	5.00	1.8688	1.8500	13.0763
sep-14	4.00	4.50	4.50	4.25	5.00	1.8404	1.7918	13.4330
oct-14	4.40	4.50	4.66	4.10	5.00	1.8889	1.8540	13.4773
nov-14	4.00	4.50	4.58	4.10	5.00	1.9586	2.0416	13.8965
dec-14	4.00	4.70	4.46	3.90	5.00	2.1938	2.3299	14.7414
jan-15	4.00	5.00	4.50	3.85	4.25	2.2483	2.2896	14.9885
feb-15	4.50	4.92	4.80	3.80	4.38	2.2315	2.2591	14.9553
mar-15	4.50	4.60	4.62	3.82	5.00	2.2897	2.3210	15.2647
apr-15	4.00	4.36	4.50	4.00	5.00	2.2694	2.2666	15.3714
may-15	3.65	4.58	4.50	4.00	5.00	2.2043	2.1922	15.3815
jun-15	3.60	4.50	4.50	4.00	4.50	2.2170	2.2503	15.6854
jul-15	3.50	4.50	4.42	4.10	4.10	2.4053	2.5915	16.0772
aug-15	3.55	4.62	4.90	4.30	4.00	2.4315	2.4297	16.7829
sep-15	3.64	5.00	4.90	4.28	4.00	2.4493	2.5255	16.9053

Modelos ARIMA estimados

Dependent Variable: D(SINALOAP,1)
 Method: Least Squares
 Date: 03/30/16 Time: 17:03
 Sample (adjusted): 2000M02 2015M08
 Included observations: 187 after adjustments
 Convergence achieved after 6 iterations
 MA Backcast: 2000M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.008644	0.028465	0.303674	0.7617
MA(1)	0.203661	0.071960	2.830212	0.0052
R-squared	0.034749	Mean dependent var		0.008289
Adjusted R-squared	0.029531	S.D. dependent var		0.328534
S.E. of regression	0.323647	Akaike info criterion		0.592310
Sum squared resid	19.37825	Schwarz criterion		0.626867
Log likelihood	-53.38098	Hannan-Quinn criter.		0.606313
F-statistic	6.659894	Durbin-Watson stat		2.022738
Prob(F-statistic)	0.010636			
Inverted MA Roots	-20			

Dependent Variable: D(JALISCO,1)
 Method: Least Squares
 Date: 06/08/16 Time: 21:46
 Sample (adjusted): 2001M05 2015M08
 Included observations: 172 after adjustments
 Convergence achieved after 6 iterations
 MA Backcast: 2001M04

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.016680	0.012464	1.338167	0.1826
AR(15)	-0.206876	0.092299	-2.241371	0.0263
MA(1)	0.176436	0.076563	2.304462	0.0224
R-squared	0.047177	Mean dependent var		0.017267
Adjusted R-squared	0.035901	S.D. dependent var		0.170884
S.E. of regression	0.167788	Akaike info criterion		-0.714940
Sum squared resid	4.757841	Schwarz criterion		-0.660042
Log likelihood	64.48482	Hannan-Quinn criter.		-0.692666
F-statistic	4.183849	Durbin-Watson stat		2.035510
Prob(F-statistic)	0.016847			
Inverted AR Roots	.88+.19i	.88-.19i	.73+.53i	.73-.53i
	.45-.78i	.45+.78i	.09-.90i	.09+.90i
	-.28-.86i	-.28+.86i	-.60+.67i	-.60-.67i
	-.82-.37i	-.82+.37i	-.90	
Inverted MA Roots	-.18			

Dependent Variable: D(EDOMEX,1)
 Method: Least Squares
 Date: 06/09/16 Time: 02:17
 Sample (adjusted): 2002M07 2015M08
 Included observations: 158 after adjustments
 Convergence achieved after 8 iterations
 MA Backcast: 2002M02 2002M06

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.017792	0.014367	1.238412	0.2175
AR(20)	-0.200017	0.083548	-2.394043	0.0179
AR(27)	-0.264949	0.088223	-3.003154	0.0031
AR(29)	0.215461	0.088478	2.435183	0.0160
MA(1)	-0.140724	0.080575	-1.746509	0.0827
MA(5)	0.178332	0.081614	2.185069	0.0304
R-squared	0.152652	Mean dependent var		0.018418
Adjusted R-squared	0.124779	S.D. dependent var		0.233351
S.E. of regression	0.218308	Akaike info criterion		-0.168586
Sum squared resid	7.244065	Schwarz criterion		-0.052285
Log likelihood	19.31831	Hannan-Quinn criter.		-0.121355
F-statistic	5.476651	Durbin-Watson stat		1.930379
Prob(F-statistic)	0.000115			
Inverted AR Roots	.93-.15i	.93+.15i	.87-.38i	.87+.38i
	.82	.77-.54i	.77+.54i	.66-.71i
	.66+.71i	.47-.86i	.47+.86i	.26-.93i
	.26+.93i	.07-.97i	.07+.97i	-.16+.97i
	-.16-.97i	-.38+.89i	-.38-.89i	-.55+.78i
	-.55-.78i	-.71-.65i	-.71+.65i	-.85-.45i
	-.85+.45i	-.87-.23i	-.87+.23i	-.89-.11i
	-.89+.11i			
Inverted MA Roots	.60-.41i	-.19+.67i	-.19-.67i	
	-.68			

Dependent Variable: D(MICHOACAN,1)
 Method: Least Squares
 Date: 04/04/16 Time: 00:49
 Sample (adjusted): 2001M01 2015M08
 Included observations: 176 after adjustments
 Convergence achieved after 7 iterations
 MA Backcast: 2000M10 2000M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.014383	0.012409	1.159051	0.2480
AR(1)	0.313714	0.071026	4.416870	0.0000
AR(11)	-0.192787	0.071034	-2.713994	0.0073
MA(3)	-0.201322	0.075051	-2.682481	0.0080
R-squared	0.154668	Mean dependent var		0.014205
Adjusted R-squared	0.139924	S.D. dependent var		0.194465
S.E. of regression	0.180347	Akaike info criterion		-0.565402
Sum squared resid	5.594310	Schwarz criterion		-0.493346
Log likelihood	53.75541	Hannan-Quinn criter.		-0.536177
F-statistic	10.49016	Durbin-Watson stat		1.914238
Prob(F-statistic)	0.000002			
Inverted AR Roots	.86+.24i	.86-.24i	.60-.65i	.60+.65i
	.15-.85i	.15+.85i	-.33-.78i	-.33+.78i
	-.70+.46i	-.70-.46i	-.84	
Inverted MA Roots	.59	-.29-.51i	-.29+.51i	

Dependent Variable: D(GTO,1)
 Method: Least Squares
 Date: 06/09/16 Time: 02:55
 Sample (adjusted): 2000M06 2015M08
 Included observations: 183 after adjustments
 Convergence achieved after 6 iterations
 MA Backcast: 1999M02 2000M05

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.011198	0.016214	0.690688	0.4907
AR(4)	-0.128162	0.064922	-1.974091	0.0499
MA(16)	0.138512	0.079678	1.738406	0.0838
R-squared	0.039679	Mean dependent var		0.011475
Adjusted R-squared	0.029009	S.D. dependent var		0.222574
S.E. of regression	0.219322	Akaike info criterion		-0.180298
Sum squared resid	8.658353	Schwarz criterion		-0.127683
Log likelihood	19.49724	Hannan-Quinn criter.		-0.158970
F-statistic	3.718647	Durbin-Watson stat		1.812920
Prob(F-statistic)	0.026151			
Inverted AR Roots	.42-.42i	.42+.42i	-.42+.42i	-.42-.42i
Inverted MA Roots	.87+.17i	.87-.17i	.73-.49i	.73+.49i
	.49+.73i	.49-.73i	.17+.87i	.17-.87i
	-.17+.87i	-.17-.87i	-.49-.73i	-.49+.73i
	-.73+.49i	-.73-.49i	-.87-.17i	-.87+.17i

Pruebas de raíz unitaria (ADF)

Null Hypothesis: SINALOAP has a unit root
 Exogenous: Constant
 Lag Length: 1 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.425803	0.1361
Test critical values:		
1% level	-3.465585	
5% level	-2.876927	
10% level	-2.575051	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(SINALOAP)
 Method: Least Squares
 Date: 01/11/17 Time: 01:20
 Sample (adjusted): 2000M03 2015M08
 Included observations: 186 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
SINALOAP(-1)	-0.049507	0.020409	-2.425803	0.0162
D(SINALOAP(-1))	0.191324	0.072012	2.656814	0.0086
C	0.181903	0.076643	2.373377	0.0187
R-squared	0.059220	Mean dependent var		0.006290
Adjusted R-squared	0.048939	S.D. dependent var		0.328279
S.E. of regression	0.320146	Akaike info criterion		0.575916
Sum squared resid	18.75627	Schwarz criterion		0.627945
Log likelihood	-50.56023	Hannan-Quinn criter.		0.597000
F-statistic	5.759760	Durbin-Watson stat		1.971439
Prob(F-statistic)	0.003751			

Null Hypothesis: JALISCO has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.964179	0.7656
Test critical values:		
1% level	-3.465392	
5% level	-2.876843	
10% level	-2.575006	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(JALISCO)
 Method: Least Squares
 Date: 01/11/17 Time: 01:22
 Sample (adjusted): 2000M02 2015M08
 Included observations: 187 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
JALISCO(-1)	-0.008542	0.008859	-0.964179	0.3362
C	0.043843	0.031235	1.403666	0.1621
R-squared	0.005000	Mean dependent var		0.016043
Adjusted R-squared	-0.000378	S.D. dependent var		0.164213
S.E. of regression	0.164244	Akaike info criterion		-0.764286
Sum squared resid	4.990593	Schwarz criterion		-0.729729
Log likelihood	73.46077	Hannan-Quinn criter.		-0.750284
F-statistic	0.929641	Durbin-Watson stat		1.749645
Prob(F-statistic)	0.336215			

Null Hypothesis: EDOMEX has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.054864	0.7331
Test critical values:		
1% level	-3.465392	
5% level	-2.876843	
10% level	-2.575006	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(EDOMEX)
 Method: Least Squares
 Date: 01/11/17 Time: 01:23
 Sample (adjusted): 2000M02 2015M08
 Included observations: 187 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
EDOMEX(-1)	-0.013122	0.012439	-1.054864	0.2929
C	0.059025	0.044886	1.314985	0.1901
R-squared	0.005979	Mean dependent var		0.014706
Adjusted R-squared	0.000606	S.D. dependent var		0.216117
S.E. of regression	0.216052	Akaike info criterion		-0.215957
Sum squared resid	8.635518	Schwarz criterion		-0.181400
Log likelihood	22.19202	Hannan-Quinn criter.		-0.201955
F-statistic	1.112738	Durbin-Watson stat		2.110084
Prob(F-statistic)	0.292863			

Null Hypothesis: GTO has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.539934	0.5113
Test critical values:		
1% level	-3.465392	
5% level	-2.876843	
10% level	-2.575006	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(GTO)
 Method: Least Squares
 Date: 01/11/17 Time: 01:24
 Sample (adjusted): 2000M02 2015M08
 Included observations: 187 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
GTO(-1)	-0.021576	0.014011	-1.539934	0.1253
C	0.084386	0.050656	1.665864	0.0974
R-squared	0.012656	Mean dependent var		0.011765
Adjusted R-squared	0.007319	S.D. dependent var		0.253853
S.E. of regression	0.252923	Akaike info criterion		0.099171
Sum squared resid	11.83442	Schwarz criterion		0.133728
Log likelihood	-7.272493	Hannan-Quinn criter.		0.113174
F-statistic	2.371396	Durbin-Watson stat		2.033094
Prob(F-statistic)	0.125285			

Null Hypothesis: MICHOACAN has a unit root
 Exogenous: Constant
 Lag Length: 1 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.593749	0.4838
Test critical values:		
1% level	-3.465585	
5% level	-2.876927	
10% level	-2.575051	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(MICHOACAN)
 Method: Least Squares
 Date: 01/11/17 Time: 01:23
 Sample (adjusted): 2000M03 2015M08
 Included observations: 186 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MICHOACAN(-1)	-0.016083	0.010091	-1.593749	0.1127
D(MICHOACAN(-1))	0.308989	0.070154	4.404429	0.0000
C	0.064774	0.036523	1.773505	0.0778
R-squared	0.104321	Mean dependent var		0.014516
Adjusted R-squared	0.094532	S.D. dependent var		0.191020
S.E. of regression	0.181767	Akaike info criterion		-0.556182
Sum squared resid	6.046197	Schwarz criterion		-0.504154
Log likelihood	54.72493	Hannan-Quinn criter.		-0.535098
F-statistic	10.65713	Durbin-Watson stat		1.918797
Prob(F-statistic)	0.000042			

Null Hypothesis: USA has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.054205	0.7333
Test critical values:		
1% level	-3.465392	
5% level	-2.876843	
10% level	-2.575006	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(USA)
 Method: Least Squares
 Date: 01/11/17 Time: 01:25
 Sample (adjusted): 2000M02 2015M08
 Included observations: 187 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
USA(-1)	-0.010277	0.009749	-1.054205	0.2932
C	0.026640	0.018836	1.414323	0.1589
R-squared	0.005971	Mean dependent var		0.009132
Adjusted R-squared	0.000598	S.D. dependent var		0.121562
S.E. of regression	0.121526	Akaike info criterion		-1.366740
Sum squared resid	2.732185	Schwarz criterion		-1.332182
Log likelihood	129.7902	Hannan-Quinn criter.		-1.352737
F-statistic	1.111347	Durbin-Watson stat		1.756202
Prob(F-statistic)	0.293164			

Null Hypothesis: FUSA has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=14)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.288759	0.6347
Test critical values:		
1% level	-3.465392	
5% level	-2.876843	
10% level	-2.575006	

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

Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(FUSA)
 Method: Least Squares
 Date: 01/11/17 Time: 01:25
 Sample (adjusted): 2000M02 2015M08
 Included observations: 187 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
FUSA(-1)	-0.015855	0.012302	-1.288759	0.1991
C	0.037066	0.024880	1.489817	0.1380
R-squared	0.008898	Mean dependent var		0.008616
Adjusted R-squared	0.003541	S.D. dependent var		0.157191
S.E. of regression	0.156913	Akaike info criterion		-0.855614
Sum squared resid	4.555008	Schwarz criterion		-0.821057
Log likelihood	81.99991	Hannan-Quinn criter.		-0.841611
F-statistic	1.660899	Durbin-Watson stat		1.821621
Prob(F-statistic)	0.199091			

Pruebas de Cointegración

Date: 01/11/17 Time: 01:27
 Sample (adjusted): 2000M06 2015M08
 Included observations: 183 after adjustments
 Trend assumption: Linear deterministic trend
 Series: SINALOAP USA FUSA
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.211864	63.85289	29.79707	0.0000
At most 1 *	0.090530	20.28334	15.49471	0.0088
At most 2	0.015818	2.917901	3.841466	0.0876

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.211864	43.56956	21.13162	0.0000
At most 1 *	0.090530	17.36544	14.26460	0.0157
At most 2	0.015818	2.917901	3.841466	0.0876

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b**S11*b=l):

SINALOAP	USA	FUSA
-0.152210	-9.707876	9.744799
1.645165	-0.298304	-1.463972
0.202876	1.166679	-0.251709

Date: 01/11/17 Time: 01:37
 Sample (adjusted): 2000M04 2015M08
 Included observations: 185 after adjustments
 Trend assumption: Linear deterministic trend
 Series: JALISCO USA FUSA
 Lags interval (in first differences): 1 to 2

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.291062	83.88413	29.79707	0.0000
At most 1 *	0.095837	20.24649	15.49471	0.0089
At most 2	0.008657	1.608517	3.841466	0.2047

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.291062	63.63765	21.13162	0.0000
At most 1 *	0.095837	18.63797	14.26460	0.0095
At most 2	0.008657	1.608517	3.841466	0.2047

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b**S11*b=l):

JALISCO	USA	FUSA
0.207717	-7.777962	7.366752
2.602434	-2.994524	-0.997931
0.680928	0.007594	0.089814

Date: 01/11/17 Time: 01:38
 Sample (adjusted): 2000M10 2015M08
 Included observations: 179 after adjustments
 Trend assumption: Linear deterministic trend
 Series: EDOMEX USA FUSA
 Lags interval (in first differences): 1 to 8

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.249338	64.97808	29.79707	0.0000
At most 1	0.064070	13.64096	15.49471	0.0933
At most 2	0.009942	1.788571	3.841466	0.1811

Trace test indicates 1 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **Mackinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.249338	51.33712	21.13162	0.0000
At most 1	0.064070	11.85239	14.26460	0.1163
At most 2	0.009942	1.788571	3.841466	0.1811

Max-eigenvalue test indicates 1 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **Mackinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b*S11*b=I):

	USA	FUSA
EDOMEX	0.495115	15.31195
	-16.17957	
	3.009405	-3.711631
	-0.578719	
	0.717160	-0.348895
	0.494069	

Date: 01/11/17 Time: 01:39
 Sample (adjusted): 2001M05 2015M08
 Included observations: 172 after adjustments
 Trend assumption: Linear deterministic trend
 Series: MICHOACAN USA FUSA
 Lags interval (in first differences): 1 to 15

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.183780	52.75195	29.79707	0.0000
At most 1 *	0.087535	17.82375	15.49471	0.0219
At most 2	0.011949	2.067561	3.841466	0.1505

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **Mackinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.183780	34.92820	21.13162	0.0003
At most 1 *	0.087535	15.75619	14.26460	0.0288
At most 2	0.011949	2.067561	3.841466	0.1505

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **Mackinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b*S11*b=I):

	USA	FUSA
MICHOACAN	3.607635	4.691186
	-10.70843	
	2.502061	-32.48738
	29.33590	
	1.367826	-1.045440
	0.162004	

Date: 01/11/17 Time: 01:40
 Sample (adjusted): 2000M06 2015M08
 Included observations: 183 after adjustments
 Trend assumption: Linear deterministic trend
 Series: GTO USA FUSA
 Lags interval (in first differences): 1 to 4

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.232629	71.20499	29.79707	0.0000
At most 1 *	0.109781	22.74944	15.49471	0.0034
At most 2	0.007994	1.468808	3.841466	0.2255

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **Mackinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.232629	48.45555	21.13162	0.0000
At most 1 *	0.109781	21.28063	14.26460	0.0033
At most 2	0.007994	1.468808	3.841466	0.2255

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
 * denotes rejection of the hypothesis at the 0.05 level
 **Mackinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b*S11*b=I):

	USA	FUSA
GTO	-0.380678	8.057683
	-7.540385	
	-2.276069	-2.700965
	6.063977	
	-0.503872	-0.322377
	-0.083190	

Modelos VAR estimados

Dependent Variable: SINALOAP

Method: Least Squares

Date: 07/19/16 Time: 23:47

Sample (adjusted): 2000M05 2015M08

Included observations: 184 after adjustments

SINALOAP = C(1)*SINALOAP(-1) + C(2)*SINALOAP(-2) + C(3)*SINALOAP(-3) + C(4)*SINALOAP(-4) + C(5)*USA(-1) + C(6)*USA(-2) + C(7)*USA(-3) + C(8)*USA(-4) + C(9)*FUSA(-1) + C(10)*FUSA(-2) + C(11)*FUSA(-3) + C(12)*FUSA(-4) + C(13)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	1.021629	0.077354	13.20715	0.0000
C(2)	-0.229010	0.109512	-2.091176	0.0380
C(3)	0.110328	0.107696	1.024440	0.3071
C(4)	-0.037423	0.074806	-0.500270	0.6175
C(5)	-0.789059	0.316893	-2.489985	0.0137
C(6)	0.322624	0.410920	0.785127	0.4335
C(7)	-0.353656	0.412885	-0.856549	0.3929
C(8)	0.261845	0.280044	0.935016	0.3511
C(9)	0.478183	0.227336	2.103417	0.0369
C(10)	0.284925	0.316932	0.899009	0.3699
C(11)	-0.044523	0.318454	-0.139809	0.8890
C(12)	-0.037690	0.239052	-0.157663	0.8749
C(13)	0.219558	0.080766	2.718454	0.0072
R-squared	0.936807	Mean dependent var		3.596467
Adjusted R-squared	0.932372	S.D. dependent var		1.159690
S.E. of regression	0.301581	Akaike info criterion		0.508476
Sum squared resid	15.55264	Schwarz criterion		0.735618
Log likelihood	-33.77979	Hannan-Quinn criter.		0.600540
F-statistic	211.2497	Durbin-Watson stat		1.999998
Prob(F-statistic)	0.000000			

Dependent Variable: JALISCO

Method: Least Squares

Date: 07/17/16 Time: 22:18

Sample (adjusted): 2000M03 2015M08

Included observations: 186 after adjustments

JALISCO = C(1)*JALISCO(-1) + C(2)*JALISCO(-2) + C(3)*USA(-1) + C(4)*USA(-2) + C(5)*FUSA(-1) + C(6)*FUSA(-2) + C(7)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.973868	0.074751	13.02809	0.0000
C(2)	-0.062892	0.075014	-0.838405	0.4029
C(3)	-0.206054	0.153648	-1.341082	0.1816
C(4)	-0.014240	0.143404	-0.099301	0.9210
C(5)	0.225335	0.113137	1.991696	0.0479
C(6)	0.116751	0.118869	0.982181	0.3273
C(7)	0.067407	0.033649	2.003232	0.0467
R-squared	0.987827	Mean dependent var		3.279570
Adjusted R-squared	0.987419	S.D. dependent var		1.356008
S.E. of regression	0.152095	Akaike info criterion		-0.891710
Sum squared resid	4.140806	Schwarz criterion		-0.770311
Log likelihood	89.92907	Hannan-Quinn criter.		-0.842515
F-statistic	2420.998	Durbin-Watson stat		1.965551
Prob(F-statistic)	0.000000			

Dependent Variable: EDOMEX

Method: Least Squares

Date: 06/28/16 Time: 15:36

Sample (adjusted): 2000M09 2015M08

Included observations: 180 after adjustments

EDOMEX = C(1)*EDOMEX(-1) + C(2)*EDOMEX(-2) + C(3)*EDOMEX(-3) + C(4)*EDOMEX(-4) + C(5)*EDOMEX(-5) + C(6)*EDOMEX(-6) + C(7)*EDOMEX(-7) + C(8)*EDOMEX(-8) + C(9)*USA(-1) + C(10)*USA(-2) + C(11)*USA(-3) + C(12)*USA(-4) + C(13)*USA(-5) + C(14)*USA(-6) + C(15)*USA(-7) + C(16)*USA(-8) + C(17)*FUSA(-1) + C(18)*FUSA(-2) + C(19)*FUSA(-3) + C(20)*FUSA(-4) + C(21)*FUSA(-5) + C(22)*FUSA(-6) + C(23)*FUSA(-7) + C(24)*FUSA(-8) + C(25)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.777199	0.081395	9.548477	0.0000
C(2)	-0.098376	0.102006	-0.964417	0.3363
C(3)	0.251336	0.102654	2.448388	0.0155
C(4)	-0.017130	0.105406	-0.162514	0.8711
C(5)	0.176887	0.104892	1.686377	0.0937
C(6)	-0.049756	0.106822	-0.465780	0.6420
C(7)	-0.058567	0.108984	-0.537389	0.5918
C(8)	-0.126749	0.082627	-1.533990	0.1271
C(9)	0.242528	0.242261	1.001101	0.3183
C(10)	-0.165796	0.317345	-0.522447	0.6021
C(11)	-0.151078	0.323349	-0.467230	0.6410
C(12)	0.081978	0.324292	0.252789	0.8008
C(13)	-0.046609	0.327384	-0.142367	0.8870
C(14)	-0.132997	0.320727	-0.414673	0.6790
C(15)	-0.052834	0.314488	-0.167999	0.8668
C(16)	0.293845	0.212008	1.386009	0.1677
C(17)	0.091490	0.170406	0.536893	0.5921
C(18)	0.011182	0.240320	0.046529	0.9629
C(19)	0.315984	0.245562	1.286779	0.2001
C(20)	-0.404668	0.243838	-1.659576	0.0990
C(21)	0.273751	0.241443	1.133813	0.2586
C(22)	-0.167751	0.237998	-0.704839	0.4820
C(23)	0.309115	0.232877	1.327377	0.1863
C(24)	-0.303655	0.172117	-1.764237	0.0797
C(25)	0.157218	0.059444	2.644805	0.0090
R-squared	0.977556	Mean dependent var		3.440944
Adjusted R-squared	0.974081	S.D. dependent var		1.275091
S.E. of regression	0.205283	Akaike info criterion		-0.200610
Sum squared resid	6.531859	Schwarz criterion		0.242856
Log likelihood	43.05494	Hannan-Quinn criter.		-0.020804
F-statistic	281.2943	Durbin-Watson stat		1.976042
Prob(F-statistic)	0.000000			

Dependent Variable: MICHOACAN

Method: Least Squares

Date: 06/28/16 Time: 15:39

Sample (adjusted): 2001M04 2015M08

Included observations: 173 after adjustments

MICHOACAN = C(1)*MICHOACAN(-1) + C(2)*MICHOACAN(-2) + C(3)*MICHOACAN(-3) + C(4)*MICHOACAN(-4) + C(5)*MICHOACAN(-5) + C(6)*MICHOACAN(-6) + C(7)*MICHOACAN(-7) + C(8)*MICHOACAN(-8) + C(9)*MICHOACAN(-9) + C(10)*MICHOACAN(-10) + C(11)*MICHOACAN(-11) + C(12)*MICHOACAN(-12) + C(13)*MICHOACAN(-13) + C(14)*MICHOACAN(-14) + C(15)*MICHOACAN(-15) + C(16)*USA(-1) + C(17)*USA(-2) + C(18)*USA(-3) + C(19)*USA(-4) + C(20)*USA(-5) + C(21)*USA(-6) + C(22)*USA(-7) + C(23)*USA(-8) + C(24)*USA(-9) + C(25)*USA(-10) + C(26)*USA(-11) + C(27)*USA(-12) + C(28)*USA(-13) + C(29)*USA(-14) + C(30)*USA(-15) + C(31)*FUSA(-1) + C(32)*FUSA(-2) + C(33)*FUSA(-3) + C(34)*FUSA(-4) + C(35)*FUSA(-5) + C(36)*FUSA(-6) + C(37)*FUSA(-7) + C(38)*FUSA(-8) + C(39)*FUSA(-9) + C(40)*FUSA(-10) + C(41)*FUSA(-11) + C(42)*FUSA(-12) + C(43)*FUSA(-13) + C(44)*FUSA(-14) + C(45)*FUSA(-15) + C(46)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	1.296164	0.085334	15.18925	0.0000
C(2)	-0.406366	0.141472	-2.872407	0.0048
C(3)	-0.046715	0.146657	-0.318529	0.7506
C(4)	0.228369	0.141388	1.615189	0.1088
C(5)	-0.149226	0.136561	-1.092744	0.2766
C(6)	-0.020598	0.137437	-0.149874	0.8811
C(7)	0.232066	0.139270	1.666302	0.0981
C(8)	-0.301195	0.140628	-2.141787	0.0341
C(9)	0.185078	0.141610	1.306957	0.1936
C(10)	0.009585	0.142189	0.067409	0.9464
C(11)	-0.357402	0.143428	-2.491867	0.0140
C(12)	0.496744	0.145706	3.409222	0.0009
C(13)	-0.262828	0.147455	-1.782424	0.0771
C(14)	-0.127313	0.141864	-0.897435	0.3712
C(15)	0.248401	0.088631	2.802641	0.0059
C(16)	0.149568	0.235090	0.636217	0.5258
C(17)	-0.203491	0.309389	-0.657720	0.5119
C(18)	-0.038109	0.316956	-0.120235	0.9045
C(19)	0.363045	0.315737	1.149834	0.2524
C(20)	-0.480264	0.309188	-1.553309	0.1228
C(21)	0.006311	0.306022	0.020622	0.9836
C(22)	-0.249787	0.301716	-0.827887	0.4093
C(23)	-0.049064	0.306581	-0.160037	0.8731
C(24)	0.468333	0.307315	1.523950	0.1300
C(25)	-0.031204	0.309496	-0.100821	0.9199
C(26)	0.047230	0.311040	0.151846	0.8795
C(27)	0.082738	0.312151	0.265058	0.7914
C(28)	-0.153680	0.311562	-0.493255	0.6227
C(29)	0.235004	0.305796	0.768498	0.4436
C(30)	-0.402506	0.206460	-1.949557	0.0534
C(31)	0.059209	0.174841	0.338645	0.7354
C(32)	-0.070744	0.233117	-0.303471	0.7620
C(33)	-0.192509	0.234160	-0.822128	0.4125
C(34)	0.105356	0.234717	0.448863	0.6543
C(35)	0.314331	0.235752	1.333314	0.1848
C(36)	-0.028400	0.232334	-0.122239	0.9029
C(37)	0.097771	0.227851	0.429099	0.6686
C(38)	-0.005167	0.227804	-0.022681	0.9819
C(39)	-0.190784	0.226152	-0.843610	0.4005
C(40)	0.021611	0.224757	0.096152	0.9236
C(41)	-0.146730	0.223579	-0.656279	0.5128
C(42)	-0.123247	0.220476	-0.559003	0.5771
C(43)	0.198444	0.222011	0.893847	0.3731
C(44)	0.117169	0.218648	0.535881	0.5930
C(45)	0.033122	0.164096	0.201844	0.8404
C(46)	0.034405	0.047919	0.717984	0.4741

R-squared	0.987250	Mean dependent var	3.510116
Adjusted R-squared	0.982732	S.D. dependent var	1.288279
S.E. of regression	0.169290	Akaike info criterion	-0.491718
Sum squared resid	3.639713	Schwarz criterion	0.346730
Log likelihood	88.53360	Hannan-Quinn criter.	-0.151565
F-statistic	218.5241	Durbin-Watson stat	2.025240
Prob(F-statistic)	0.000000		

Dependent Variable: GTO

Method: Least Squares

Date: 06/28/16 Time: 15:38

Sample (adjusted): 2000M09 2015M08

Included observations: 180 after adjustments

GTO = C(1)*GTO(-1) + C(2)*GTO(-2) + C(3)*GTO(-3) + C(4)*GTO(-4) + C(5)*GTO(-5) + C(6)*GTO(-6) + C(7)*GTO(-7) + C(8)*GTO(-8) + C(9)*USA(-1) + C(10)*USA(-2) + C(11)*USA(-3) + C(12)*USA(-4) + C(13)*USA(-5) + C(14)*USA(-6) + C(15)*USA(-7) + C(16)*USA(-8) + C(17)*FUSA(-1) + C(18)*FUSA(-2) + C(19)*FUSA(-3) + C(20)*FUSA(-4) + C(21)*FUSA(-5) + C(22)*FUSA(-6) + C(23)*FUSA(-7) + C(24)*FUSA(-8) + C(25)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	1.006779	0.081209	12.39734	0.0000
C(2)	-0.146375	0.115035	-1.272440	0.2051
C(3)	0.001263	0.115975	0.010894	0.9913
C(4)	-0.045339	0.108999	-0.415955	0.6780
C(5)	0.071132	0.092455	0.769364	0.4428
C(6)	0.086077	0.093171	0.923863	0.3570
C(7)	-0.076210	0.094107	-0.809823	0.4193
C(8)	-0.024396	0.069446	-0.351294	0.7258
C(9)	-0.021021	0.250634	-0.083873	0.9333
C(10)	-0.070064	0.325462	-0.215276	0.8298
C(11)	0.429590	0.332306	1.292754	0.1980
C(12)	-0.229266	0.336123	-0.682092	0.4962
C(13)	0.112956	0.341150	0.331104	0.7410
C(14)	0.160358	0.339261	0.472669	0.6371
C(15)	-0.434395	0.330703	-1.313548	0.1909
C(16)	0.249737	0.225257	1.108676	0.2693
C(17)	0.029905	0.176778	0.169166	0.8659
C(18)	0.053749	0.250406	0.214646	0.8303
C(19)	-0.353253	0.256046	-1.379647	0.1697
C(20)	0.335033	0.257574	1.300727	0.1953
C(21)	0.089490	0.259312	0.345107	0.7305
C(22)	-0.241386	0.254401	-0.948840	0.3442
C(23)	0.252571	0.246548	1.024429	0.3072
C(24)	-0.191191	0.183822	-1.040086	0.2999
C(25)	0.145759	0.058456	2.493487	0.0137

R-squared	0.977007	Mean dependent var	3.423722
Adjusted R-squared	0.973447	S.D. dependent var	1.320594
S.E. of regression	0.215191	Akaike info criterion	-0.106334
Sum squared resid	7.177621	Schwarz criterion	0.337132
Log likelihood	34.57006	Hannan-Quinn criter.	0.073472
F-statistic	274.4287	Durbin-Watson stat	2.007951
Prob(F-statistic)	0.000000		

Modelos VEC estimados

Dependent Variable: D(SINALOAP)

Method: Least Squares

Date: 07/19/16 Time: 23:48

Sample (adjusted): 2000M06 2015M08

Included observations: 183 after adjustments

$$D(SINALOAP) = C(1)*(SINALOAP(-1) + 63.7793683403*USA(-1) - 64.0219490413*FUSA(-1) + 2.6416519284) + C(2)*D(SINALOAP(-1)) + C(3)*D(SINALOAP(-2)) + C(4)*D(SINALOAP(-3)) + C(5)*D(SINALOAP(-4)) + C(6)*D(USA(-1)) + C(7)*D(USA(-2)) + C(8)*D(USA(-3)) + C(9)*D(USA(-4)) + C(10)*D(FUSA(-1)) + C(11)*D(FUSA(-2)) + C(12)*D(FUSA(-3)) + C(13)*D(FUSA(-4)) + C(14)$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.007204	0.003521	-2.045957	0.0423
C(2)	0.096644	0.077402	1.248599	0.2135
C(3)	-0.132893	0.077661	-1.711197	0.0889
C(4)	-0.011474	0.077298	-0.148438	0.8822
C(5)	0.048740	0.076530	0.636873	0.5251
C(6)	-0.454076	0.316273	-1.435710	0.1529
C(7)	-0.021983	0.299640	-0.073365	0.9416
C(8)	-0.413597	0.295343	-1.400393	0.1632
C(9)	0.066518	0.295553	0.225063	0.8222
C(10)	0.061670	0.281274	0.219253	0.8267
C(11)	0.295440	0.268698	1.099523	0.2731
C(12)	0.239734	0.256318	0.935301	0.3510
C(13)	0.164226	0.251803	0.652201	0.5152
C(14)	0.006633	0.023536	0.281821	0.7784
R-squared	0.169228	Mean dependent var		0.005738
Adjusted R-squared	0.105323	S.D. dependent var		0.330865
S.E. of regression	0.312957	Akaike info criterion		0.587915
Sum squared resid	16.55220	Schwarz criterion		0.833450
Log likelihood	-39.79424	Hannan-Quinn criter.		0.687442
F-statistic	2.648097	Durbin-Watson stat		2.002795
Prob(F-statistic)	0.002146			

Dependent Variable: D(JALISCO)

Method: Least Squares

Date: 07/13/16 Time: 14:02

Sample (adjusted): 2000M04 2015M08

Included observations: 185 after adjustments

$$D(JALISCO) = C(1)*(JALISCO(-1) - 37.4449117851*USA(-1) + 35.4652506964*FUSA(-1) - 3.10504859481) + C(2)*D(JALISCO(-1)) + C(3)*D(JALISCO(-2)) + C(4)*D(USA(-1)) + C(5)*D(USA(-2)) + C(6)*D(FUSA(-1)) + C(7)*D(FUSA(-2)) + C(8)$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.009967	0.002351	4.239643	0.0000
C(2)	0.026947	0.075012	0.359230	0.7199
C(3)	-0.210114	0.076387	-2.750656	0.0066
C(4)	0.072724	0.144042	0.504882	0.6143
C(5)	0.037380	0.144143	0.259326	0.7957
C(6)	-0.124270	0.122399	-1.015284	0.3114
C(7)	0.018599	0.123948	0.150058	0.8809
C(8)	0.019054	0.011537	1.651450	0.1004
R-squared	0.163780	Mean dependent var		0.016108
Adjusted R-squared	0.130710	S.D. dependent var		0.165102
S.E. of regression	0.153934	Akaike info criterion		-0.862304
Sum squared resid	4.194141	Schwarz criterion		-0.723045
Log likelihood	87.76309	Hannan-Quinn criter.		-0.805866
F-statistic	4.952413	Durbin-Watson stat		2.052301
Prob(F-statistic)	0.000039			

Dependent Variable: D(EDOMEX)
 Method: Least Squares
 Date: 06/28/16 Time: 15:12
 Sample (adjusted): 2000M10 2015M08
 Included observations: 179 after adjustments

$$D(EDOMEX) = C(1)*(EDOMEX(-1) - 32.6783920991*USA(-1) + 30.9260394117*FUSA(-1) - 3.18424348194) + C(2)*D(EDOMEX(-1)) + C(3)*D(EDOMEX(-2)) + C(4)*D(EDOMEX(-3)) + C(5)*D(EDOMEX(-4)) + C(6)*D(EDOMEX(-5)) + C(7)*D(EDOMEX(-6)) + C(8)*D(EDOMEX(-7)) + C(9)*D(EDOMEX(-8)) + C(10)*D(USA(-1)) + C(11)*D(USA(-2)) + C(12)*D(USA(-3)) + C(13)*D(USA(-4)) + C(14)*D(USA(-5)) + C(15)*D(USA(-6)) + C(16)*D(USA(-7)) + C(17)*D(USA(-8)) + C(18)*D(FUSA(-1)) + C(19)*D(FUSA(-2)) + C(20)*D(FUSA(-3)) + C(21)*D(FUSA(-4)) + C(22)*D(FUSA(-5)) + C(23)*D(FUSA(-6)) + C(24)*D(FUSA(-7)) + C(25)*D(FUSA(-8)) + C(26)$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.005071	0.007795	-0.650581	0.5163
C(2)	-0.151401	0.082381	-1.837812	0.0680
C(3)	-0.224203	0.083116	-2.697464	0.0078
C(4)	0.022315	0.087552	0.254876	0.7992
C(5)	0.011236	0.087270	0.128749	0.8977
C(6)	0.159383	0.087129	1.829270	0.0693
C(7)	0.116849	0.088936	1.313863	0.1909
C(8)	0.039719	0.086930	0.456912	0.6484
C(9)	-0.037212	0.085706	-0.434180	0.6648
C(10)	0.227539	0.262916	0.865445	0.3881
C(11)	0.017286	0.255436	0.067671	0.9461
C(12)	-0.118916	0.247179	-0.481095	0.6311
C(13)	-0.015521	0.243239	-0.063811	0.9492
C(14)	-0.124251	0.233285	-0.532614	0.5951
C(15)	-0.166039	0.221255	-0.750439	0.4541
C(16)	-0.263502	0.220323	-1.195979	0.2336
C(17)	0.254648	0.223109	1.141360	0.2555
C(18)	0.095004	0.254924	0.372677	0.7099
C(19)	0.185574	0.252111	0.736080	0.4628
C(20)	0.450723	0.230558	1.954926	0.0524
C(21)	-0.010288	0.221261	-0.046496	0.9630
C(22)	0.280826	0.199977	1.404293	0.1623
C(23)	0.076220	0.192481	0.395988	0.6927
C(24)	0.398145	0.184521	2.157724	0.0325
C(25)	0.051909	0.179849	0.288627	0.7733
C(26)	0.004882	0.017129	0.285043	0.7760

R-squared	0.213302	Mean dependent var	0.016089
Adjusted R-squared	0.084756	S.D. dependent var	0.220179
S.E. of regression	0.210642	Akaike info criterion	-0.143757
Sum squared resid	6.788626	Schwarz criterion	0.319215
Log likelihood	38.86629	Hannan-Quinn criter.	0.043974
F-statistic	1.659348	Durbin-Watson stat	1.989079
Prob(F-statistic)	0.033793		

Dependent Variable: D(MICHOACAN)
 Method: Least Squares
 Date: 06/28/16 Time: 15:30
 Sample (adjusted): 2001M05 2015M08
 Included observations: 172 after adjustments

$$D(MICHOACAN) = C(1)*(MICHOACAN(-1) - 2.9682690534*USA(-1) + 1.30034933225*FUSA(-1) - 0.637263047065) + C(2)*D(MICHOACAN(-1)) + C(3)*D(MICHOACAN(-2)) + C(4)*D(MICHOACAN(-3)) + C(5)*D(MICHOACAN(-4)) + C(6)*D(MICHOACAN(-5)) + C(7)*D(MICHOACAN(-6)) + C(8)*D(MICHOACAN(-7)) + C(9)*D(MICHOACAN(-8)) + C(10)*D(MICHOACAN(-9)) + C(11)*D(MICHOACAN(-10)) + C(12)*D(MICHOACAN(-11)) + C(13)*D(MICHOACAN(-12)) + C(14)*D(MICHOACAN(-13)) + C(15)*D(MICHOACAN(-14)) + C(16)*D(MICHOACAN(-15)) + C(17)*D(USA(-1)) + C(18)*D(USA(-2)) + C(19)*D(USA(-3)) + C(20)*D(USA(-4)) + C(21)*D(USA(-5)) + C(22)*D(USA(-6)) + C(23)*D(USA(-7)) + C(24)*D(USA(-8)) + C(25)*D(USA(-9)) + C(26)*D(USA(-10)) + C(27)*D(USA(-11)) + C(28)*D(USA(-12)) + C(29)*D(USA(-13)) + C(30)*D(USA(-14)) + C(31)*D(USA(-15)) + C(32)*D(FUSA(-1)) + C(33)*D(FUSA(-2)) + C(34)*D(FUSA(-3)) + C(35)*D(FUSA(-4)) + C(36)*D(FUSA(-5)) + C(37)*D(FUSA(-6)) + C(38)*D(FUSA(-7)) + C(39)*D(FUSA(-8)) + C(40)*D(FUSA(-9)) + C(41)*D(FUSA(-10)) + C(42)*D(FUSA(-11)) + C(43)*D(FUSA(-12)) + C(44)*D(FUSA(-13)) + C(45)*D(FUSA(-14)) + C(46)*D(FUSA(-15)) + C(47)$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.066501	0.046986	1.415330	0.1595
C(2)	0.228845	0.105209	2.175146	0.0315
C(3)	-0.171589	0.101087	-1.697431	0.0921
C(4)	-0.207117	0.102619	-2.018306	0.0457
C(5)	-0.001252	0.101326	-0.012361	0.9902
C(6)	-0.126238	0.094336	-1.338176	0.1833
C(7)	-0.148066	0.097472	-1.519050	0.1313
C(8)	0.081499	0.096871	0.841316	0.4018
C(9)	-0.201270	0.096284	-2.090372	0.0386
C(10)	-0.041185	0.101588	-0.405412	0.6859
C(11)	-0.019644	0.098917	-0.198590	0.8429
C(12)	-0.390184	0.097568	-3.999107	0.0001
C(13)	0.120845	0.101263	1.193381	0.2350
C(14)	-0.140918	0.096314	-1.463117	0.1459
C(15)	-0.265799	0.095397	-2.786239	0.0062
C(16)	-0.035394	0.092749	-0.381610	0.7034
C(17)	0.384710	0.272846	1.409988	0.1610
C(18)	0.156564	0.269300	0.581374	0.5620
C(19)	0.115470	0.282014	0.409448	0.6829
C(20)	0.463390	0.265544	1.745059	0.0834
C(21)	0.049713	0.262305	0.189523	0.8500
C(22)	0.021183	0.260944	0.081177	0.9354
C(23)	-0.230162	0.235939	-0.975514	0.3312
C(24)	-0.204285	0.255777	-0.798683	0.4260
C(25)	0.209339	0.232337	0.901014	0.3693
C(26)	0.201905	0.234686	0.860320	0.3913
C(27)	0.265497	0.228241	1.163232	0.2470
C(28)	0.325994	0.219955	1.482093	0.1408
C(29)	0.214617	0.225892	0.950086	0.3439
C(30)	0.401654	0.213998	1.876904	0.0629
C(31)	0.189759	0.211251	0.898261	0.3708
C(32)	-0.039293	0.199955	-0.196510	0.8445
C(33)	-0.120630	0.195416	-0.617298	0.5382
C(34)	-0.318365	0.200945	-1.584339	0.1156
C(35)	-0.215842	0.192309	-1.122367	0.2639
C(36)	0.078959	0.201428	0.391998	0.6957
C(37)	0.055791	0.210297	0.265295	0.7912
C(38)	0.162346	0.198286	0.818743	0.4145
C(39)	0.094926	0.207058	0.458450	0.6474
C(40)	-0.040559	0.196989	-0.205893	0.8372
C(41)	-0.045315	0.195794	-0.231442	0.8173
C(42)	-0.226028	0.185213	-1.220364	0.2246
C(43)	-0.338235	0.177235	-1.908398	0.0586
C(44)	-0.161198	0.183518	-0.878378	0.3814
C(45)	-0.012233	0.170456	-0.071768	0.9429
C(46)	-0.074108	0.168705	-0.439277	0.6612
C(47)	0.019616	0.014560	1.347310	0.1803

R-squared	0.447439	Mean dependent var	0.014535
Adjusted R-squared	0.244097	S.D. dependent var	0.196461
S.E. of regression	0.170808	Akaike info criterion	-0.469218
Sum squared resid	3.646936	Schwarz criterion	0.390853
Log likelihood	87.35279	Hannan-Quinn criter.	-0.120265
F-statistic	2.200423	Durbin-Watson stat	1.995505
Prob(F-statistic)	0.000303		

Dependent Variable: D(GTO)

Method: Least Squares

Date: 07/16/16 Time: 18:19

Sample (adjusted): 2000M06 2015M08

Included observations: 183 after adjustments

D(GTO) = C(1)*(GTO(-1) + 19.8077593742*USA(-1) - 21.1666437089

*FUSA(-1) + 0.879104803746) + C(2)*D(GTO(-1)) + C(3)*D(GTO(-2)) +

C(4)*D(GTO(-3)) + C(5)*D(GTO(-4)) + C(6)*D(USA(-1)) + C(7)*D(USA(-

2)) + C(8)*D(USA(-3)) + C(9)*D(USA(-4)) + C(10)*D(FUSA(-1)) + C(11)

*D(FUSA(-2)) + C(12)*D(FUSA(-3)) + C(13)*D(FUSA(-4)) + C(14)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.013342	0.006130	-2.176523	0.0309
C(2)	0.040623	0.068854	0.589983	0.5560
C(3)	-0.068529	0.064445	-1.063363	0.2891
C(4)	-0.031925	0.065415	-0.488043	0.6262
C(5)	-0.131970	0.065230	-2.023166	0.0446
C(6)	0.073718	0.208330	0.353851	0.7239
C(7)	0.009476	0.203250	0.046624	0.9629
C(8)	0.487522	0.202659	2.405631	0.0172
C(9)	0.148442	0.207891	0.714036	0.4762
C(10)	-0.186879	0.173040	-1.079975	0.2817
C(11)	-0.134589	0.173612	-0.775231	0.4393
C(12)	-0.545598	0.166731	-3.272325	0.0013
C(13)	-0.101766	0.174223	-0.584115	0.5599
C(14)	0.016791	0.016455	1.020457	0.3090
R-squared	0.110568	Mean dependent var		0.011475
Adjusted R-squared	0.042150	S.D. dependent var		0.222574
S.E. of regression	0.217832	Akaike info criterion		-0.136764
Sum squared resid	8.019211	Schwarz criterion		0.108771
Log likelihood	26.51387	Hannan-Quinn criter.		-0.037236
F-statistic	1.616066	Durbin-Watson stat		1.937269
Prob(F-statistic)	0.084868			

Predicción fuera de muestra

<i>sep-15</i>				
SINALOAP	ARIMA (0, 1, 1)	VAR	VEC	
Observado	3.64	3.64	3.64	
Predicho	3.57	3.67	3.58	
Diferencia	-1.88%	0.92%	-1.54%	
JALISCO	ARIMA (1, 1, 1)	VAR	VEC	
Observado	5.00	5.00	5.00	
Predicho	4.57	4.60	4.64	
Diferencia	-8.57%	-8.03%	-7.12%	
EDO MEX	ARIMA (3, 1, 2)	VAR	VEC	
Observado	4.90	4.90	4.90	
Predicho	4.77	4.78	4.904	
Diferencia	-2.61%	-2.49%	0.07%	
MICHOACAN	ARIMA (2, 1, 1)	VAR	VEC	
Observado	4.28	4.28	4.28	
Predicho	4.40	4.19	4.22	
Diferencia	2.87%	-2.04%	-1.50%	
GTO	ARIMA (1, 1, 1)	VAR	VEC	
Observado	4.00	4.00	4.00	
Predicho	4.17	4.07	4.00	
Diferencia	4.18%	1.76%	-0.12%	

Predicción de una observación fuera de muestra

Representación del modelo de vectores autorregresivos (VAR) de 3 variables, sin restricciones, considerado para predecir el precio físico de maíz:

$$\begin{aligned}
 P_t &= \alpha_P + \sum_{i=1}^n \beta_{1i} P_{t-i} + \sum_{i=1}^n \delta_{1i} F_{t-i} + \sum_{i=1}^n \gamma_{1i} I_{t-i} + \mathcal{E}_t^P \\
 F_t &= \alpha_F + \sum_{i=1}^n \delta_{2i} F_{t-i} + \sum_{i=1}^n \beta_{2i} P_{t-i} + \sum_{i=1}^n \gamma_{2i} I_{t-i} + \mathcal{E}_t^F \\
 I_t &= \alpha_I + \sum_{i=1}^n \gamma_{3i} I_{t-i} + \sum_{i=1}^n \beta_{3i} P_{t-i} + \sum_{i=1}^n \delta_{3i} F_{t-i} + \mathcal{E}_t^I
 \end{aligned}$$

donde:

P = Precio físico de maíz blanco.

F = Precio futuro de maíz (amarillo - EU).

I = Precio internacional de maíz (amarillo - EU).

\mathcal{E}_t = Término de error (innovaciones o impulsos), en el periodo t, de cada uno de los modelos.

Las α 's representan el cambio en los niveles de la variable en cuestión, γ , δ y β , son los parámetros para cada una de las diferentes variables del modelo.

Representación matricial del modelo de vectores autorregresivos (VAR)

$$P_t = A + \sum_{k=1}^p \theta_k P_{t-k} + \mathcal{E}_t \quad t = 1, \dots, T$$

donde P_t denota el vector ($m \times 1$) de variables incluidas en el modelo (Precio físico de maíz blanco, Precio futuro de maíz amarillo de EU y Precio Internacional de maíz “amarillo -EU”) para el periodo t, A es el vector ($m \times 1$) de términos constantes, θ_k son las matrices ($m \times m$) de los coeficientes autorregresivos y \mathcal{E}_t es el vector ($m \times 1$) de términos de error (innovaciones o impulsos), en el periodo t. Los elementos de \mathcal{E}_t pueden estar correlacionados contemporáneamente pero no correlacionados a través de diferentes períodos. La especificación es irrestricta en el sentido de que todas las variables P_t tienen el mismo orden de rezago p

(evidentemente dependiendo del modelo de cada estado) y ninguno de los coeficientes en θ_k se supone cero a priori.

Representación del modelo vectorial de corrección del error (VCE) de 3 variables, sin restricciones, para predecir el precio físico de maíz:

$$\begin{aligned}\Delta P_t &= \alpha_P + \sum_{i=1}^n \beta_{1i} \Delta P_{t-i} + \sum_{i=1}^n \delta_{1i} \Delta F_{t-i} + \sum_{i=1}^n \gamma_{1i} \Delta I_{t-i} + \varphi_P Z_{t-1} + \mathcal{E}_t^P \\ \Delta F_t &= \alpha_F + \sum_{i=1}^n \delta_{2i} \Delta F_{t-i} + \sum_{i=1}^n \beta_{2i} \Delta P_{t-i} + \sum_{i=1}^n \gamma_{2i} \Delta I_{t-i} + \varphi_F Z_{t-1} + \mathcal{E}_t^F \\ \Delta I_t &= \alpha_I + \sum_{i=1}^n \gamma_{3i} \Delta I_{t-i} + \sum_{i=1}^n \beta_{3i} \Delta P_{t-i} + \sum_{i=1}^n \delta_{3i} \Delta F_{t-i} + \varphi_I Z_{t-1} + \mathcal{E}_t^I\end{aligned}$$

donde:

P = Precio físico de maíz blanco.

Δ = Operador de primera diferencia aplicada a la variable.

F = Precio futuro de maíz (amarillo - EU).

I = Precio internacional de maíz (amarillo - EU).

Z_{t-1} = Denota la desviación del periodo anterior respecto a la relación de equilibrio de largo plazo entre las variables P_t , F_t e I_t . De esta manera, los términos $\varphi_P Z_{t-1}$, $\varphi_F Z_{t-1}$ y $\varphi_I Z_{t-1}$ se denominan términos de corrección del error.

\mathcal{E}_t = Término de error (innovaciones o impulsos), en el periodo t, de cada uno de los modelos.

Las α 's representan el cambio en los niveles de la variable en cuestión, γ , δ y β , son los parámetros para cada una de las variables del modelo.

Representación matricial del modelo vectorial de corrección del error (VCE)

$$\Delta P_t = A + \sum_{k=1}^{p-1} \theta_k \Delta P_{t-k} - \varphi_i Z_{t-1} + \mathcal{E}_t$$

$$t = 1, \dots, T$$

donde ΔP_t denota el vector $(m \times 1)$ de variables en primera diferencia I(1) incluidas en el modelo (Precio físico de maíz blanco, Precio futuro de maíz amarillo de EU y Precio Internacional de maíz “amarillo -EU”) para el periodo t. A es el vector $(m \times 1)$ de términos constantes, θ_k son las matrices $(m \times m)$ de los coeficientes autorregresivos. Z_{t-1} denota la desviación del periodo anterior respecto a la relación de equilibrio de largo plazo entre las variables P_t , de esta manera, las propiedades de equilibrio se caracterizan por el rango de φ_i . Si los elementos de P_t son I(1) y cointegrados con rango $(\varphi) = r < m$, φ se puede descomponer en dos matrices columna de rango completo $(m \times r)$ α y β , donde $\varphi = \alpha\beta'$. Esto implica que existe $r = m$ combinaciones lineales estacionarias de P , tales que $\mathcal{E}_t = 0$. La matriz de coeficientes de ajuste α mide que tan fuerte las desviaciones de equilibrio de largo plazo, v_t , se retroalimentan en el sistema. \mathcal{E}_t es el vector $(m \times 1)$ de términos de error (innovaciones o impulsos), en el periodo t. La especificación es irrestricta y ninguno de los coeficientes en θ_k se supone cero a priori.