



COLEGIO DE POSTGRADUADOS

**INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS
AGRÍCOLAS**

CAMPUS MONTECILLO

**POSTGRADO DE SOCIOECONOMÍA, ESTADÍSTICA E INFORMÁTICA
ECONOMÍA**

**ANÁLISIS DE LOS PRECIOS DE HUEVO
BLANCO PAGADOS AL PRODUCTOR EN
MÉXICO 2000 - 2016, MEDIANTE LA
METODOLOGÍA BOX - JENKINS**

SAMUEL LUIS ROJAS

T E S I S
PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:

MAESTRO EN CIENCIAS

MONTECILLO, TEXCOCO, EDO. DE MÉXICO

2018


CARTA DE CONSENTIMIENTO DE USO DE LOS DERECHOS DE AUTOR Y DE LAS REGALIAS COMERCIALES DE PRODUCTOS DE INVESTIGACION

En adición al beneficio ético, moral y académico que he obtenido durante mis estudios en el Colegio de Postgraduados, el que suscribe SAMUEL LUIS ROJAS, Alumno (a) de esta Institución, estoy de acuerdo en ser participe de las regalías económicas y/o académicas, de procedencia nacional e internacional, que se deriven del trabajo de investigación que realicé en esta institución, bajo la dirección del Profesor DR. ROBERTO CARLOS GARCÍA SÁNCHEZ, por lo que otorgo los derechos de autor de mi tesis ANALISIS DE LOS PRECIOS DE HUEVO BLANCO PAGADOS AL PRODUCTOR EN MEXICO 2000 - 2016, MEDIANTE LA METODOLOGÍA BOX - JENKINS y de los producto de dicha investigación al Colegio de Postgraduados. Las patentes y secretos industriales que se puedan derivar serán registrados a nombre el colegio de Postgraduados y las regalías económicas que se deriven serán distribuidas entre la Institución, El Consejero o Director de Tesis y el que suscribe, de acuerdo a las negociaciones entre las tres partes, por ello me comprometo a no realizar ninguna acción que dañe el proceso de explotación comercial de dichos productos a favor de esta Institución.

Montecillo, Mpio. de Texcoco, Edo. de México, a 31 de JULIO de 2018



Firma del
Alumno (a)



DR. ROBERTO CARLOS GARCÍA SÁNCHEZ
Vo. Bo. del Consejero o Director de Tesis

La presente tesis titulada: "ANÁLISIS DE LOS PRECIOS DE HUEVO BLANCO PAGADOS AL PRODUCTOR EN MÉXICO 2000 – 2016, MEDIANTE LA METODOLOGÍA BOX - JENKINS" realizada por el alumno: **SAMUEL LUIS ROJAS**, bajo la dirección del Consejo Particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

**MAESTRO EN CIENCIAS
SOCIOECONOMÍA ESTADÍSTICA E INFORMÁTICA
ECONOMÍA**

CONSEJO PARTICULAR

CONSEJERO: 
Dr. Roberto Carlos García Sánchez

ASESOR 
Dr. Roberto García Mata

ASESOR 
Dr. Oscar Antonio Arana Coronado

ASESOR 
Dr. Adrián González Estrada

Montecillo, Texcoco, Estado de México, agosto de 2018

**ANÁLISIS DE LOS PRECIOS DE HUEVO BLANCO PAGADOS AL
PRODUCTOR EN MÉXICO 2000 – 2016, MEDIANTE LA METODOLOGÍA
BOX – JENKINS**

Samuel Luis Rojas, M. en C.
Colegio de Postgraduados, 2018

RESUMEN

La avicultura mexicana es la actividad más dinámica del país y uno de los sectores estratégicos para la alimentación en México. Actualmente, el precio de la proteína de huevo, es más barato que el de la carne de res, cerdo o del pescado, y su adquisición es mucho más rápida y sencilla, ubicando a México como el principal consumidor de huevo en el mundo. El presente estudio tuvo como objetivo principal desarrollar un modelo de pronóstico para los precios nominales mensuales de huevo blanco pagados al productor en México (PPHBP) a través de la metodología de Box- Jenkins, así como evaluar la relación de los precios promedios mensuales rurales de sorgo (PPSRG) para mejorar la capacidad predictiva utilizando un modelo bivariado de función de transferencia (MFT) de series de tiempo, utilizando datos del periodo 2000 a 2016. Los parámetros de los modelos y las predicciones se estimaron con el método de máxima verosimilitud con el paquete Statistical Analysis System (SAS) y fueron estadísticamente apropiadas y significativas. Se encontró que la serie (PPHBP) puede ser explicado por el modelo univariado SARIMA (0, 1, 1) X (1, 0, 1)_{s=12}, pero al incluir la variable (PPSRG) como independiente al MFT, los pronósticos de los PPHBP para el corto plazo se mejoran, logrando reducir la varianza en 5.69 % respecto al modelo de la primer metodología, debido a que el modelo bivariado toma en cuenta la evolución temporal del PPSRG por lo tanto sus estimaciones son más cercanas a la realidad y útiles para planificar y tomar decisiones en el sector avícola en el corto y mediano plazo.

Palabras clave: Precios, huevo, SARIMA, Modelo de Función de transferencia, sorgo, pronóstico, predicción

BOX - JENKINS METHODOLOGY TO ANALYSIS THE WHITE EGG PRICES PAID TO THE PRODUCER IN MEXICO 2000 - 2016

Samuel Luis Rojas, M. en C.
Colegio De Postgraduados, 2018

ABSTRACT

The Mexican poultry farming is the most dynamic activity in the country and one of the strategic sectors for food in Mexico. Currently, the price of egg protein is cheaper than that of beef, pork or fish, and its acquisition is much quicker and easier, placing Mexico as the main egg consumer in the world. The main objective of the present study was to develop a forecast model for the monthly nominal prices of white eggs paid to the producer in Mexico (PPHBP) through the Box-Jenkins methodology, as well as to evaluate the relationship of the monthly average prices of sorghum (PPSRG) to improve the predictive capacity using a bivariate model of transfer function (MFT) of time series, using data from the period 2000 to 2016. The parameters of the models and the predictions were estimated with the maximum likelihood method with the Statistical Analysis System (SAS) package and were statistically appropriate and significant. It was found that the series (PPHBP) can be explained by the univariate model SARIMA (0, 1, 1) X (1, 0, 1) s = 12, but by including the variable (PPSRG) as independent to the MFT, the forecasts of the PPHBP for the short term are improved, managing to reduce the variance in 5.69% with respect to the model of the first methodology, because the bivariate model takes into account the temporal evolution of the PPSRG therefore its estimates are closer to reality and useful for planning and making decisions in the poultry sector in the short and medium term.

Key words: Prices, egg, SARIMA, Transfer function model, sorghum, forecast, prediction

AGRADECIMIENTO

A los millones de mexicanos (as) que pagan impuestos, quienes a través del Consejo Nacional de Ciencia y Tecnología (CONACYT) y el Colegio de Postgraduados (COLPOS); han financiado mi formación académica e investigación.

Al Colegio de Postgraduados, institución noble y generosa que apoyó e impulsó mi desarrollo intelectual y profesional.

Al Programa de Economía, especialmente a mis estimados profesores que compartieron generosamente sus conocimientos.

A mi consejo particular, por aceptarme y guiarme durante mi proceso de investigación.

Al Dr. Roberto Carlos García Sánchez, por la confianza que depositó en mí, su constante apoyo, sus indicaciones y orientaciones indispensables en el desarrollo de este trabajo.

Al Dr. Adrián González Estrada, por su amistad y confianza depositada en mí, y sus apasionadas charlas y debates sobre este trabajo, así como del quehacer y porvenir de nuestra amada patria.

A todos los compañeros y amigos del Colegio de Postgraduados quisiera darles las gracias por los buenos momentos que hemos compartido. Creo que todos hemos aprendido y aprendemos continuamente de todos y de nosotros mismos, tanto profesional como personalmente. En especial un cariñoso reconocimiento a los que me han demostrado su apoyo y brindado sus ánimos y consejos durante estos dos años: Jenny Virgilio, Laura Santiago, José Pizano, Romelia, Francisco, Joss, Griselda

DEDICATORIA

Este trabajo está dedicado a:

A mi amada esposa **Blanquita**,

Que ha sido el impulso de superación y el pilar principal para la culminación de mis estudios de postgrado; que con su apoyo constante y su amor incondicional ha sido amiga y compañera inseparable, fuente de tolerancia, calma y consejo en todo momento.

Gracias por compartir tu vida y tiempo conmigo.

A mis amados hijos: **Samuel y Ariel**

Para quienes ningún sacrificio es suficiente, que con su luz han iluminado mi vida y hacen mi camino más claro.

Quienes tuvieron que soportar días, meses y años sin mi compañía; y mi amor por ustedes jamás en juicio pusieron, han sido mi mayor motivación para nunca rendirme y poder llegar a ser un ejemplo para ustedes.

Como en todos mis logros, en este, también están presentes.

A mis padres y hermanos

Que con su amor y enseñanza han sembrado las virtudes que se necesitan para vivir con anhelo y felicidad.

Samuel L. R.

CONTENIDO

RESUMEN	iv
ABSTRACT.....	v
AGRADECIMIENTO	vi
DEDICATORIA	vii
CONTENIDO.....	viii
LISTA DE CUADROS.....	x
LISTA DE FIGURAS.....	xi
INTRODUCCIÓN GENERAL.....	1
Planteamiento del problema.....	4
Objetivos	6
Objetivo General	6
Objetivos Específicos.....	6
Hipótesis.....	7
Hipótesis general	7
Hipótesis específicas	7
Revisión de literatura.....	8
Bibliográfica.....	11
CAPITULO I. METODOLOGÍA BOX – JENKINS PARA PRONOSTICAR LOS PRECIOS DE HUEVO BLANCO PAGADOS AL PRODUCTOR EN MÉXICO	13
RESUMEN	13
ABSTRACT	14
INTRODUCCIÓN	15
MATERIALES Y MÉTODOS	18
RESULTADOS Y DISCUSIÓN.....	21
CONCLUSIONES.....	31
LITERATURA CITADA.....	31
CAPITULO II. UN MODELO BIVARIADO DE FUNCIÓN DE TRANSFERENCIA PARA PRONOSTICAR EL PRECIO DE HUEVO BLANCO PAGADO AL PRODUCTOR EN MEXICO	34

RESUMEN	34
ABSTRACT	35
INTRODUCCION	36
MATERIALES Y METODOS	37
RESULTADOS Y DISCUSION	41
Identificación de los modelos ARIMA para Y_t (PPHBP) y para X_1 (PPSRG)	41
Etapa 1: Preparación de las series de entrada y salida	42
Etapa 2: Preblanqueo de las series entrada (<i>input</i>) y salida (<i>output</i>)	44
Etapa 3: Cálculo de la función de correlación cruzada (CCF) entre α_t y β_t	45
Etapa 4: Identificación de la función de transferencia	46
Etapa 5: Estimación de la función de transferencia	47
Etapa 6: Validación y predicción	48
CONCLUSIONES E IMPLICACIONES	52
LITERATURA CITADA	52
CONCLUSIONES Y RECOMENDACIONES GENERALES	54
CONCLUSION GENERAL	54
RECOMENDACIONES GENERALES	55
ANEXOS	56

LISTA DE CUADROS

CAPITULO I

- Cuadro 1.1.** Prueba de Dickey Fuller aumentada (ADF) para la serie de precios promedios mensuales de huevo blanco pagados al productor en México (PPHBP).24
- Cuadro 1.2.** Valores de AR, MA, SBC y AIC de los modelos SARIMA identificados $(p, 1, q) \times (1, 0, 1)_{s=12}$ y estimadores para $\delta \varepsilon^2$26
- Cuadro 1.3.** Estimación del modelo para la serie de tiempo LPPHBP(1) por máxima verosimilitud.27
- Cuadro 1.4.** Precios nominales observados y pronosticados de huevo blanco pagados al productor en México, 2017 (\$ kg⁻¹), obtenidos a través del modelo SARIMA $(0, 1, 1) \times (1, 0, 1)_{s=12}$30

CAPITULO II

- Cuadro 2.1.** Estimación del modelo SARIMA para la serie de tiempo LPPHBP(1) por máxima verosimilitud.44
- Cuadro 2.2.** Estimación del modelo de transferencia para la serie de tiempo LPPHBP(1) por máxima verosimilitud.47
- Cuadro 2.3.** Precios nominales observados y pronosticados de huevo blanco pagados al productor en México, 2017 (\$ kg⁻¹), obtenidos a través del modelo SARIMA y MFT.51

LISTA DE FIGURAS

CAPITULO I

Figura 1.1. Flujograma de la metodología Box- Jenkins.....20

Figura 1.2. Diagnósticos gráficos de la serie original (PPHBP): (a) Comportamiento original de la serie PPHBP en \$ kg⁻¹, 2000 – 2016, (b) Comportamiento de la serie PPHBP transformada a logaritmos naturales (LPPHBP), (c) Serie LPPHBP diferenciada en la parte no estacional, transformada con logaritmos naturales y sin tendencia.23

Figura 1.3. Función de autocorrelación ACF (a) y Función de autocorrelación parcial PACF (b) estimadas para la serie $Y_t = 1 - BLPPHBP$25

Figura 1.4. Diagnósticos gráficos para evaluar el ajuste del modelo SARIMA (0,1,1)X(1,0,1)_{s=12}: (a) Residuos estandarizados, (b) Histograma de los residuos estandarizados, (c) ACF de los residuales y (d) Valores p para las pruebas de ruido blanco.28

CAPITULO II

Figura 2.1.- Gráficos de las series de estudio: (a) Serie original PPHBP en \$ kg⁻¹, 2000 – 2017, (b) Serie PPSRG en \$ kg⁻¹, 2000 – 2017.42

Figura 2.2. Gráficos de las series de estudio: (a) Serie PPHBP transformada a logaritmos naturales (LPPHBP), (b) Serie LPPHBP diferenciada en la parte no estacional, transformada con logaritmos naturales y sin tendencia, (c) Serie PPSRG transformada a logaritmos naturales (LPPSRG) (d) Serie LPPSRG diferenciada en la parte no estacional, transformada con logaritmos naturales y sin tendencia.43

Figura 2.3. Correlación cruzada entre las series PPSRG (*entrada*) y PPHBP (*salida*) preblanqueadas.....46

Figura 2.4. Gráficos para evaluar el ajuste del modelo SARIMA $(0,1,1)X(1,0,1)_{s=12}$: (a) Residuos estandarizados, (b) Histograma de los residuos estandarizados, (c) ACF de los residuales y (d) Valores p para las pruebas de ruido blanco.	49
Figura 2.5. Precio nominal y pronosticado del huevo blanco pagados al productor en México.....	50

INTRODUCCIÓN GENERAL

La avicultura mexicana es la actividad más dinámica del país y uno de los sectores estratégicos para la alimentación en México, producto de la innovación en sus diferentes ámbitos dentro de la ganadería, expandiéndose en forma importante para cubrir mayoritariamente el mercado nacional, adoptando tecnología de punta que le permite obtener elevados índices productivos (Pérez, 2000).

En el año 2017, esta actividad aportó el 0.737 % en el PIB total, el 23.18 % en el PIB agropecuario y el 37.2 % en el PIB pecuario. Para el mismo año, el sector avícola mexicano participó con el 63.8 % de la producción pecuaria; 29% es la producción de huevo. Esta actividad juega un papel estratégico en el subsector pecuario puesto que en el año 2017 la industria avícola generó 1,257,824 empleos, de los cuales 209,637 son directos y 1,048,187 indirectos (UNA, 2018a), aunque cabe señalar que el crecimiento de los empleos es menor que al incremento observado en la producción, esto se debe principalmente al avance tecnológico que vienen adquiriendo las empresas dedicadas a esta actividad (UNCTAD, 2013).

La parvada nacional, esta se refiere al número de aves en cada rama de esta actividad, ya sea de postura o de aves para carne; ésta decreció 0.67%, respecto al crecimiento obtenido en 2016, cerrando en 523 millones de aves. La parvada de postura está representada por las ponedoras en producción y en crianza, reproductoras ligeras en producción y crianza y las progenitoras ligeras en crianza y producción, las que constituyen la base para la producción de huevo, ellas representan el 39.27 % aproximadamente de la parvada nacional total para el 2017 y se estima que para el cierre del año 2017 existen 156.77 millones de gallinas ponedoras (UNA, 2018b).

En México se vivieron cambios significativos desde la década de los 90's, ya que en dicho periodo se eliminaron los controles de precios que existía sobre esta rama productiva, lo que permitió que se obtuvieran niveles de rentabilidad adecuados, traduciéndose en beneficio de menores costos y una mejor calidad del producto (SAGARPA, 2004) , estos estándares de producción se reflejan ya que la producción

de huevo en México durante el año 2017 fue de 2,718,476 millones de toneladas (125.7 millones de cajas anuales) y durante el periodo 1994 a 2017 creció a un ritmo anual de 2.7%, y se produjo fundamentalmente en los siguientes estados y regiones del país como: Jalisco, Puebla, Sonora, La Laguna y Yucatán donde se concentra más del 75% de la producción de huevo en el país (UNA, 2018c).

Para el mismo año, México se ubicó como el cuarto productor de huevo a nivel mundial, después de China (1,090.9 millones de cajas), EUA (243.2 millones de cajas), India (215.7 millones de cajas) (UNA, 2018d). Cada caja de huevo consta de 360 unidades (30 docenas de huevos).

La comercialización del huevo para consumo humano, conocido también como huevo para plato, suele hacerse mediante tres vías principales: el 79% se comercializa a granel en los mercados tradicionales y centrales de abasto, el 14% en tiendas de autoservicio en envases cerrados y tiendas de conveniencia y el 7% restante, se destina al uso industrial (UNA, 2018e).

En la actualidad el precio de la proteína de huevo, es comparativamente más barato que el de la carne de res, cerdo o del pescado, sin contar que su adquisición es mucho más rápida y sencilla. Debido a su versatilidad y bajo costo con respecto a otras fuentes de proteína, y la facilidad de su preparación se integra fácilmente a la dieta de grandes sectores de la población Cruz, *et al* (2016).

El principal consumidor de huevo a nivel mundial es México, teniendo un consumo per cápita de 22.7 Kg de huevo; casi un huevo diario. En segundo lugar, se encuentra Rusia con 18.44 Kg; en tercer lugar, Colombia con 16.38 kg; Argentina en cuarto lugar con 15.56 Kg, y en quinto lugar Nueva Zelanda con 14.69 Kg (UNA, 2018f).

En materia de política agrícola, los precios han sido el origen de las mayores polémicas y conflictos, aunque el sector público en su momento intervino para regular el mercado y fijar precios a un número cada vez mayor de productos agropecuarios, en la actualidad el precio del huevo está totalmente regulado por la

oferta y la demanda, además de la relación que existe con el nivel de consumo, de tal modo que las variaciones a nivel nacional son determinados por las fluctuaciones en el consumo que se producen en las grandes ciudades, y para el caso del huevo el precio que rige los demás mercados es establecido por el comportamiento del precio que rige la Ciudad de México, ya que esta plaza es la que consume casi la mitad de la producción nacional de huevo (Ortega, 2014).

Planteamiento del problema

La importancia alimenticia, pero sobre todo económica que tiene el sector avícola productor de huevo para plato es de trascendencia nacional, debido a que el consumo de huevo se ha extendido y está en aumento a nivel mundial, así como a su amplia disponibilidad en el mercado, fácil preparación y precio competitivo en relación con otros productos ricos en proteínas de origen animal Cruz, et al (2016).

El abastecimiento de huevo para plato en México se da principalmente por la producción de los estados de Jalisco, Puebla y Sonora en donde se concentra el 75% de la producción de huevo (UNA, 2018), en estos estados se localizan once de las principales empresas productoras encabezadas por: Proteína Animal, Bachoco, El Calvario, Empresas Guadalupe, Socorro Romero Sánchez, Granjas Avícolas Rancho Grande, José Asunción, Productora de Huevos Gigantes, Gena Agropecuaria, Avícola González y González e Impulsora Agropecuaria Santa Rosa (Cruz et al. 2016).

La baja del poder adquisitivo expresado en salarios reales, hace que el precio del huevo sea un factor muy importante en la alimentación del mexicano por su costo más barato, fácil adquisición y de alto nivel proteico.

Los elevados niveles de producción han permitido satisfacer prácticamente la totalidad del consumo interno, y por tanto, que las importaciones representen menos del 1.2% del consumo nacional de huevo para plato (UNA, 2016).

En México se cuenta con la tecnología más avanzada para la producción masiva de este alimento básico, desde los aspectos genéticos, hasta el desarrollo de maquinaria especializada para la recolección del producto, clasificación y empaquetado, aunque no cuenta con los avances en materia farmacológica que se han desarrollado en la actividad (Pérez, 2000).

Ante este panorama es importante explicar el comportamiento de los precios del huevo, ¿cómo ha sido el ciclo y qué lo explica?, así como encontrar los periodos de tiempo fundamentales que determinan el precio futuro y el impacto que ejerce en el tiempo el precio del sorgo, toda vez que este insumo forma parte fundamental de los costos de producción de la actividad, ya que hasta el año 2017, la alimentación forma parte del 62.4 % de los costos de producción del huevo, por tal motivo, el huevo es un producto que debe ser considerado como de primera necesidad en el consumo, la información obtenida servirá de apoyo para poder tomar decisiones que disminuyan el riesgo en cambios tan bruscos de los precios. a aquellos actores relacionados con esta actividad, sobre las variaciones de los precios.

Objetivos

Objetivo General

Determinar la capacidad predictiva de los modelos SARIMA y MFT que describan la serie del precio promedio mensual de huevo blanco pagado al productor en México, desde el año 2000 - 2017, a través de la metodología de Box- Jenkins y efectuar pronósticos con el fin de proporcionar información útil para planificar y tomar decisiones en el sector avícola productor de huevo para plato en el corto y mediano plazo.

Objetivos Específicos

- 1).- Utilizar la metodología Box-Jenkins, para identificar el mejor modelo SARIMA, que se ajuste al comportamiento de la serie de tiempo de precios nominales de huevo blanco en México y permita realizar pronósticos con el mejor nivel de confianza.
- 2).- Desarrollar un modelo dinámico bivariado de función de transferencia de series de tiempo y evaluar la relación e impacto de los PPSRG como variable independiente que influye para pronosticar en el corto y mediano plazo los PPHBP
- 3).- Difundir una herramienta para la toma de decisiones del sector avícola productor de huevo e ilustrar que la metodología genera resultados satisfactorios en el corto y mediano plazo.

Hipótesis

Hipótesis general

Los precios promedio del huevo blanco presentan al menos un componente de las cuatro fluctuaciones características: tendencia a largo plazo, variación cíclica, estacional e irregular que pueden ser modelados para anticiparse al comportamiento futuro real de la variable estudiada.

Hipótesis específicas

- 1).- Los precios del huevo futuros se explican por los mismos precios del pasado y la serie presenta comportamientos estacionales periódicos de un año.

- 2).- Los precios del maíz y sorgo influyen e impactan de manera inmediata en los precios presentes y futuros de los precios del huevo.

Revisión de literatura

El origen de la Avicultura mesoamericana se da cuando las culturas prehispánicas florecieron en el preclásico Maya (1000 a. C – 200 a. C), esta avicultura se basó principalmente la cría de guajolotes domesticados por los mayas, al mismo tiempo se dio en las culturas Mesoamericanas como: la Olmeca, Chichimeca, Totonaca, Zapoteca, Teotihuacano, Tolteca y Azteca por lo que el surgimiento de la avicultura mexicana, se dio en forma paralela a la avicultura más avanzada del mundo (Aguirre, 1980).

En la teoría del mercado de productos agropecuarios se señala que el comportamiento de los precios de materias primas, es típicamente el resultado de una mezcla compleja de cambios asociados con factores de tendencia, estacionales, cíclicos y aleatorios; mientras que la inestabilidad de los precios que caracteriza a los mercados de productos agropecuarios, se explican por tres factores: a) Son relativamente competitivos, la demanda derivada y la oferta primaria son típicamente inelásticas, b) La naturaleza biológica del proceso de producción significa que la oferta es parcialmente dependiente de procesos aleatorios (clima) y es frecuentemente de naturaleza estacional, c) Los productores y acopiadores primarios deben usar los precios esperados para la toma de decisiones y las expectativas introducen cambios sistemáticos en los precios y cantidades (Tomek y Kaiser, 2014).

Algunos trabajos relacionados con el análisis del mercado del sector avícola y sus factores determinantes como el precio al productor son mencionados a continuación. Un ejemplo es el realizado por López (1990) quien utilizó un modelo de ecuaciones simultaneas para estudiar el mercado del huevo en México, donde incluyó como variables explicativas de la oferta, al precio del alimento balanceado, mismo que hizo depender del precio del sorgo y de la soya; al precio al productor de huevo, que lo relacionó con el precio oficial, y a la tecnología, que la representó con una variable de tendencia.

García *et al.* (2003), utilizaron una serie historia de 1967 a 2000 y mediante modelos de regresión múltiple obtuvieron la tendencia, y aplicando el suavizamiento de series históricas, obtuvieron el índice estacional, cíclico y aleatorio de la serie de precios reales de huevo blanco pagado al productor, para posteriormente realizar predicciones.

Rojas (2005), actualizó el trabajo de López (1990) y también utilizó un modelo de ecuaciones simultaneas, el cual incorporó directamente como variables explicativas de la oferta el precio del alimento balanceado, a la tecnología, que la aproxima con la conversión alimenticia a kilogramo de huevo, el precio al productor de huevo, una variable de tendencia y una de clasificación con la que separa los periodos de economía cerrada (1960-1985) y abierta (1986 -2010).

Se destaca también el trabajo realizado por Ortega (2013), quien utilizando un modelos de regresión lineal múltiple, estimó la producción nacional avícola hasta el año 2024, así como los precios de maíz y la soya, utilizando en su primer modelo como variables predictoras, la producción avícola anual, el costo anual de la materia prima y el tamaño de la población, mientras que para el segundo utilizó como variables exógenas a los años, el número de habitantes, el precio de la tonelada de maíz (*Zea mays*) y soya (*Glycine max*), llegando a la conclusión que para el año 2024 la producción huevo para plato crecerá un 17.4 % es decir a 1.74 % anual, destacando que las mejoras buenas prácticas de producción, sustentabilidad, genética aplicada y alimentación pueden mejorar este resultado; sin embargo no contempla el análisis de los precios del huevo para plato al productor ni al consumidor.

Cruz *et al.* (2016) utilizando una serie de 1960 a 2012, y con estimaciones de mínimos cuadrados en dos etapas también estudiaron el mercado del huevo en México, pero a diferencia del trabajo de López, (1990) y de Rojas, (2004). En su estudio incluyó como variables, el precio al productor de pollo como producto competitivo del huevo, al alimento balanceado, la tecnología, una variable de clasificación y una de tendencia, y a partir de sus resultados obtuvieron coeficientes

de elasticidad para huevo y con los resultados pudieron realizar estimaciones respecto al precio pagado al productor, en el corto plazo.

Referente a investigaciones donde se utiliza la metodología Box y Jenkins en el sector avícola, se destaca el trabajo realizado por Peña y Sumpsi (1980), quienes utilizaron la metodología de los modelos paramétricos ARIMA y de función de transferencia para cuantificar cómo operan los mecanismos de transmisión de efectos entre los precios de origen y consumo de pollo en España, encontraron que la transmisión de efectos debidos a aumentos en el nivel general de precios no transmitidos a origen vía consumo para esa época, tiene lugar a muy largo plazo.

Aunque, existe poca información de esta metodología aplicada al sector avícola, se han encontrado estudios para el sector pecuario. Se destaca el trabajo realizado por Barreras *et al*, (2013), quienes utilizando un modelo univariado de series de tiempo, pronosticaron el comportamiento de la producción de carne de cerdo en Baja California México, encontrando que el mejor modelo que explica la producción resultó ser un ARMA (12,12).

Asimismo (Ceballos, 2015) estimó el precio internacional del arroz (*Oryza sativa L.*) bajo el modelo ARIMA, utilizando una serie de junio de 2002 a noviembre de 2012, encontró que el mejor modelo que refleja adecuadamente el proceso estocástico generado por la serie de datos fue un SARIMA (1,0,1)X(1,0,1)_{s=12} y concluyó que a medida que aumenta el precio del arroz existe un factor predominante en la producción; el crecimiento de la población.

Si bien el estudio de (Ramírez, 1993), no trata sobre cuestiones agroalimentarias, resulta interesante mencionarlo, puesto que detalla de manera sencilla y simple la aplicación de la metodología de función de transferencia, estudiando el número de muertes humanas en función de variables ambientales como la temperatura y dióxido de azufre de Inglaterra durante el invierno de 1962. Mediante este método demostró que un aumento de la unidad en el dióxido de azufre aumenta la mortalidad en 20.44 ± 3.67 muertes.

Bibliográfica

- Aguirre B. C. 1980. Historia de la Avicultura mexicana, México, D.F. miembro de la Asociación de Escritores de Baja California. pp: 1 - 440.
- Barreras S., S.L. Eduardo., P.L. Cristina., F.S. Fernando. 2013. Uso de un modelo univariado de series de tiempo para la predicción del comportamiento de la producción de carne de cerdo en Baja California. México. Revista científica. Univ. De Zulia. Venezuela. Vol. XXIII. No. 5. pp:403 – 409.
- Ceballos P. S.G y P. Reinaldo. 2015. Estimación del precio internacional del arroz (*Oryza sativa* L) bajo el modelo ARIMA. Revista Mexicana de Ciencia agrícolas. INIFAP. México. No. 11. pp: 2083-2089.
- Cruz J., S., R. García M., J. S. Mora F., y R.C. García S. 2016. El mercado de huevo para plato en México, 1960 – 2012. Agricultura Sociedad y Desarrollo. Vol. 13 No. 3. pp: 385 - 399.
- García M., R., J. A. García S., y R. C. García S. 2003. Teoría del Mercado de Productos Agrícolas. Instituto de Socioeconomía, Estadística e Informática, Programa de Postgrado en Economía. Colegio de Postgraduados. Montecillo, Texcoco Edo de México. 382 p.
- López L. E. 1990. Modelo econométrico del mercado del huevo en México 1960 - 1987. Tesis de maestría. México, ISEI-Economía, Colegio de Postgraduados-Montecillo.
- Ortega, S. de T. J. 2014. Plan Rector Visión 2014 – 2024. “Sistema producto huevo para plato”. Imagen Editorial Yire. Cd. de México. 110 p
- Peña D. y S. José M. 1980. Un enfoque de series temporales para el análisis de la relación entre los precios del pollo en origen y consumo. Revista Estadística Española. No. 89. pp:115 – 137.
- Pérez V. F. C. 2000. El mercado del huevo en México. Tesis. Maestría. México. ISEI-Economía. Colegio de Postgraduados. Montecillo.
- Ramírez, G.M.E. 1993. SAS macro for analyzing step and impulse response functions derived from transfer function models. http://www.sascommunity.org/wiki/SAS_Global_Forum_Proceedings/SUGI_93 : p 990 – 995.
- Rojas R. M. M. 2005. Modelo econométrico del mercado del huevo en México, 1960-2003. Tesis de maestría. México, ISEI-Economía, Colegio de Postgraduados-Montecillo.

SAGARPA. 2004. Situación actual y perspectiva de la producción de huevo para plato en México. Folleto. Coordinación general de ganadería. Ciudad de México.

Tomek, W. G., and H. M. Kaiser. 2014. Agricultural product prices. Ithaca and London. Cornell University Press. 394 p.

UNA (Unión Nacional de Avicultores). Compendio de Indicadores económicos del sector avícola. México, 2017 y 2018.

UNCTAD. 2013. Mexico's Agriculture development. Perspectives and outlook. pp: 115 – 118.

CAPITULO I. METODOLOGÍA BOX – JENKINS PARA PRONOSTICAR LOS PRECIOS DE HUEVO BLANCO PAGADOS AL PRODUCTOR EN MÉXICO

Samuel Luis Rojas, M.C
Colegio De Postgraduados, 2018

RESUMEN

El huevo de gallina es uno de los alimentos más demandados en México, porque es una fuente de proteína accesible, preparación fácil, versátil y con disponibilidad amplia en el mercado. En 2016 el consumo *per cápita* en México fue 23.1 kg; además, representó el consumo mayor en el mundo respecto a las demás fuentes de proteína. El objetivo de este estudio fue desarrollar un modelo de pronóstico para los precios nominales mensuales de huevo blanco pagados al productor en México (PPHBP). Los datos que se usaron fueron del periodo 2000 a 2016 y la metodología fue Box-Jenkins de procesos estacionales autorregresivos integrados de medias móviles (SARIMA). Los parámetros de los modelos se estimaron con el método de máxima verosimilitud con el paquete Statistical Analysis System. Un modelo basado en la serie PPHBP se adaptó para el periodo 2000 a 2016 y se validó con los datos de enero a diciembre de 2017. El mejor modelo estimado fue SARIMA (0, 1, 1) X (1, 0, 1)_{s=12} e indicó que los PPHBP pueden explicarse con los precios de dos y doce meses previos. Los valores pronosticados para 2017 fueron relativamente cercanos a los valores observados. El modelo SARIMA representó con cierta precisión el PPHBP en el próximo año y proporcionó información para planificar y tomar decisiones en el sector avícola.

Palabras clave: Precios, huevo, metodología Box - Jenkins, SARIMA, pronóstico, predicción.

BOX - JENKINS METHODOLOGY TO FORECAST WHITE EGG PRICES PAID TO THE PRODUCER IN MEXICO

Samuel Luis Rojas, M.C
Colegio De Postgraduados, 2018

ABSTRACT

The chicken egg is one of the most demanded foods in Mexico, because it is a source of accessible protein, easy preparation, versatile and with wide availability in the market. In 2016, per capita consumption in Mexico was 23.1 kg; In addition, it represented the highest consumption in the world with respect to other sources of protein. The objective of this study was to develop a forecast model for nominal monthly white egg prices paid to the producer in Mexico (PPHBP). The data that was used were from the period 2000 to 2016 and the Box-Jenkins methodology of seasonal autoregressive integrated of moving averages processes (SARIMA). The parameters of the models were estimated with the maximum likelihood method with the Statistical Analysis System package. A model based on the PPHBP series was adapted for the period 2000 to 2016 and validated with data from January to December 2017. The best estimated model was SARIMA (0, 1, 1) X (1, 0, 1)_{s=12} and indicated that the PPHBP can be explained with the prices of two and twelve months prior. The predicted values for 2017 were relatively close to the observed values. The SARIMA model represented with some precision the PPHBP in the next year and provided useful information to plan and make decisions in the poultry sector.

Keywords:

Prices, egg, Box - Jenkins methodology, SARIMA, forecast, prediction

INTRODUCCIÓN

El huevo de gallina es la fuente de proteína más completa y barata del sector pecuario en México, por su precio competitivo es la proteína animal más accesible en el mercado mexicano. Además, el huevo de gallina es uno de los alimentos más demandados en el ámbito nacional por su disponibilidad amplia en el mercado y preparación fácil (Alonso, 2017). De 1994 a 2016 el consumo *per cápita* pasó de 16.7 a 23.1 kg y su tasa de crecimiento media anual (TCMA) fue 1.5% (UNA, 2016a). El crecimiento de consumo *per cápita* de huevo en México se explica por su precio competitivo con respecto a otras fuentes de proteína. Cruz *et al.* (2016) señalaron que con un salario mínimo en 2013 podían adquirirse en promedio 2.45 kg de huevo, o 1.84, 0.69 y 0.70 kg de carne de pollo, porcino o bovino. Sin embargo, con datos de la FAO (2016), CONAPO (2016) y CONASAMI (2016) el cálculo mostró que con un salario mínimo promedio de 2016 podían adquirirse 4.71 kg de huevo o 3.30, 0.86 y 0.56 kg de carne de pollo, cerdo y res. Lo que indicó que la proteína del huevo continúa siendo la más barata.

La producción nacional de huevo pasó de 1,956,000 t en el año 2000 a 2,765,422 t en 2016, registrando una TCMA de 2.9 % superior a la de la población (1.98 %) (UNA, 2016b). La producción de 119.9 millones de cajas de huevo obtenidas en 2016, ubicó a México como el cuarto productor mundial, después de China, EE. UU. y la India, que en el mismo año produjeron 931.8, 224.5 y 208.8 millones de cajas respectivamente. Los principales estados productores en México son Jalisco (55 %), Puebla (15 %), Sonora (8 %), región de la Comarca Lagunera (Durango y Coahuila) (5 %), Yucatán (5 %), Nuevo León (3 %), Sinaloa (3 %), Guanajuato (2 %), otros estados (4%) del total nacional (UNA, 2016c). En los tres principales estados se localizan once de las principales empresas productoras encabezadas por: Proteína Animal, Bachoco, El Calvario, Empresas Guadalupe, Socorro Romero Sánchez, Granjas Avícolas Rancho Grande, José Asunción, Productora de Huevos Gigantes, Gena Agropecuaria, Avícola González y González e Impulsora Agropecuaria Santa Rosa (Cruz *et al.* 2016).

La producción de huevo fue menor que el consumo (2,799,000 t) en 2016; por lo que, para cubrir la demanda se importó 1.21 % del total (UNA, 2016d) y entre el 2006 y 2016 creció a una tasa media anual de 4.8 %.

Los costos de alimentación, empaque y mano de obra, son tres de los insumos más importantes en la producción de huevo, representando el 63.4 %, 5.7 % y 4.4 % respectivamente. En el año 2016, se consumieron 16,000,000 de t de alimento balanceado de los cuales el 63 % es grano forrajero (maíz y sorgo), equivalente a 10,000,000 de t; mientras que, en el mismo año, la avicultura productora de huevo generó 255 mil empleos directos y 985 mil empleos indirectos (UNA, 2016e).

Tomek y Kaiser (2014) señalan que el comportamiento de los precios de materias primas, es típicamente el resultado de una mezcla compleja de cambios asociados con factores de tendencia, estacionales, cíclicos y aleatorios; mientras que la inestabilidad de los precios que caracteriza a los mercados de productos agropecuarios, se explican por tres factores: a) Son relativamente competitivos, la demanda derivada y la oferta primaria son típicamente inelásticas, b) La naturaleza biológica del proceso de producción significa que la oferta es parcialmente dependiente de procesos aleatorios (clima) y es frecuentemente de naturaleza estacional, c) Los productores y acopiadores primarios deben usar los precios esperados para la toma de decisiones y las expectativas introducen cambios sistemáticos en los precios y cantidades.

Con una serie histórica de 1967 a 2000, mediante promedios móviles, García *et al.* (2003) obtuvieron la tendencia, el índice estacional, cíclico y aleatorio, de la serie de precios reales de huevo blanco pagado al productor y mediante el método multiplicativo realizaron predicciones. Con datos de 1976 a 2013, mediante modelos de regresión múltiple, Ortega (2013) estimó la producción nacional avícola hasta el año 2024, así como los precios de maíz y la soya, utilizando en su primer modelo como variables predictoras, la producción avícola anual, el costo anual de la materia prima y el tamaño de la población, mientras que para el segundo utilizó como variables exógenas a los años, el número de habitantes, el precio de la tonelada de

maíz (*Zea mays*) y soya (*Glycine max*), llegando a la conclusión que para el año 2024 la producción huevo para plato crecerá un 17.4 % es decir a 1.74 % anual, destacando que las mejoras buenas prácticas de producción, sustentabilidad, genética aplicada y alimentación pueden mejorar este resultado; sin embargo no contempla el análisis de los precios del huevo para plato al productor ni al consumidor. Cruz *et al.* (2016) utilizando una serie de 1960 a 2012, y con estimaciones de mínimos cuadrados en dos etapas obtuvieron coeficientes de elasticidad para huevo y con los resultados pudieron realizar estimaciones respecto al precio pagado al productor, en el corto plazo. En la presente investigación se utilizó la metodología de procesos estacionales autorregresivos integrados de medias móviles (SARIMA). Estos modelos son más apropiados para predicciones a largo plazo que para corto plazo que presentan patrones estacionales, sin embargo, estas se analizan sobre una serie estacionaria y se necesitan como mínimo 50 datos (Box y Jenkins, 1976), de ahí que su predicción sea más confiable que los métodos utilizados en las tres investigaciones antes mencionadas.

El modelo SARIMA es útil en situaciones en las que los datos de series temporales muestran fluctuaciones periódicas de estacionalidad que se repiten con aproximadamente la misma intensidad cada año Box y Jenkins (1976). Esta característica hace que este modelo sea adecuado para estudios de productos agropecuarios, y por lo tanto para el sector avícola. García *et al.* (2003) plantearon que el proceso biológico de la producción y los factores climatológicos, provocan que la mayor parte de la producción de la mayoría de los productos agrícolas salgan en determinados meses del año, originando una marcada estacionalidad de la producción y, en consecuencia, de los precios. En temporadas de primavera - verano se esperaría un incremento en la producción de huevo, debido a las condiciones óptimas de producción para las gallinas, dando como resultado que el precio del producto esté por debajo de su promedio y en las temporadas de otoño – invierno se esperaría una producción contraria, debido a la temporada de frío. El objetivo de este estudio fue desarrollar modelos de series de tiempo para pronosticar los PPHBP, con base en los precios nominales promedios mensuales disponibles entre 2000 y 2016.

Con los datos recopilados de los meses del año 2017 se validó el modelo. Dada la incertidumbre del mercado, el pronóstico de los PPHBP utilizando modelos de series de tiempo puede proporcionar información útil que puede utilizarse para facilitar la planificación en la toma de decisiones de los diferentes actores que forman parte de este sector. La hipótesis planteada fue que los PPHBP futuros se explican por los mismos precios del pasado y la serie presenta comportamientos estacionales periódicos de un año.

MATERIALES Y MÉTODOS

Para conocer el comportamiento de los PPHBP y realizar pronósticos, se utilizó una serie histórica de precios, proporcionados por la Unión Nacional de Avicultores (UNA). La serie de tiempo de los PPHBP se dividió en dos partes: los datos de enero de 2000 a diciembre de 2016 expresados en (\$ kg⁻¹), se utilizaron para desarrollar el modelo de series temporales, y los precios de enero a diciembre de 2017 también expresados en (\$ kg⁻¹), se utilizaron para validar el modelo.

Si se asume que $Y' = (Y_1, Y_2, \dots, Y_n)$ es una serie de tiempo, entonces un modelo estacional SARIMA con “s” observaciones por periodo, denotado por $(p,d,q)X(P,D,Q)s$, (Guerrero, 1991), dado por:

$$\Phi_P(B) \phi_p(B) \nabla_S^D \nabla^d Y_t = \Theta_Q(B) \theta_q(B) a_t$$

donde:

B es el operador de retraso ($B^r Y_t = Y_{t-r}$).

Y_t es la serie de tiempo de la variable Y en el tiempo t .

$\Phi(B)$ = polinomio autorregresivo (AR) de la parte estacional, de orden “P”, esto es: $\Phi(B) = 1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p$.

$\phi(B)$ = polinomio autorregresivo (AR) de la parte no estacional, de orden “p”, se simboliza y se desarrolla así, $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$.

$\Theta(B)$ = polinomio de promedios móviles (MA) de la parte estacional, de orden “Q”, donde: $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$.

$\theta(B)$ = polinomio de promedios móviles (MA) de la parte no estacional, de orden “q”, donde: $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$.

$\nabla^d = (Y_t - Y_{t-1})^{D=1}$ es el número de diferencias que se necesitan para estacionar la serie en la parte no estacional y se simboliza “d”.

$\nabla_S^D Y_t = (1 - B^S)^{D=1} Y_t$, es el número de diferencias estacionales y se representa “D”.

a_t = se refiere a los términos de error aleatorio o también llamado ruido blanco que se supone que son variables aleatorias independientemente distribuidas de forma idéntica muestreadas de una distribución con media igual a cero y varianza $a_t \approx N(0, \delta^2)$ (Box y Jenkins, 1976).

En el análisis de series de tiempo, la variable a_t se conoce comúnmente como ruido blanco, y se interpreta como un efecto exógeno que el modelo no puede explicar. Teniendo en cuenta la serie temporal PPHBP, este ruido blanco puede ser; por ejemplo, un efecto de variables climáticas, enfermedades aviares, el tipo de cambio peso - dólar, la situación de riesgo país, catástrofes naturales o factores aleatorios.

Se utilizó el procedimiento PROC ARIMA del software Statistical Analysis System (SAS) versión 9.4. (SAS, 2014) para adaptar el modelo SARIMA a la serie PPHBP del periodo 2000 - 2016 utilizando la metodología para la construcción del modelo ARIMA, se ajustó a los pasos sugeridos por Box y Jenkins: identificación del modelo, estimación de parámetros, verificación de supuestos y predicción (Greene, 2003) (Figura 1.1).

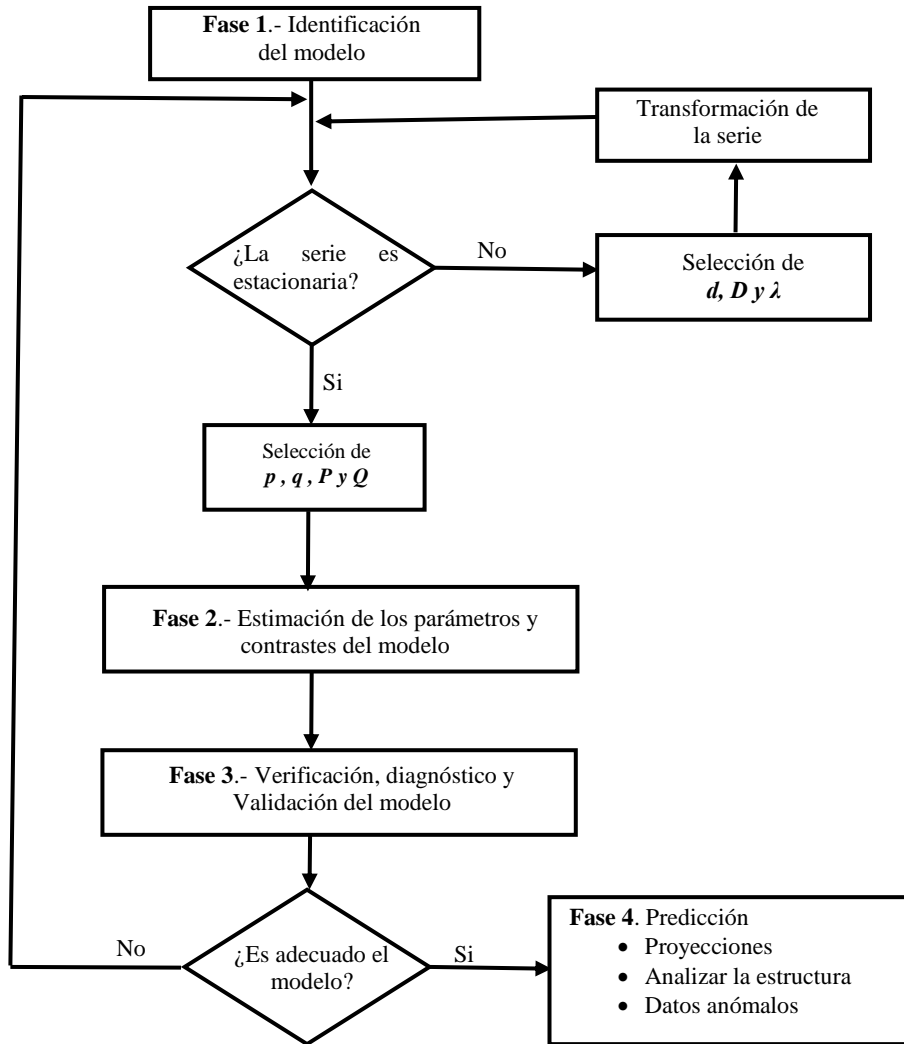


Figura 1.1. Flujograma de la metodología Box- Jenkins.

La idoneidad de cada modelo se verificó mediante gráficas de los residuales contra el tiempo. Si el modelo es adecuado, se esperaría que los residuales estén distribuidos de forma aleatoria alrededor de cero, sin mostrar ningún patrón o tendencia; en caso que existiera algún tipo de comportamiento regular, esto sería un motivo para suponer que los residuales no tienen una distribución normal y no son puramente aleatorios (Ljung, 1978). Se utilizó la elección del modelo de forma parsimoniosa sugerida por Burnham y Anderson (2002), mediante el Criterio de información Akaike (AIC) y el Criterio Bayesiano de Schwartz (SBC) los cuales comparan la bondad de ajuste de los diferentes modelos. Ambos criterios se basan

en la utilización de la suma de los cuadrados de los errores, buscando minimizarla a partir de diversas combinaciones de p y q . Los valores de AIC y el SBC más bajos indican un mejor ajuste en el modelo.

RESULTADOS Y DISCUSIÓN

Los datos de la serie PPHBP muestran tendencia al alza, enmascarada por una marcada estacionalidad, producto de las condiciones climáticas que hay a lo largo del año y el proceso biológico que ocurre en las gallinas (García *et al*, 2003). En épocas de otoño – invierno; los precios están por arriba de la media, ya que es la temporada donde las gallinas reducen su producción debido al frío que se presenta; mientras que en los meses de primavera – verano, y debido a las condiciones favorables, las gallinas aumentan su producción, ocasionado un exceso de oferta que obliga a los productores a mantener el precio debajo del promedio (Figura 2a).

Los picos más altos de la serie temporal corresponden a los meses de agosto de 2012 a mayo de 2014 (observaciones 152 a 173), y se explican por el brote de la influenza aviar que atacó a las parvadas en México, mientras que los picos de noviembre 2014 a abril de 2015 (observaciones 179 a 184), se explican por la volatilidad y devaluación del peso mexicano frente al dólar, que afecta directamente a la industria del huevo; aproximadamente el 65 % de los costos de producción están dolarizados, esto trae consigo que los costos de las materias primas aumenten y poco a poco los productores trasladen el costo de la alimentación al consumidor final (Figura 1.2a).

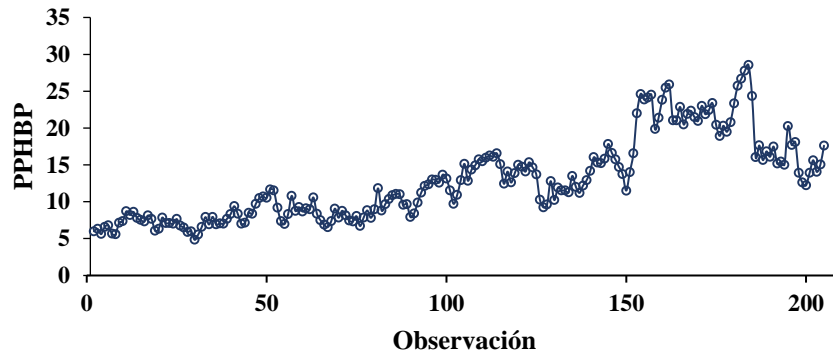
La prueba de Cox – Box arrojó un $\lambda = -0.25$, por lo que la serie PPHBP se debió transformar en logaritmos naturales para tener varianza constante. La magnitud de este coeficiente concuerda con la teoría de las series temporales, planteada por Cox y Box, (1964) para la aplicación de cualquiera de los modelos de la familia de los ARMA. Es necesario que las series sean estacionarias en media la cual se obtiene con al menos una diferencia, mientras que para para estabilizar la varianza se puede aplicar una transformación de la familia Cox - Box, además de estabilizar la varianza,

mejoran la aproximación a la distribución normal del proceso $\{Z_t\}$, donde λ es el parámetro de transformación. Entonces $Y' = (Y_1, Y_2, \dots, Y_n)$ es el vector de los logaritmos naturales, renombrando ahora a la serie como LPPHBP. Se observa que la serie Y_1, Y_2, \dots, Y_n frente al tiempo todavía hay cierta tendencia, pero a través de la primera diferencia (∇) se obtiene una serie estacionaria. Por lo tanto, se considera $d = 1$ (Figura 1.2b).

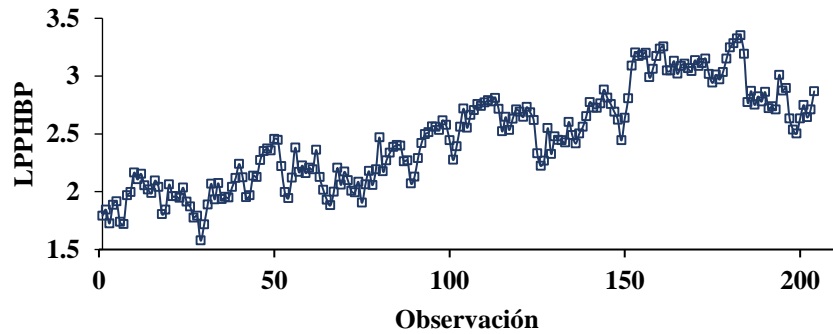
La serie PPHBP diferenciada y transformada a logaritmos naturales se ha renombrado LPPHBP (1), y a simple vista ya es estacionaria en media (no existe tendencia) y en varianza, situación que concuerda con lo establecido con Box y Jenkins, (1976) puesto que la serie a estudiar debe tener una variabilidad constante a través del tiempo y sin tendencia (Figura 1.2c).

Una situación diferente es planteada por García *et al.* (2003), ya que para poder realizar pronósticos de PPHBP, utilizando el enfoque univariado, fue necesario transformar la serie PPHBP a precios reales. De este modo la nueva serie contiene las cuatro componentes características de una serie de tiempo: tendencia (T), ciclicidad (C), estacionalidad (E) y aleatoriedad (I). Posteriormente mediante un movimiento medio centrado de doce meses, se eliminó la componente estacional (E) perdiéndose seis datos al principio y al final de la serie, quedando únicamente las componentes (C), (T) e (I) y aplicando mínimos cuadrados ordinarios (MCO) calcularon la ecuación de Tendencia (T) con mejor ajuste de la serie de PPHBP reales.

a) Serie PPHBP original



b) Serie PPHBP transformada con logaritmo natural



c) Serie LPPHBP diferenciada

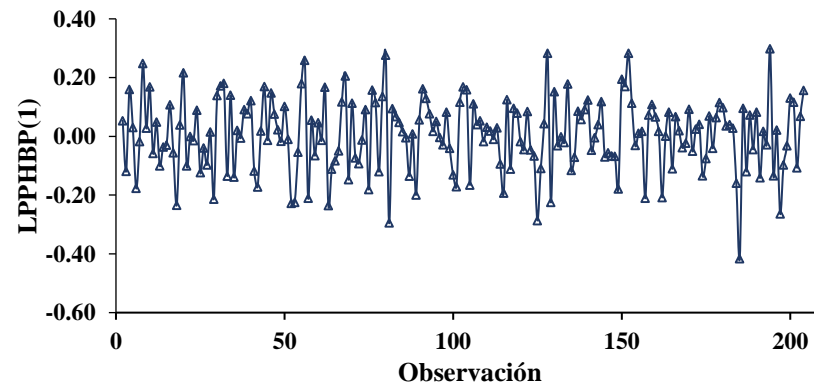


Figura 1.2. Diagnósticos gráficos de la serie original (PPHBP): (a) Comportamiento original de la serie PPHBP en \$ kg-1, 2000 – 2016, (b) Comportamiento de la serie PPHBP transformada a logaritmos naturales (LPPHBP), (c) Serie LPPHBP diferenciada en la parte no estacional, transformada con logaritmos naturales y sin tendencia.

Se procedió a verificar la estacionariedad o no estacionariedad de la serie de tiempo de manera estadística, planteada por Dickey y Fuller (1981), mediante la prueba de


raíz unitaria de Dickey Fuller Aumentada (ADF), la cual consiste en incluir rezagos de la primera diferencia de Y_t en la regresión de prueba para admitir la posible existencia de autocorrelación serial. Para ello se plantea la siguiente hipótesis, H_0 : La serie no es estacionaria ($\rho=1$) y tiene raíz unitaria vs H_a : La serie es estacionaria ($\rho \neq 1$) y no tiene raíz unitaria. Regla de decisión: Se rechaza H_0 si tau calculado \leq tau de tablas (Pankratz, 1983). Dado que el valor absoluto de la tau calculada es menor que la tau de tablas, se rechaza la hipótesis nula y se concluye que la serie PPHBP no tiene raíz unitaria, por lo tanto, es estacionaria, es decir tiene media y varianza constante en el tiempo (Cuadro 1.1).

Cuadro 1.1. Prueba de Dickey Fuller aumentada (ADF) para la serie de precios promedios mensuales de huevo blanco pagados al productor en México (PPHBP).

Tipo	Retardos	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Media Simple	0	-215.091	0.0001	-15.04	<.0001	113.09	0.0010
	1	-243.971	0.0001	-10.92	<.0001	59.61	0.0010
	2	-449.149	0.0001	-10.15	<.0001	51.53	0.0010
Tendencia	0	-215.194	0.0001	-15.00	<.0001	112.59	0.0010
	1	-244.632	0.0001	-10.90	<.0001	59.43	0.0010
	2	-451.725	0.0001	-10.13	<.0001	51.35	0.0010

Se realizaron gráficos de la función de autocorrelación estimada (ACF) y la función de autocorrelación parcial (PACF) para la serie ∇ LPPHBP, para el caso de la ACF presentan una correlación alta para los *lags* = 12, 24, señal de presencia de un comportamiento estacional, repetido cada 12 meses ($s=12$), además con pequeños picos significativos en los valores 3, 5 y 6. Con respecto a la FACF se notan picos altos en las correlaciones para el lag=12 y 24 repitiéndose el mismo patrón estacional anual, así como pequeños picos en los retardos 3, 5, 7, por lo que se intuye que un proceso SARIMA puede describir y explicar el comportamiento de los PPHBP (Figura 1.3).

a) Función de autocorrelación (ACF)



b) Función de autocorrelación parcial (PACF)




Figura 1.3. Función de autocorrelación ACF (a) y Función de autocorrelación parcial PACF (b) estimadas para la serie $Y_t = (1 - B)LPPHBP$.

La etapa de identificación del modelo es prácticamente una inspección visual, la ACF y la PACF graficadas pueden ocultar información de interés para la elección del modelo adecuado (Gujarati, 2009), por lo que se propusieron 14 modelos. De estos se identificaron los cuatro mejores que cumplen con la significancia de parámetros y ruido blanco.

Se estimaron los coeficientes AR, MA, considerando diferentes elecciones de p y q , así como los valores de SBC, AIC y las estimaciones para la varianza δ_ε^2 para los cuatro mejores modelos SARIMA ajustados a la serie LPPHBP. Sin embargo, se encontraron problemas con la convergencia cuando se usa $D=1$. Por lo tanto, considerando que 1 diferencia en la parte no estacional suele ser suficiente ($d = 1$), se estableció d en 1 en todos los modelos. El modelo con el valor SBC y AIC más bajo para este conjunto de datos, fue el SARIMA $(0,1,1) \times (1,0,1)_{s=12}$ (Cuadro 1.2).

Cuadro 1.2. Valores de AR, MA, SBC y AIC de los modelos SARIMA identificados $(p,1,q) \times (1,0,1)_{s=12}$ y estimadores para δ_ε^2 .

Mejores modelos SARIMA [†]	Componentes no estacionales		Componentes estacionales		SBC ^p	AIC ^q	δ_ε^2	
	AR [¶] (p)	MA [§] (q)	AR ^{¶¶} ($P1$)	MA ^{§§} ($Q1$)				
1.- $(0,1,0) \times (1,0,1)_{s=12}$	X	-	-	0.98831	0.88766	-322.277	-328.904	0.0107
2.- $(0,1,1) \times (1,0,1)_{s=12}$	X	-	0.18861	0.99193	0.90043	-322.599	-332.538	0.0104
3.- $(1,1,0) \times (1,0,1)_{s=12}$	X	-0.14903	-	0.98678	0.88663	-321.254	-331.194	0.0106
4.- $(1,1,1) \times (1,0,1)_{s=12}$	X	-0.99998	-0.99944	0.97302	0.86431	-313.578	-326.831	0.0109

† SARIMA: Proceso estacional autorregresivo integrado de media móvil, ¶ AR: Coeficiente autorregresivo de orden (p), § MA: Coeficiente de media móvil de orden (q), ¶¶ AR: Coeficiente autorregresivo de orden (P), §§ MA: Coeficiente de media móvil de orden (Q), ^p SBC: Criterio Bayesiano de Shwartz, ^q AIC: Criterio de información Akaike. Fuente: elaboración propia con los resultados de las estimaciones de los modelos SARIMA.

Se calcularon los parámetros AR_{1,1} para la parte estacional Φ_{12} , el parámetro de promedio móvil MA_{2,1} Θ_{12} para la parte estacional y el componente de promedio móvil MA_{1,1} θ_2 para la parte no estacional, mediante máxima verosimilitud, utilizando el proceso PROC ARIMA (SAS, 2014). Para la interpretación y significancia de los estimadores, Box *et al.* (1994), plantean que para que se considere un modelo moderado, se deben incluir aquellos parámetros cuya estadística t absoluta sea mayor que 2 y los p-values sean <0.05. Por lo tanto, se considera al modelo SARIMA $(0,1,1) \times (1,0,1)_{s=12}$ como moderado, ya que se ajusta suficientemente a los datos antiguos sin usar ningún parámetro innecesario (Cuadro 1.3).

Cuadro 1.3. Estimación del modelo para la serie de tiempo LPPHBP(1) por máxima verosimilitud.

Parámetro	Estimación	Error estándar	Valor t	Aprox Pr > t	Retardo
MA1,1	0.18861	0.0674	2.8	0.0051	2
MA2,1	0.90043	0.09707	9.28	<.0001	12
AR1,1	0.99193	0.01481	66.99	<.0001	12

Después de estimar los parámetros del modelo, se validó mediante el análisis de residuos (Yafee, 1999). Se analizaron los residuos estandarizados a través de su histograma, el gráfico de ACF respectivo y los valores de p para las pruebas de ruido blanco. Se parte, que los residuos estandarizados estimados, a partir de este modelo deberían comportarse como una secuencia independiente e idénticamente distribuida, con una media de cero y una varianza constante. El histograma de los residuos estandarizados para el modelo se aproximó a una distribución normal. La ACF de los residuos sugiere que las autocorrelaciones están dentro de la banda de confianza, es decir, son cercanas a cero. Este resultado indica que los residuos no se desviaron significativamente de un proceso de ruido blanco cero, y son puramente aleatorios, por lo que ya no hay información de dependencia de unos datos con otros a través del tiempo. Dado el alto p-value, asociado con las estadísticas de Chi cuadrada, no existe razón para rechazar la hipótesis nula de que los residuos son ruido blanco ($p \text{ value} \leq 0.05$). Por lo tanto, el modelo SARIMA (0,1,1) X (1,0,1)_{s=12} se ajusta al comportamiento de los datos de LPPHBP (Figura 1.4).

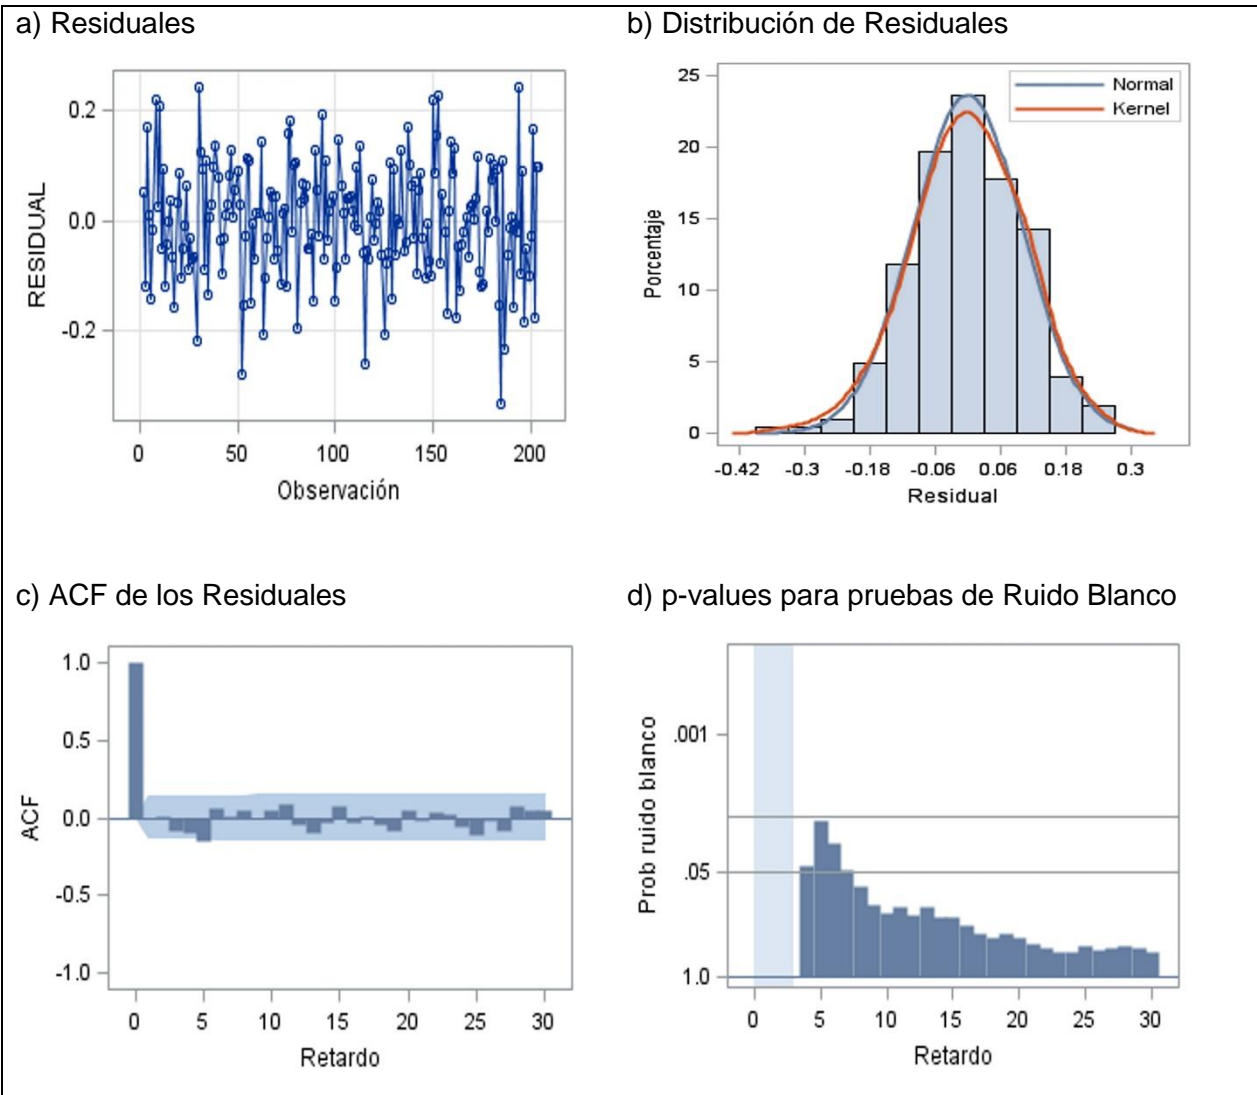


Figura 1.4. Diagnósticos gráficos para evaluar el ajuste del modelo SARIMA $(0,1,1)X(1,0,1)_{s=12}$: (a) Residuos estandarizados, (b) Histograma de los residuos estandarizados, (c) ACF de los residuales y (d) Valores p para las pruebas de ruido blanco.

El PPHBP para el mes de agosto de 2012 fue de $21.98 \text{ \$ kg}^{-1}$, mes en que se reportó la presencia de la gripe aviar en México. Utilizando el valor de la elasticidad precio propia de la oferta, Cruz *et al.* (2016), pronosticaron que el PPHBP debió de ser $20.16 \text{ \$ kg}^{-1}$; a partir de esta estimación concluyeron que el incremento del precio al consumidor de huevo de 73 %, que se originó de julio a agosto de 2012, debió ser de 45.78 %; el incremento adicional del precio en alta medida se debió a cuestiones especulativas, mientras que el modelo SARIMA $(0,1,1) X (1,0,1)_{s=12}$, para la misma

fecha lo estimó en 18.82 \$ kg⁻¹; precio inferior al reportado por la UNA en 14.38% y por debajo al estimado por Cruz *et al.* (2016) en un 8.28%.

El PPHBP para el mes de agosto de 2012 fue de 21.98 \$ kg⁻¹, mes en que se reportó la presencia de la gripe aviar en México. Utilizando el valor de la elasticidad precio propia de la oferta, Cruz *et al.* (2016), pronosticaron que el PPHBP debió de ser 20.16 \$ kg⁻¹; a partir de esta estimación concluyeron que el incremento del precio al consumidor de huevo de 73 %, que se originó de julio a agosto de 2012, debió ser de 45.78 %; el incremento adicional del precio en alta medida se debió a cuestiones especulativas, mientras que el modelo SARIMA (0,1,1) X (1,0,1)_{s=12}, para la misma fecha lo estimó en 18.82 \$ kg⁻¹; precio inferior al reportado por la UNA en 14.38% y por debajo al estimado por Cruz *et al.* (2016) en un 8.28%.

Los valores pronosticados fuera de muestra para los meses del año 2017 teniendo en cuenta el modelo SARIMA (0,1,1) X (1,0,1)_{s=12}, se compararon estos precios con los de la serie PPHBP, las predicciones son buenas, habiéndose obtenido un error porcentual absoluto medio (MAPE) de 12.38 que indica que nuestro pronóstico está errado en un 12.38 %. Sin embargo, no se debe basar el pronóstico únicamente en este indicador, también se debe examinar la prueba de Chi cuadrada para conocer si la serie presenta residuales que se comportan como ruido blanco. Este modelo predice valores de PPHBP muy próximos a los observados, porque todas se ubican dentro de la banda de confianza estimada al ± 95 % (Cuadro 1.4).

Cuadro 1.4. Precios nominales observados y pronosticados de huevo blanco pagados al productor en México, 2017 (\$ kg-1), obtenidos a través del modelo SARIMA (0,1,1) X (1,0,1)_{s=12}.

Año 2017	Meses											
	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
PPHBP	15.54	17.10	15.16	15.38	18.48	15.30	17.01	19.28	19.50	20.16	21.55	20.03
Límite inferior 95%	13.65	13.32	12.15	11.51	9.94	9.29	9.27	10.42	9.62	9.85	9.69	9.82
Pronóstico	16.66	17.67	16.83	16.55	14.79	14.27	14.67	16.95	16.08	16.87	17.00	17.63
Límite superior 95%	20.34	23.43	23.31	23.81	22.03	21.94	23.23	27.59	26.86	28.90	29.82	31.65
Residual	-1.12	-0.57	-1.67	-1.17	3.69	1.03	2.34	2.33	3.42	3.29	4.55	2.40

Este modelo se usa para predecir fuera de la muestra los PPHBP y fue capaz de hacerlo con relativa precisión para un año posterior. Sin embargo Chu (1978), plantea que estas estimaciones pueden no ser creíbles para predecir los precios en el mediano y largo plazo, por lo que es preciso señalar, que no obstante, el principal inconveniente que presenta este tipo de modelos, radica en su propio fundamento, ya que al estar basados en hechos pasados y aprender de la propia historia para realizar las predicciones, estas serán acertadas en la medida en que los factores que determinan la evolución sigan actuando del mismo modo y no sean alterados de forma notoria.

Dado que este producto es estratégico en la dieta y el consumo nacional, es importante que en estudios futuros donde se utilice la metodología Box - Jenkins, se introduzca al modelo nuevas variables que expliquen la perturbación aleatoria y que estén asociadas de manera directa con el incremento de los PPHBP. Las variables a considerar podrían ser los precios mensuales del sorgo, pasta de soya y maíz amarillo, ya que la alimentación de las aves representa más del 63 % de los costos de producción, con lo que se esperarían estimaciones más precisas. Para ello se plantea el uso de los modelos multivariantes de series de tiempo también llamados modelos de función de transferencia (TFM). Según Keller (1987), estos modelos permiten simular y estudiar cómo ciertos “escenarios” definidos por posibles evoluciones de la variable explicativa, afectan a la variable respuesta, de ahí que su predicción sea más confiable que los métodos que utilizan el modelo de regresión clásica.

CONCLUSIONES

Es posible modelar los PPHBP en México utilizando la metodología propuesta por Box y Jenkins, dado que el comportamiento de estas series no es completamente aleatorio y se pueden describir como series de tiempo con una alta probabilidad de éxito en la modelación a través de dicha metodología.

El mejor modelo que representó el comportamiento de los PPHBP fue el SARIMA $(0, 1, 1) \times (1, 0, 1)_{s=12}$ al demostrar que el precio al productor de huevo blanco en un mes dado puede ser estimado por el precio del huevo que ocurrió en 2 y 12 meses antes. Las estimaciones de los parámetros y los pronósticos fueron estadísticamente apropiadas y significativas, aun cuando la serie estudiada presenta variabilidad alta. Se encontró que la serie estudiada presenta estacionalidad de 12 meses repitiéndose el mismo patrón de manera periódica. Las predicciones del modelo en el corto plazo difieren en 12.38 % de los datos observados, minimizándose el error aleatorio. Los PPHBP estimados proporcionan información útil para planificar y tomar decisiones en el sector avícola productor de huevo para plato en el corto plazo.

LITERATURA CITADA

- Alonso P., F. A. 2017. Situación de la actividad avícola nacional. Revista Los Avicultores y su entorno No 116. México. pp: 96 - 104.
- Box, G. E. P., and G. M. Jenkins. 1976: Time Series Analysis: Forecasting and Control. Ed. Holden-day. San Francisco, CA. 575 p.
- Box, G. E. P., G. M. Jenkins., and G.C. Reinsel. 1994: Time Series Analysis: Forecasting and Control. 3rd ed. Ed. Prentice Hall. Englewood Cliffs, NJ.
- Burnham, K. P., and D. R. Anderson. 2002. Model selection and multimodel inference: a practical information-theoretic approach. 2da ed. Ed. Springer. New York, N.Y. 515 p.
- Chu, K.Y. 1978. Short-run forecasting of commodity prices: An application of autoregressive moving average models. IMF Staff Papers. Vol. 25 No 1. pp: 90-111.

- CONAPO. Consejo Nacional de Población. 2013. Proyecciones de la población de México 2010-2050. <http://www.conapo.gob.mx/es/CONAPO/Proyecciones> (Consulta: enero a marzo 2018).
- CONASAMI. Comisión Nacional de los Salarios Mínimos. <https://www.gob.mx/conasami> (Consulta: enero a marzo 2018).
- Cox, D. R. and G. E. Box. 1964. An analysis of transformations. *Journal of the Royal Statistical Society. Serie B.* Vol 26. pp: 211-252.
- Cruz J., S., R. García M., J. S. Mora F., y R.C. García S. 2016. El mercado de huevo para plato en México, 1960 – 2012. *Agricultura Sociedad y Desarrollo.* Vol. 13 No. 3. pp: 385 - 399.
- Dickey, D. and W. Fuller. 1981. Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica Journal of the Econometric Society.* Vol. 49. No. 4. pp:1057-1072.
- FAOSTAT. Organización de las Naciones Unidas para la Agricultura y la Alimentación. <http://faostat.fao.org> (Consulta: enero a marzo 2018).
- García M., R., J. A. García S., y R. C. García S. 2003. Teoría del Mercado de Productos Agrícolas. Instituto de Socioeconomía, Estadística e Informática, Programa de Postgrado en Economía. Colegio de Postgraduados. Montecillo, Texcoco Edo de México. 382 p.
- Greene, W. H. 2003. *Econometric analysis.* 5th edition. Ed. Prentice Hall. Upper Saddle River. New Jersey. pp: 619 - 621.
- Guerrero G., V. M. 1991. *Análisis Estadístico de Series de Tiempo Económicas.* Ed. UAM - Iztapalapa. México. 309 p.
- Gujarati, D. N. y C. Porter D. 2009. *Econometría.* 5ta ed., Ed. Mc Graw Hill, México. 921 p.
- Keller, A. 1987. Modeling and forecasting primary production rates using Box-Jenkins transfer function Models. *Canadian Journal of Fisheries and Aquatic Sciences.* Vol. 44 No 5. pp: 1045 – 1052.
- Ljung, G. M. and G. E. Box. 1978. On a measure of lack of fit in time series models. *Econometrica Journal of the Econometric Society.* Vol. 65. pp:297 - 303.
- Ortega, S. de T. J. 2014. Plan Rector Visión 2014 – 2024. “Sistema producto huevo para plato”. Imagen Editorial Yire. Cd. de México. 110 p

- Pankratz, A. 1983. Forecasting with univariate Box-Jenkins models concepts and cases. Ed., John Wiley & Sons. United States. 587 p.
- SAS. 2014. The SAS (Statistical Analysis System) System for Windows V. 9.4. Sas Institute Inc. Cary, NC. USA.
- Tomek, W. G., and H. M. Kaiser. 2014. Agricultural product prices. Ithaca and London. Cornell University Press. 394 p.
- UNA (Unión Nacional de Avicultores). Compendio de Indicadores económicos del sector avícola. México, 2015, 2016 y 2017.
- Yafee, R. A., and M. McGee. 1999. Introduction to time Series Analysis and forecasting. Ed., Academic Press, Inc. Brooklyn, New York. pp: 83 – 89.

CAPITULO II. UN MODELO BIVARIADO DE FUNCIÓN DE TRANSFERENCIA PARA PRONOSTICAR EL PRECIO DE HUEVO BLANCO PAGADO AL PRODUCTOR EN MEXICO

Samuel Luis Rojas, M.C
Colegio De Postgraduados, 2018

RESUMEN

El huevo para plato es uno de los alimentos con mayor demanda en el ámbito nacional, debido a que es una de las fuentes de proteína más accesible, de preparación fácil, versátil y con disponibilidad amplia en el mercado. El objetivo de este trabajo fue desarrollar un modelo de series de tiempo para pronosticar los precios nominales mensuales de huevo blanco pagados al productor en México (PPHBP) mediante la metodología Box-Jenkins de modelos de función de transferencia (MFT), evaluar su relación con los precios promedios rurales del sorgo (PPSRG), utilizando datos del periodo 2000 a 2017. Los parámetros de los modelos y las predicciones se estimaron con el método de máxima verosimilitud con el paquete Statistical Analysis System (SAS) y fueron estadísticamente apropiadas y significativas. El mejor MFT que representó el comportamiento de los PPHBP fue el que posee dos coeficientes autorregresivos, tres de media móvil, dos grados de denominador “ r ”, un grado de numerador “ s ” y un coeficiente “ b ”, se encontró que el PPSRG impacta en los PPHBP en un mes después de ocurrido el primero, disminuyendo la varianza original del PPHBP = 0.01036 a 0.009771 con el modelo de transferencia, representando una disminución del 5.69 %. El MFT bivariado genera mejores pronósticos de los PPHBP que el modelo SARIMA, debido a que el primero, toma en cuenta la evolución temporal del PPSRG logrando estimaciones más cercanas a la realidad y útiles para planificar y tomar decisiones en el sector avícola en el corto y mediano plazo.

Palabras clave: Precios, huevo, SARIMA, Modelo de Función de transferencia, sorgo, pronóstico, predicción

A TRANSFER FUNCTION BIVARIATE MODEL TO FORECAST WHITE EGG PRICES PAID TO THE PRODUCER IN MEXICO

Samuel Luis Rojas, M.C
Colegio De Postgraduados, 2018

ABSTRACT

The egg for dish is one of the most demanded foods in the national scope, because it is one of the most accessible sources of protein, easily prepared, versatile and widely available in the market. The objective of this work was to develop a time series model to forecast the nominal monthly prices of white egg paid to the producer in Mexico (PPHBP) by means of the Box-Jenkins methodology of transfer function models (MFT) to evaluate its relationship with the average rural prices of sorghum (PPSRG), using data from the period 2000 to 2017. Model parameters and predictions were estimated using the maximum likelihood method with the Statistical Analysis System (SAS) package and were statistically appropriate and significant. The best MFT that represented the behavior of the PPHBP was the two autoregressive coefficients, three moving average, two degrees of denominator "r", one degree of numerator "s" and one coefficient "b", it was found that the PPSRG impacts in the PPHBP in a month after the first occurred, decreasing the original variance of PPHBP = 0.01036 to 0.009771 with the transfer model, representing a decrease of 5.69%. The bivariate MFT generates better forecasts of the PPHBP than the SARIMA model, because the first one takes into account the temporal evolution of the PPSRG achieving estimates closer to reality and useful for planning and making decisions in the poultry sector in the short and medium term.

Key words: Prices, egg, SARIMA, Transfer function model, sorghum, forecast, prediction

INTRODUCCION

La industria avícola mexicana es la actividad pecuaria más dinámica del país y uno de los sectores estratégicos para la alimentación en México. En el 2017, la participación porcentual de la avicultura en el Producto Interno Bruto (PIB) total fue de 0.737%. En el PIB pecuario participó con 37.2 por ciento (UNA, 2018a). El consumo per cápita promedio del huevo en el año 2017 fue de 22.7 kg; mientras que la producción fue menor que el consumo (2,718,476 t), por lo que para cubrir la demanda se importó 1.25 % del total (UNA, 2018b); así como, entre el 1994 y 2017 creció a una tasa media anual de 2.7%.

Los principales estados productores de huevo en México son Jalisco, Puebla y Sonora, y en conjunto en 2017 aportaron 75 % de la producción nacional (UNA, 2018c). Los costos de alimentación, empaque y mano de obra, son tres de los insumos más importantes en la producción de huevo, representando el 62.4%, 6.5% y 5.0% respectivamente. En el año 2017, se consumieron 16 millones de toneladas de alimento balanceado de los cuales el 63% fue grano forrajero (maíz y sorgo), equivalente a 10 millones de toneladas; mientras que, en el mismo año, la avicultura productora de huevo generó 209,637 mil empleos directos y 1,048,187 empleos indirectos (UNA, 2018d).

García *et al.* (2003), realizaron estudios para pronosticar los PPHBP, mediante promedios móviles, en ellos obtuvieron la tendencia, el índice estacional, cíclico y aleatorio, de la serie de precios reales de huevo blanco pagado al productor y mediante el método multiplicativo realizaron predicciones. Ortega (2014), utilizó datos de 1976 a 2013, y mediante modelos de regresión múltiple, estimó la producción nacional avícola hasta el año 2024, así como los precios de maíz y la soya. Cruz *et al.* (2016) utilizó una serie de 1960 a 2012, y con estimaciones de mínimos cuadrados en dos etapas obtuvieron coeficientes de elasticidad para huevo y con los resultados pudieron realizar estimaciones respecto al precio pagado al productor, en el corto plazo.

En la presente investigación se utilizó la metodología Box- Jenkins a través de los Modelos de Función de Transferencia (MFT). Estos modelos son útiles en situaciones en las que se supone las relaciones no son instantáneas ni estáticas, es decir consideran la dimensión temporal de las observaciones y permiten medir cómo se transmiten los efectos entre las variables, por lo que se consideran como un instrumento para evaluar las respuestas dinámicas, (Box y Jenkins, 1976).

México importa de EE.UU. más de 16 millones de toneladas de granos y semillas, ubicándolo como un alto dependiente de la producción y venta de EE. UU, esto trae consigo que los costos de las materias primas aumenten y poco a poco los productores trasladen el costo de la alimentación al consumidor final. Por ello, el objetivo del presente estudio es desarrollar y evaluar la relación e impacto de los PPSRG como variable independiente que influye para pronosticar en el corto y mediano plazo los PPHBP mediante un modelo bivariado de función de transferencia de series de tiempo. En la hipótesis se establece que los precios de los granos forrajeros (maíz y sorgo) impactan de manera inmediata en los precios presentes y futuros de los PPHBP.

MATERIALES Y METODOS

Los modelos de función de transferencia (MFT), son una extensión del modelo de regresión clásico (MRC). Sin embargo, el MRC presenta dos limitaciones importantes: supone que la relación es instantánea y estática, la segunda, que la parte no explicada por la variable (o variables) independientes es ruido blanco. Mientras que los MFT permiten que el modelo de ruido tenga una estructura diferente.

Los MRC son estáticos, mientras que MFT son dinámicos (Ramírez, 1993), es decir combinan los conceptos de regresión múltiple con los de los modelos univariantes de series de tiempo. Los MFT resuelven estas dos limitaciones, al considerar la dimensión temporal de las observaciones y permitir que el ruido siga un modelo ARMA (p,q) .

Los MFT relacionan dos o más series temporales elaborando modelos causales de predicción. Se considera la forma de relacionar una serie temporal, denominada *salida* (Y_t) en función de una u otras series temporales, que se denominan *entrada* X_t . También se considera *a priori* que existe una causalidad unidireccional desde las entradas hacia la salida, desechando la posibilidad de retroalimentación.

En un sistema lineal de una única *entrada* y única *salida*, la serie Y_t y la serie X_t se relacionan a través de un filtro lineal de la siguiente forma:

$$Y_t = v_0 X_t + v_1 X_{t-1} + v_2 X_{t-2} + \dots + N_t$$

$$Y_t = (v_0 + v_1 B + v_2 B^2 + \dots) X_t + N_t$$

$$Y_t = v(B) X_t + \dots \quad (1)$$

Donde $X_t, X_{t-1}, X_{t-2}, \dots, X_{t-n}$ son los valores presentes y pasados de la serie de entrada, $v(B) = v_0 + v_1 B + v_2 B^2 + \dots + v_n B^n$ se refiere como función de transferencia del filtro de Chiogna (2007), y (t) es el ruido del sistema que es independiente de la serie input X_t . Los coeficientes de $v(B)$ se conocen como la función de respuesta al impulso del sistema y representan el impacto en Y_t de un cambio de unidad en X_t . Para que el sistema planteado en la ecuación (1) sea estable se debe cumplir que una variación finita produzca una variación también finita en la salida. Esto es deberá cumplirse que

$$\sum_{j=0}^{\infty} v_j = g \quad (2)$$

Siendo g la *ganancia* finita del modelo. El valor de g representa el cambio total en Y_t motivado por un cambio unitario en X_t mantenido en el tiempo.

Los propósitos de la modelización de función de transferencia son identificar y estimar la función de transferencia $v(B)$ y el modelo del ruido $N(t)$ sobre la base de la información que proporcionan la serie *entrada* y la serie *salida*.

En la práctica, no se puede esperar que las variaciones en la salida Y_t sigan exactamente el patrón determinado por el modelo de función de transferencia ya que existen disturbios de varios tipos que no sean X_t que se representan por ruido N_t .

Entonces el modelo de función de transferencia con ruido incluido es:

$$Y_t = v(B)X_t + N_t \quad (3)$$

El modelo (3) se conoce como el modelo de retraso distribuido y es inestimable, debido a que en él aparece un número infinito de parámetros. Este problema se puede aliviar al expresar la función de transferencia como una representación parsimoniosa del peso de respuesta al impulso $v(B)$ que viene dada por la relación de dos polinomios (rationales) finito, obteniéndose:

$$Y_t = \frac{\omega(B)B^b}{\delta(B)} X_t + N_t \quad (4)$$

Donde

$\omega(B) = \omega_0 - \omega_1 B - \dots - \omega_s B^s$, es un polinomio de grado “ s ” y representa la magnitud del efecto que tiene una entrada en la salida (por ejemplo, impacto abrupto o gradual), mientras que:

$\delta(B) = 1 - \delta_1 B - \dots - \delta_r B^r$ es un polinomio de grado “ r ”, representa el tipo de duraciones del impacto transferido desde la entrada a la salida (por ejemplo, temporal o permanente)

b = es un parámetro de retardo que representa el retraso o tiempo que transcurre antes de que la respuesta a un cambio dado comience a tener efecto, es decir el impulso en la variable *entrada* produzca un efecto en la variable *salida*.

Por otro lado, el término de error no tiene por qué ser necesariamente un ruido blanco. Se puede suponer, con carácter general, que N_t sigue un proceso ARIMA (p, d, q) aunque sigue independiente de la variable de *input* X_t es decir:

$$N_t = \frac{\theta(B)}{\phi(B)(1-B)^d} a_t \quad (5)$$

con $\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ y $\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ de manera que todas las raíces de ambos polinomios caen dentro del círculo unidad siendo $(1 - B)^d$ el operador diferencias consecutivas utilizado para inducir estacionariedad y a_t es un ruido blanco.

Una vez lograda la estacionariedad en ambas variables, el proceso N_t deberá ser un *ARIMA* (p, d, q) con lo cual el modelo de función de transferencia se puede escribir como:

$$PPHBP_t = \mu + \frac{C\omega(B)}{\delta(B)} B^b PPSRG_t + \frac{\theta(B)}{\phi(B)} a_t \quad (6)$$

Donde:

$\omega(B), \delta(B)$ = Son polinomios en el operador de rezago B.

b = Es el número de periodos que transcurren antes de que el precio del sorgo (PPSRG) afecte al precio del huevo (PPHBP).

a_t = Disturbios (termino de perturbaciones que no se comportan como ruido blanco)

C = Constante de escala para el efecto directo del precio del sorgo (PPSRG) sobre el precio promedio del huevo blanco pagado al productor (PPHBP).

$\phi(B)\eta_t = \theta(B)a_t$ = Especificación ARMA para a_t .

$a_t = iidN(0, \sigma^2)$ Ruido blanco que supone que es una variable aleatoria independientemente distribuida de forma idéntica muestreadas de una distribución con media igual a cero y varianza constante.

Para conocer el comportamiento de los PPHBP, se utilizó una serie mensual de tiempo reportada por la Unión Nacional de Avicultores (UNA) de enero de 2000 a diciembre de 2017 en \$ kg⁻¹. La serie de tiempo del precio promedio mensual de sorgo (PPSRG), se utilizaron los precios proporcionados por el Sistema Nacional de Información e Integración de Mercados (SNIIM) de la Secretaria de Economía expresados en (\$ Kg⁻¹), para el mismo periodo.

Para realizar el análisis, se parte de la premisa de que los modelos de este tipo solo se pueden obtener y validar cuando corresponden a series asociadas

significativamente (Brocwell, 2004). Para calcular adecuadamente el término v se utilizó la metodología propuesta por Box y Jenkins, (1976) para la construcción de modelos de función de transferencia. Este consiste en las siguientes etapas: a) Identificación de los modelos ARIMA para Y_t y X_t , b) Preparación de las series de entrada y salida, c) Preblanqueo de la serie de entrada (X_t) y de salida (Y_t) para obtener α_t y β_t , d) Cálculo de la función de correlación cruzada entre (α_t, β_t) , e) Identificación de la función de transferencia, f) Estimación de la función de transferencia, g) Validación y predicción. Los modelos elaborados se validaron mediante pruebas estadísticas no paramétricas de aleatoriedad de los residuos del modelo y de su independencia. En el análisis se utilizó el procedimiento PROC ARIMA del software Statistical Analysis System (SAS) versión 9.4. (SAS, 2014).

RESULTADOS Y DISCUSION

Identificación de los modelos ARIMA para Y_t (PPHBP) y para X_t (PPSRG)

Los datos de la serie PPSRG (serie de entrada) y PPHBP (serie de salida) fluctúan en el tiempo, y siguen un comportamiento similar. Los picos más altos de la serie temporal de los PPHBP corresponden a los meses de agosto de 2012 a mayo de 2014 (observaciones 152 a 173), y se explican por el brote de la influenza aviar que atacó a las parvadas en México. Los picos de noviembre 2014 a abril de 2015 (observaciones 179 a 184), se explican por la volatilidad y devaluación del peso mexicano frente al dólar, que afecta directamente a la industria del huevo. Aproximadamente el 65% de los costos de producción están dolarizados, esto trae consigo que los costos de las materias primas aumenten y poco a poco los productores trasladen el costo de la alimentación al consumidor final (Figura 1a).

Los datos de la serie PPSRG muestran tendencia al alza, se observan picos en las observaciones 135 a 146, correspondientes a los meses de marzo de 2011 a febrero de 2012. Esto se debe a la volatilidad de los precios de los granos básicos del sector agropecuario a nivel mundial CEDRSSA, (2014). Ocasionado principalmente por las condiciones climáticas adversas que enfrentaron los países productores, tales como las sequías, heladas e inundaciones (Figura 1b).

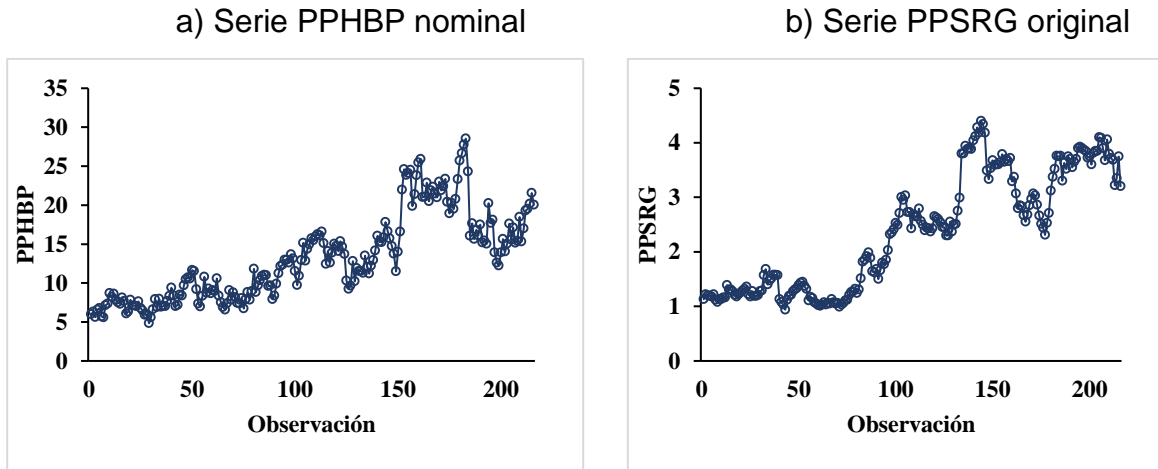


Figura 2.1.- Gráficos de las series de estudio: (a) Serie original PPHBP en \$ kg⁻¹, 2000 – 2017, (b) Serie PPSRG en \$ kg⁻¹, 2000 – 2017.

Etapa 1: Preparación de las series de entrada y salida

Las series PPHBP y PPSRG se transformaron en logaritmos naturales para que la varianza fuera constante Cox y Box, (1964). Se observa en ambas series tendencia, pero a través de la primera diferencia (∇) esto es, $(1 - B)LPPSRG_t$ y $(1 - B)LPPHBP_t$, las series se transformaron en estacionarias en media y varianza. Por lo tanto, se considera $d = 1$ para ambas series (Figura 2.2).

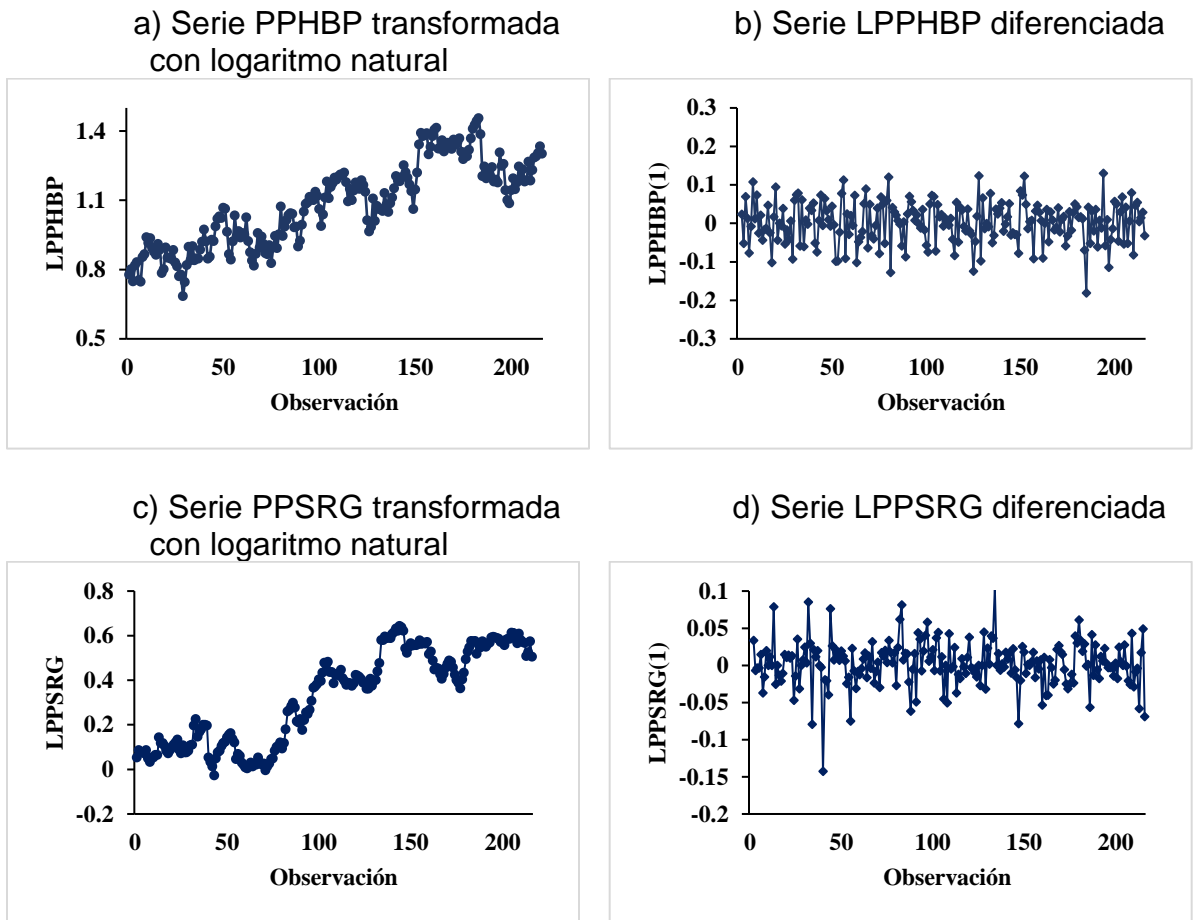


Figura 2.2. Gráficos de las series de estudio: (a) Serie PPHBP transformada a logaritmos naturales (LPPHBP), (b) Serie LPPHBP diferenciada en la parte no estacional, transformada con logaritmos naturales y sin tendencia, (c) Serie PPSRG transformada a logaritmos naturales (LPPSRG) (d) Serie LPPSRG diferenciada en la parte no estacional, transformada con logaritmos naturales y sin tendencia.

A partir de la inspección visual, las funciones de autocorrelación simple (ACF) y parcial (PACF) de la variable PPHBP estacionaria y mediante máxima verosimilitud, utilizando el proceso PROC ARIMA (SAS, 2014), se identificó al mejor modelo que cumpla con la significancia de parámetros, ruido blanco y se considere moderado. Para que se considere un modelo moderado, se deben incluir aquellos parámetros cuya estadística t absoluta sea mayor que 2 y los p-values sean <0.05 , Box *et al.* (1994). Por lo que, el modelo SARIMA $(0,1,1) \times (1,0,1)_{s=12}$ es mejor y moderado, ya que se ajusta a los datos antiguos sin usar ningún parámetro innecesario. Éste se

utilizó para realizar el preblanqueo de la variable *salida* para luego calcular la función de transferencia (Cuadro 2.1).

Cuadro 2.1. Estimación del modelo SARIMA para la serie de tiempo LPPHBP(1) por máxima verosimilitud.

Parámetro	Estimación	Error estándar	Valor t	Aprox Pr > t	Retardo	SBC ^p	AIC ^q	δ_{ε}^2
MA1,1	0.16739	0.06661	2.56	0.0104	2			
MA2,1	0.94368	0.09220	9.13	<.0001	12	-339.93	-350.04	0.01036
AR1,1	0.99710	0.01275	107.19	<.0001	12			

▸ SBC: Criterio Bayesiano de Shwartz, ^q AIC: Criterio de información Akaike, δ_{ε}^2 : Varianza del error.

Etapa 2: Preblanqueo de las series entrada (*input*) y salida (*output*)

Después de un análisis en la etapa de preparación de las series, se encontró que la serie de entrada PPSRG puede ser modelado por un modelo ARIMA (2,1,0), ya que PPSRG tiene una diferencia ordinaria, se puede decir que PPSRG sigue un proceso ARMA (2,0):

$$(1 - \phi_5 B^5 - \phi_8 B^8) PPSRG = a_t$$

Con los siguientes estimadores para $\phi_5 = -0.14669$ y $\phi_8 = -0.19027$. Así, para convertir la serie PPSRG a “ruido blanco”, se despeja a a_t

$$(1 - \phi_5 B^5 - \phi_8 B^8) PPSRG = a_t$$

Los residuos del modelo a_t se pueden obtener pasando la serie PPSRG(1) por un filtro definido por los parámetros del modelo, entonces para obtener los valores de a_t , se reescribió la ecuación en su forma de diferencias

$$a_t = PPSRG + 0.14669 PPSRG_{t-5} + 0.19027 PPSRG_{t-8} \quad (7)$$

Se aplicó la misma transformación de preblanqueo a la serie de salida PPHBP usando el mismo modelo obtenido SARIMA (0,1,1) X (1,0,1)_{s=12}. Obteniendo de este modelo la serie de residuos β_t , recordando que la serie LPPHBP (1) es la serie estacionaria de PPHBP después de la transformación, entonces se puede decir que PPHBP sigue un proceso estacional ARMA (0,1)X(1,1):

$$(1 - \Phi_{12}B^{12})LPPHBP = (1 - \theta_1B^2)(1 - \Theta_{12}B^{12})\beta_t$$

$$(1 - 0.99710B^{12})LPPHBP = (1 - 0.16739B^2)(1 - 0.94368B^{12})\beta_t$$

$$\beta_t = \frac{(1 - 0.99710B^{12})LPPHBP}{(1 - 0.16739B^2)(1 - 0.94368B^{12})} \quad (8)$$

Etapa 3: Cálculo de la función de correlación cruzada (CCF) entre a_t y β_t

La función de correlación cruzada (CCF) es una medida muy útil de la fuerza y la dirección de la relación entre dos variables aleatorias, es decir representan la dirección de causalidad (Granger, 1969). En este caso se deben usar series estacionarias ya que las covarianzas cruzadas sólo podrán interpretarse cuando se efectúan sobre series estacionarias.

Se supone que la variable PPSRG influye en el PPHBP pero no a la inversa, es decir, existe causalidad unidireccional de PPSRG hacia PPHBP, pero no existe retroalimentación. En la metodología de MFT solo interesa conocer la relación lineal entre variables, por lo que solo se toma en cuenta la parte positiva (retardos positivos) de la CCF. Así usando las ecuaciones (7) y (8) se calcularon las correlaciones cruzadas, con $k = \pm 1, \dots, \pm 25$.

Se observa que en la CCF existe una retroalimentación entre a_t y β_t , es decir, puede existir un efecto de retroalimentación del PPSRG sobre el PPHBP a partir del retardo k_1 . Sin embargo, debe notarse, que después del retardo 5, las demás correlaciones cruzadas son esencialmente ceros, además de que existe un patrón de comportamiento sinusoidal de estas correlaciones cruzadas (Figura 2.3).




Figura 2.3. Correlación cruzada entre las series PPSRG (*entrada*) y PPHBP (*salida*) preblanqueadas.

Etapa 4: Identificación de la función de transferencia

Se identificaron los órdenes r y s de los polinomios del denominador y del numerador respectivamente, así como el retardo inicial b del modelo de función de transferencia. Los órdenes r y s de los polinomios (B) y (B) se pudieron determinar por la forma de la función de correlación cruzada entre α y β a partir del retardo b planteada por Hillmer y Tiao, (1979). En la CCF se observa un pico en $b = 1$, que significa que toma un mes para que la variable PPSRG afecte a la variable PPHBP. Respecto al operador de orden r se observa que la CCF de la muestra se extinguen de un modo de onda sinusoidal amortiguada desde el retardo 1, por lo que es razonable fijar $r = 2$, y por lo tanto el valor "s" se obtiene a partir de que el patrón de decaimiento empieza en v_{b+s+1} . Para este caso el patrón de decaimiento inicia en v_1 , entonces $v_{b+s+1} = v_1$, por lo tanto $s = 0$ y los valores de b , r y s quedan de la siguiente forma $(b,r,s) = (1,2,0)$.

Luego el modelo tentativo de la función de transferencia identificado es el siguiente:

$$PPHBP_t = \frac{\omega_0}{(1 - \delta_1 B - \delta_2 B^2)} B^1 PPSRG_t + (\text{modelo de ruido})$$

Etapa 5: Estimación de la función de transferencia

La CCF calculada revela una estructura posible, se destaca que el operador del numerador y denominador pueden tener raíces complejas para que produzcan el efecto. El modelo con el valor SBC y AIC más bajo para estos conjuntos de datos, fue el modelo (1,2,0).

Para la interpretación y significancia de los estimadores, Box *et al.* (1994), plantean que se deben incluir aquellos parámetros cuya estadística t absoluta sea mayor que 2 y los p-values sean <0.05. Por lo tanto, se considera al modelo de transferencia (1,2,0) como moderado, ya que se ajusta a los datos antiguos sin usar ningún parámetro innecesario (Cuadro 2.2).

Cuadro 2.2. Estimación del modelo de transferencia para la serie de tiempo LPPHBP(1) por máxima verosimilitud.

Parám.	Estimador	Error estándar	Valor t	Aprox Pr > t	Retar-do	Variable	Desp.	SBC ^p	AIC ^q	δ_ε^2
MA1,1	0.16074	0.06757	2.38	0.0174	2	LPPHBP	0			
MA2,1	0.93248	0.10891	8.56	<.0001	12	LPPHBP	0			
AR1,1	0.99614	0.01131	88.06	<.0001	12	LPPHBP	0	-332.84	-352.95	0.00977
NUM1	0.18756	0.05739	3.27	0.0011	0	LPPPSG	1			
DEN1,1	0.69095	0.04899	14.11	<.0001	1	LPPPSG	1			
DEN1,2	-0.57169	0.05694	-10.04	<.0001	3	LPPPSG	1			

^p SBC: Criterio Bayesiano de Shwartz, ^q AIC: Criterio de información Akaike.

Por lo tanto, ya que se ha identificado el modelo de función de transferencia y estimado los parámetros del mismo, el modelo de transferencia final queda de la siguiente forma:

$$LPPHBP_t = \frac{0.18756}{(1 - 0.69095B + 0.5717B^3)} LPPSRG_t + \frac{(1 - 0.16074B^2)(1 - 0.93248B^{12})}{(1 - 0.99614B^{12})} a_t$$

Etapa 6: Validación y predicción

Después de estimar los parámetros del modelo, se validó mediante el análisis de residuos (Yafee, 1999). Los residuos estandarizados, su histograma, el gráfico de ACF respectivo y los valores de p para las pruebas de ruido blanco se muestran en la Figura 4.

La Figura 2.4(a) muestra que los residuos estandarizados estimados a partir de este modelo deberían comportarse como una secuencia independiente e idénticamente distribuida con una media de cero y una varianza constante. El histograma de la Figura 2.4(b) muestra que los residuos estandarizados para el modelo se aproximaron a una distribución normal como lo planteado por Jarque y Bera (1987). La ACF de los residuos en la Figura 2.4(c) muestra que las autocorrelaciones están dentro de la banda de confianza, es decir, son cercanas a cero. Este resultado significa que los residuos no se desviaron significativamente de un proceso de ruido blanco cero, y son puramente aleatorios, por lo que ya no hay información de dependencia de unos datos con otros a través del tiempo. La Figura 2.4(d) muestra los p -values para la prueba de ruido blanco. Dado que el p -value, asociado con las estadísticas de Chi cuadrada es alto, no existe razón para rechazar la hipótesis nula de que los residuos son ruido blanco (p -value ≤ 0.05). Por lo tanto, el MFT seleccionado se ajusta a los datos de LPPHBP.

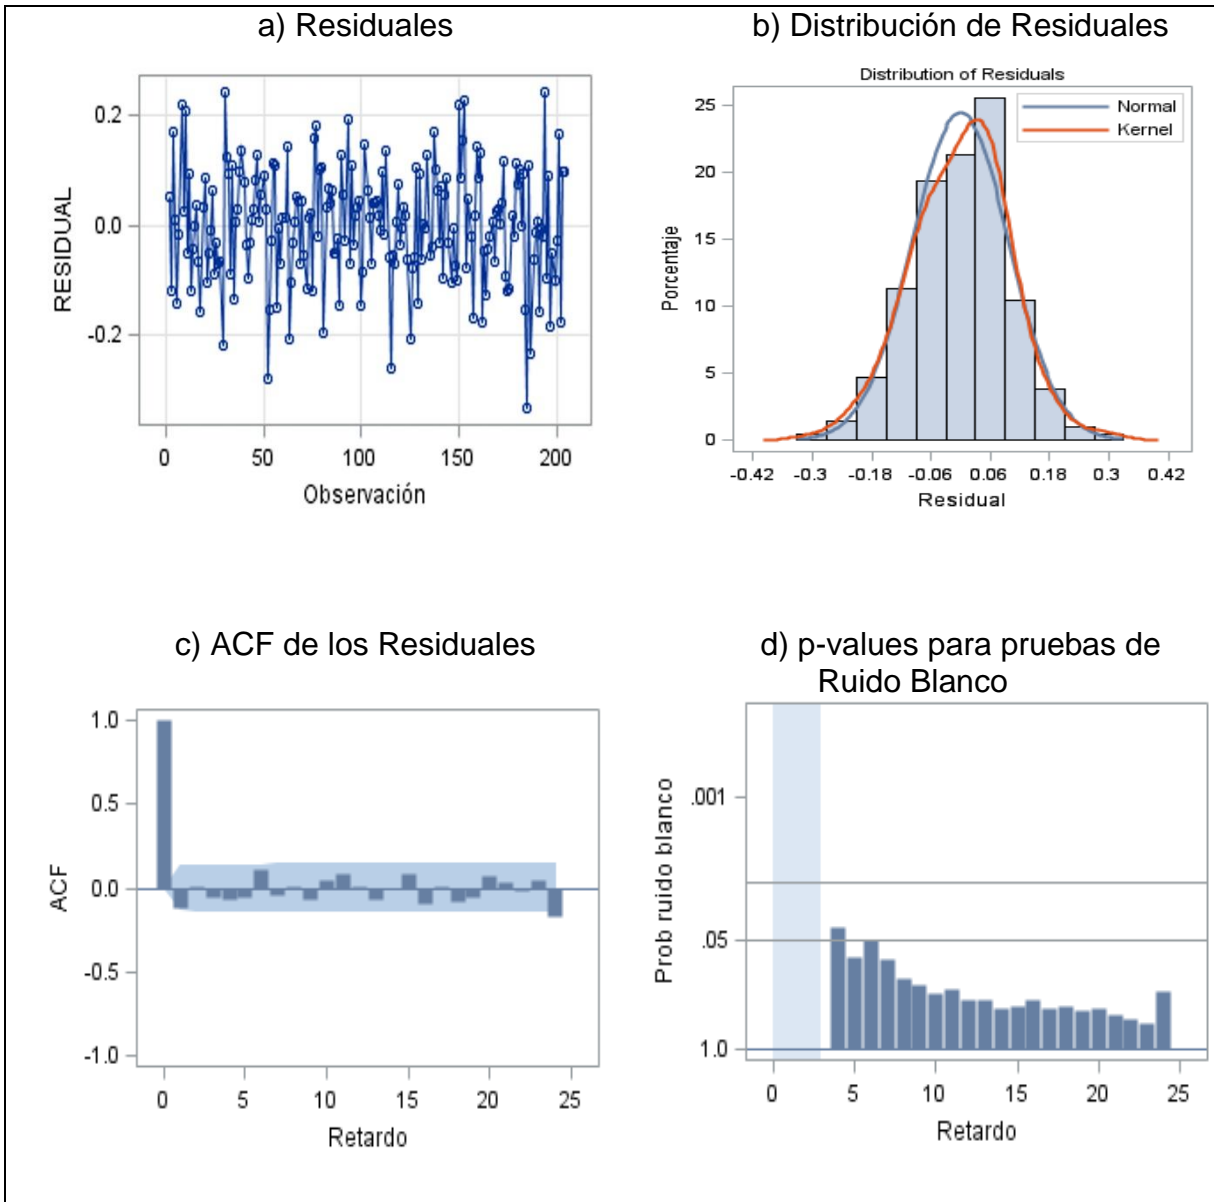


Figura 2.4. Gráficos para evaluar el ajuste del modelo SARIMA $(0,1,1)X(1,0,1)_{s=12}$: (a) Residuos estandarizados, (b) Histograma de los residuos estandarizados, (c) ACF de los residuales y (d) Valores p para las pruebas de ruido blanco.

Se llevó a cabo la última etapa de la metodología, en el cual los modelos estimados fueron utilizados para hacer predicciones fuera de la muestra para los 24 meses siguientes a la última observación utilizada en la estimación (Figura 2.5).

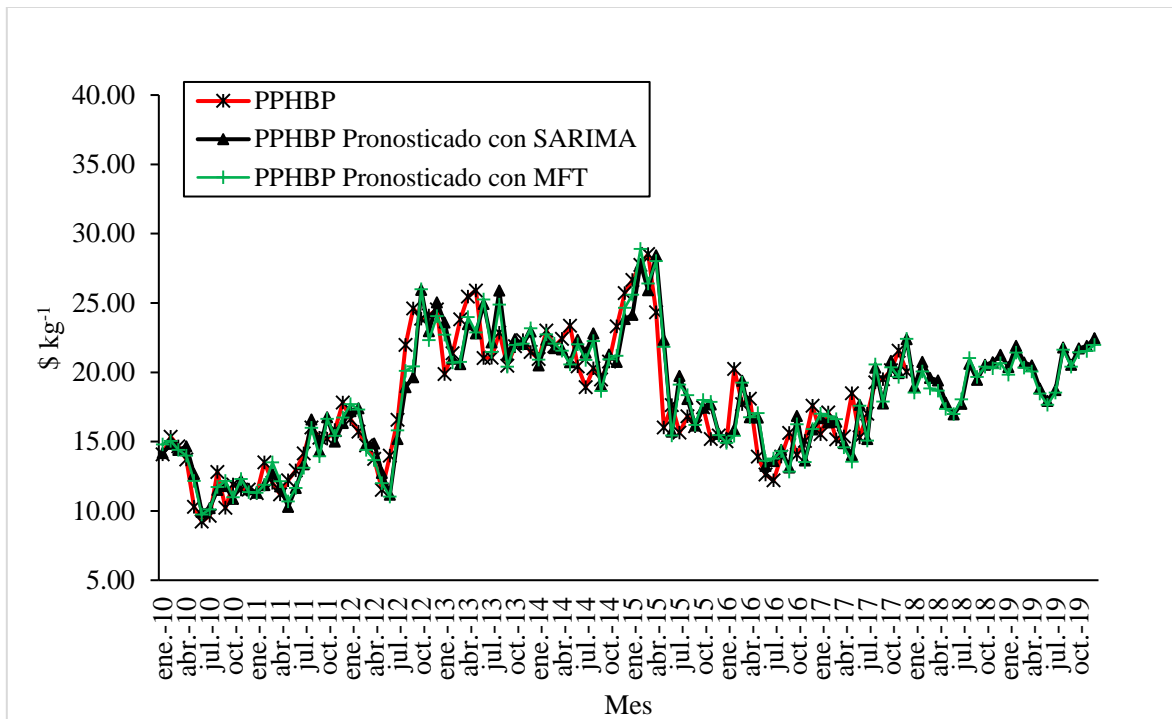


Figura 2.5. Precio nominal y pronosticado del huevo blanco pagados al productor en México.

Con los modelos SARIMA y MFT se pronosticaron los PPHBP para los meses del año 2017 y se compararon estos precios con los de la serie PPHBP. Se obtuvieron buenas predicciones con un error porcentual absoluto medio (MAPE) de 8.46 % para el primer modelo y 8.13 % para el segundo. Esto indica que el MFT es mejor para predecir los PPHBP. Sin embargo, Wheelwright y Maridakis (1989) plantean que no se debe basar el pronóstico únicamente en este indicador, también se debe examinar la prueba de Chi cuadrada para conocer si la serie presenta residuales que se comportan como ruido blanco. Estos modelos predicen valores de PPHBP muy próximos a los observados, porque estos se ubican dentro de la banda de confianza estimada al ± 95 % (Cuadro 2.3).

Cuadro 2.3. Precios nominales observados y pronosticados de huevo blanco pagados al productor en México, 2017 (\$ kg⁻¹), obtenidos a través del modelo SARIMA y MFT.

Año 2017	Meses												MAPE
	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	(%)
PPHBP	15.54	17.10	15.16	15.38	18.48	15.30	17.01	19.28	19.50	20.16	21.55	20.03	
Pronóstico con SARIMA	16.69	16.39	16.43	14.88	14.04	17.67	15.19	20.33	17.75	20.82	19.93	22.39	8.46
Pronóstico con MFT	17.02	16.82	16.61	14.59	13.54	17.58	15.07	20.56	17.89	20.36	19.66	22.41	8.13

Los efectos del PPSRG sobre los PPHBP indican que la ganancia (efecto marginal del PPHBP respecto a las variaciones del PPSRG) fue de 0.21, es decir, cuando el precio del sorgo (*PPSRG*) se incrementa en un peso; el precio promedio (\$13.12 kg) del huevo blanco al productor en México (PPHBP) aumenta en \$0.21 ± 0.099 pesos, 30 días después de incremento del primero.

Se pronosticaron con relativa precisión los PPHBP utilizando los MFT, mejorando levemente los resultados del pronóstico, respecto a la estimación de modelos de series temporales univariados de tipo SARIMA. Sin embargo Chu (1978), plantea que estas estimaciones pueden no ser creíbles para predecir los precios en el mediano y largo plazo, por lo que es preciso señalar, que no obstante, el principal inconveniente que presenta este tipo de modelos, radica en su propio fundamento, ya que al estar basados en hechos pasados y aprender de la propia historia para realizar las predicciones, estas serán acertadas en la medida en que los factores que determinan la evolución sigan actuando del mismo modo y no sean alterados de forma notoria.

CONCLUSIONES E IMPLICACIONES

La estimación de modelos de series temporales bivariados de tipo MFT y ruido para los precios promedios de huevo blanco pagados al productor, permite lograr un buen ajuste en el pronóstico de corto plazo y mediano plazo, mejorando los resultados del pronóstico, respecto a la estimación de modelos de series temporales univariados de tipo SARIMA.

Se demostró que las predicciones de la serie estudiada en el corto plazo difieren en 8.46 % de los datos observados mediante el modelo SARIMA y 8.13% mediante el MFT, minimizándose el error aleatorio para ambos casos, además toma un mes para que la variable PPSRG afecte a la variable PPHBP. Los PPHBP estimados proporcionan información útil para planificar y tomar decisiones en el sector avícola productor de huevo para plato en el corto plazo.

LITERATURA CITADA

- Box, G. E. and G.M. Jenkins. 1976: Time Series Analysis: Forecasting and Control. Revised Ed., Holden-day, San Francisco. 575 p.
- Box, G. E. P., G. M. Jenkins., and G.C. Reinsel. 1994: Time Series Analysis: Forecasting and Control. 3rd ed. Ed. Prentice Hall. Englewood Cliffs, NJ.
- Brockwell, P. J. (2004). Representations of continuous-time ARMA processes. Journal of Applied Probability. Vol. 41^a. pp: 375-382.
- CEDRSSA. Centro de Estudios para el Desarrollo Rural Sustentable y la Soberanía Alimentaria. 2014.Evolución de los precios del maíz, frijol y sorgo. <http://www.cedrssa.gob.mx/?doc=2643>
- Chiogna M, Gaetan C, Masarotto G. Automatic identification of seasonal transfer function models by means of iterative stepwise and genetic algorithms. J Time Ser Anal. 2007;(29)1: 37–50.
- Chu, K.Y. 1978. Short-run forecasting of commodity prices: An application of autoregressive moving average models. IMF Staff Papers. Volume 25 No 1. pp: 90-111.
- Cox, D. R. and G. E. Box. 1964. An analysis of transformations. Journal of the Royal Statistical Society. Serie B. Vol 26. p 211-252.

- Cruz J., S., R. García M., J. S. Mora F., y R.C. García S. 2016. El mercado de huevo para plato en México, 1960 – 2012. *Agricultura Sociedad y Desarrollo*. Vol. 13 No. 3: p 385 - 399.
- Espinosa R. M. 2016. El mercado de la carne de pollo y su relación con los granos forrajeros en México, 1980 -2013 [tesis doctorado]. Montecillo, Texcoco, Edo de México: Colegio de Postgraduados.
- García M., R., J. A. García S., y R. C. García S. 2003. Teoría del Mercado de Productos Agrícolas. Instituto de Socioeconomía, Estadística e Informática, Programa de Postgrado en Economía. Colegio de Postgraduados. Montecillo, Texcoco Edo de México. 382 p.
- Granger C. W. J. 1969. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*. Vol. 37. No 3. pp:424 – 438.
- Hilmer, S.C., and A. C. Tiao. 1979. Likelihood Function of stationary Multiple Autorregresive Moving Average Models. *Journal of the American Statistical Association* 74. pp: 652 – 660.
- Jarque, C.M. y A.K. Bera. 1987. A test for Normality of observations and regression residuals. *International Statistical Review*. Vol. 55. No 2. pp:163-172.
- Ortega, S. de T. J. 2014. Plan Rector Visión 2014 – 2024. “Sistema producto huevo para plato”. Imagen Editorial Yire. Cd. de México. 110 p
- Ramírez, G.M.E. 1993. SAS macro for analyzing step and impulse response functions derived from transfer function models. http://www.sascommunity.org/wiki/SAS_Global_Forum_Proceedings/SUGI_93 : p 990 – 995.
- SAS. 2014. The SAS (Statistical Analysis System) System for Windows V. 9.4. Sas Institute Inc. Cary, NC. USA.
- UNA (Unión Nacional de Avicultores). Compendio de Indicadores económicos del sector avícola. México, 2016, 2017 y 2018.
- Wheelwright, S. C. and S. Maridakis. 1989. *Forecasting Methods for Management*. 5th Ed. New York: John Wiley & Sons.
- Yafee, R. A., and M. McGee. 1999. *Introduction to time Series Analysis and forecasting*. Ed., Academic Press, Inc. Brooklyn, New York. pp: 83 – 89.

CONCLUSIONES Y RECOMENDACIONES GENERALES

CONCLUSION GENERAL

Es posible modelar los PPHBP en México utilizando la metodología propuesta por Box y Jenkins, dado que el comportamiento de esta serie no es completamente aleatorio y presenta un componente estacional de 12 meses repitiéndose el mismo patrón de manera periódica y puede ser modelado por un procedimiento SARIMA $(0, 1, 1) \times (1, 0, 1)_{s=12}$, sin embargo, al incluir la serie (PPSRG) como variable independiente al MFT, los pronósticos de los PPHBP para el corto plazo se mejoran respecto a la estimación de modelos de series temporales univariados de tipo SARIMA logrando reducir la varianza en 5.69 % respecto al modelo de la primer metodología, debido a que el modelo bivariado de MFT toma en cuenta la evolución temporal del PPSRG. Se demostró que las predicciones de la serie estudiada en el corto plazo difieren en 8.46 % de los datos observados mediante el modelo SARIMA y 8.13% mediante el MFT, minimizándose el error aleatorio para ambos casos, además toma un mes para que la variable PPSRG afecte a la variable PPHBP.

La metodología Box Jenkins, presenta ventajas para proyectar los PPHBP en el corto y mediano plazo, toda vez que parte de situaciones dinámicas al explicar el futuro en función del pasado, mientras que el modelo de regresión clásico supone relaciones instantáneas y estáticas.

RECOMENDACIONES GENERALES

La presente investigación demostró que los PPHBP pueden ser modelados utilizando la metodología Box – Jenkins obteniendo pronósticos estadísticamente apropiados y significativos aun cuando la serie estudiada presenta variabilidad alta, por lo que se propone a los actores que conforman el sector avícola productor de huevo para plato en México, apoyarse del modelo SARIMA $(0, 1, 1) \times (1, 0, 1)_{s=12}$ y/o el MFT $(1,0,2)$ toda vez que dichos modelos parten de metodologías estadísticas rigurosas y proporcionan elementos sólidos de apoyo para diagnosticar, sugerir, encausar las políticas de análisis de precios del sector avícola productor de huevo para plato en el corto plazo.

Asimismo, se sugiere a los tomadores de decisiones que es importante realizar estimaciones que incluyan mucho más variables de impacto para fortalecer los modelos de función de transferencia, puesto que de no ser así los pronósticos pueden no ser creíbles para predecir los precios en el mediano y largo plazo, ya que al estar basados en hechos pasados y aprender de la propia historia para realizar las predicciones, estas serán acertadas en la medida en que los factores que determinan la evolución sigan actuando del mismo modo y no sean alterados de forma notoria, de ahí la importancia de utilizarlos como herramienta de apoyo para ayudar a formar su propios criterios.

ANEXOS

PROGRAMACIÓN SAS PARA EL MODELO SARIMA DE HUEVO

```
/* Serie mensual de los precios del Precio promedio de huevo blanco pagado
al productor. ($/kg) (2000-2016)*/
title1 'Análisis de los Precios promedios de huevo blanco pagados al
productor en México. ($/kg)';
title2 'periodo (2000-2018), utilizando la metodología Box - Jenkins';
data huevol;
input
PPHBP;
LPPHBP=LOG(PPHBP);
date = intnx('MONTH', '31dec1999'd, _n_);
format date monyy.;
cards;
5.99
6.32
5.61
6.58
6.78
5.68
5.58
7.15
7.35
8.7
8.21
8.62
7.8
7.52
7.3
8.13
7.69
6.08
6.32
7.85
7.1
7.1
7
7.65
6.76
6.5
5.9
5.99
4.84
5.56
6.6
7.91
*
*
*
*
*
*
Y DEMAS DATOS
```

```

16.1
17.48
15.18
15.45
15.02
20.25
17.71
18.10
13.91
12.62
12.22
13.92
15.63
14.05
15.04
17.60
;

* 1. Impresión de datos;
proc print;
run;

symbol1 c=red i=join v=circle h=0.8;
symbol2 c=blue i=join v=circle h=0.8;

* 2. Cálculo de estadísticas descriptivas;
proc means;
var PPHBP;
run;

/*2.1 Grafica de la serie de datos con PROC TIME SERIES*/
PROC TIMESERIES DATA=HUEVO1 PLOT=SERIES;
ID DATE INTERVAL=MONTH;
VAR PPHBP;
RUN;

PROC Gplot DATA=HUEVO1;
PLOT PPHBP*DATE=1;
RUN;

SYMBOL1 I=JOIN V=DIAMOND C=BLUE;
SYMBOL2 I=JOIN V=DIAMOND C=RED;
RUN;

/* 3. Se realiza la prueba de DFA para saber si la serie es estacionaria
en Media y varianza*/
PROC ARIMA;
IDENTIFY VAR=PPHBP NLAG=30
STATIONARITY=(ADF) ;
RUN;

/*4. Prueba de box cox para verificar si se requiere alguna
transformacion*/
proc transreg DATA=HUEVO1;
MODEL boxcox (PPHBP)=identity (date);
run;
ods rtf close;

```

```

/*5. Se realiza la prueba de DFA para saber si la serie es estacionaria en
varianza*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP NLAG=30
STATIONARITY=(ADF);
RUN;

/*6. Como la serie ya es estacionaria en varianza, se realiza la primera
diferencia para volver la serie estacionaria en Media*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30
STATIONARITY=(ADF);
RUN;

/*7. Como se observó que la serie presenta estacionalidad, se le aplica una
diferencia a la parte Estacional*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1,12) NLAG=36
STATIONARITY=(ADF);
RUN;

/*8. Se comienza a modelar para buscar los mejores parámetros
significativos y con los criterios mínimos*/
/*MODELO 1 ARIMA(0,1,0)X(0,1,0)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1,12) NLAG=30; /**/
ESTIMATE P=(0)Q=(0) method=ml NOINT;
run;

/*MODELO 2 ARIMA(0,1,0)X(0,1,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1,12) NLAG=30; /**/
ESTIMATE P=(0)(0) Q=(0)(12) method=ml NOINT;
run;

/*MODELO 3 ARIMA(0,1,0)X(1,1,0)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1,12) NLAG=30;
ESTIMATE P=(0)(12) Q=(0)(0) method=ml NOINT;
run;

/*MODELO 4 ARIMA(0,1,0)X(1,0,0)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30;
ESTIMATE P=(0)(12) Q=(0)(0) method=ml NOINT;
run;

/*MODELO 5 ARIMA(0,1,0)X(0,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30;
ESTIMATE P=(0)(0) Q=(0)(12) method=ml NOINT;
run;

/*MODELO 6 ARIMA(0,1,0)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30;

```

```

ESTIMATE P=(0) (12) Q=(0) (12) method=ml NOINT;
run;

/*MODELO 7 ARIMA(0,1,0)X(1,1,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1,12) NLAG=30;
ESTIMATE P=(0) (12) Q=(0) (12) method=ml NOINT;
run;

/*MODELO 8 ARIMA(0,1,1)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30;
ESTIMATE P=(0) (12) Q=(2) (12) method=ml NOINT;
run;

/*MODELO 9 ARIMA(1,1,0)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30;
ESTIMATE P=(5) (12) Q=(0) (12) method=ml NOINT;
run;

/*MODELO 10 ARIMA(1,0,0)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP NLAG=30;
ESTIMATE P=(5) (12) Q=(0) (12) method=ml NOINT;
run;

/*MODELO 11 ARIMA(0,0,1)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP NLAG=30;
ESTIMATE P=(0) (12) Q=(5) (12) method=ml NOINT;
run;

/*MODELO 12 ARIMA(1,0,1)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP NLAG=30;
ESTIMATE P=(5) (12) Q=(5) (12) method=ml NOINT;
run;

/*MODELO 13 ARIMA(1,1,1)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30; /**/
ESTIMATE P=(3) (12) Q=(3) (12) method=ml NOINT;
run;

/*MODELO 14 ARIMA(2,1,1)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30; /**/
ESTIMATE P=(4,11) (0) Q=(3) (12) method=ml NOINT;
run;

/*MODELO 15 ARIMA(1,1,2)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30; /**/
ESTIMATE P=(4) (12) Q=(2,4) (12) method=ml NOINT;
run;

```

```

/*MODELO 16 ARIMA(2,1,2)X(1,0,1)s=12*/
PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30; /**/
ESTIMATE P=(2,4)(12) Q=(2,4)(12) method=ml NOINT;
run;

/* 9. -----EL MEJOR MODELO -----*/
/*EL MEJOR MODELO FUE EL MODELO 08 ARIMA(0,1,1)X(1,0,1)s=12*/

PROC ARIMA;
IDENTIFY VAR=LPPHBP(1) NLAG=30; /**/
ESTIMATE P=(0)(12) Q=(2)(12) method=ml NOINT;
FORECAST LEAD=24 OUT=OUT2 ID=date INTERVAL=MONTH;

/*10. Se gráfica la serie normal vs la serie pronosticada*/
PROC GPLOT DATA=OUT2;
PLOT LPPHBP*date=1 FORECAST*date=2/overlay haxis='31jan2000'd to
'30nov2018'd
by year;
run;

/*11. Se realiza la prueba de Ruido Blanco a los residuales del mejor
modelo mediante la prueba Dickey Fuller*/
PROC ARIMA data=out2;
IDENTIFY VAR=residual NLAG=30;
RUN;

/*12. Se imprimen los residuales del mejor modelo*/
PROC PRINT
DATA=OUT2;
RUN;

PROC GPLOT DATA=OUT2;
PLOT LPPHBP*date=1 FORECAST*date=2/overlay haxis='31jan2000'd to
'30nov2018'd
by YEAR;
run;

PROC ARIMA data=out2;
IDENTIFY VAR=residual NLAG=30;
RUN;

PROC PRINT
DATA=OUT2;
RUN;

```


PROGRAMACION SAS PARA EL MODELO DE ANALISIS DE TRANSFENCIA PARA EL HUEVO EN FUNCION DEL PRECIO DEL SORGO

```

/* Serie mensual de los precios del Precio promedio de pollo en pie en el
D.F. ($/kg) (2000-2016)*/
title1 'El Precio promedio del huevo blanco pagado al productor en México y
su Relación con el precios de los insumos (Sorgo, maiz amarillo y pasta de
soya)';
title2 '(2000-2016)';
data seriesam;
input
PPHBP PPPSG PPPSY PPMAM;
LPPHBP=LOG(PPHBP);
LPPPSG=LOG(PPPSG);
LPPPSY=LOG(PPPSY);
LPPMAM=LOG(PPMAM);
cards;
5.99 1.13 2.38 1.35
6.32 1.22 2.42 1.45
5.61 1.20 2.18 1.39
6.58 1.19 2.30 1.45
6.78 1.18 2.18 1.50
5.68 1.22 2.46 1.49
5.58 1.12 2.33 1.45
7.15 1.08 2.23 1.32
7.35 1.13 2.23 1.38
8.70 1.13 2.37 1.44
8.21 1.16 2.48 1.45
8.62 1.16 2.48 1.43
7.80 1.39 2.62 1.48
7.52 1.31 2.45 1.42
7.30 1.31 2.30 1.38
8.13 1.27 2.24 1.41
7.69 1.21 2.47 1.42
6.08 1.18 2.36 1.37
6.32 1.22 2.35 1.40
7.85 1.25 2.25 1.36
7.10 1.29 2.29 1.50
7.10 1.32 2.45 1.29
7.00 1.36 2.55 1.33
7.65 1.22 2.14 1.35
6.76 1.18 2.07 1.73
6.50 1.28 2.45 1.78
5.90 1.19 2.09 1.57
5.99 1.19 2.22 1.32
4.84 1.21 2.45 1.34
5.56 1.28 2.45 1.54
6.60 1.29 2.58 1.38
*
*
*
*
*
Y DEMAS DATOS

```

18.48	4.06	8.80	4.03
15.30	3.80	7.20	4.00
17.01	3.72	6.91	3.96
19.28	3.69	7.25	3.87
19.50	3.22	6.87	3.85
20.16	3.35	7.60	3.88
21.55	3.75	8.10	3.88
20.03	3.20	7.18	3.30

```

;
* 1. Asignacion de fecha;
data seriesam; set seriesam;
fecha = intnx( 'month', '31dec1999'd, _n_ );
format fecha monyy.;

* 2. Impresión de datos;
proc print; run;

* 3. Calculo de estadísticas descriptivas;
proc means; var PPHBP PPPSG PPPSY PPMAM;
run;
proc corr; var PPHBP PPPSG PPPSY PPMAM;
run;

* 4. Gráfica de datos con Proc timeseries, proc sgplot y proc gplot;
title1 "Grafica de datos";
proc timeseries data=seriesam plot=series;
  id fecha interval= month;
  var PPHBP;
run;

title1 "Series";
proc sgplot data=seriesam;
  where date >= '1jan00'd;
  band Upper=u95 Lower=l95 x=date
  / LegendLabel="Límites del 95% de confianza";
  series x=fecha y=PPHBP;
run;

proc sgplot data=seriesam;
  where date >= '1jan00'd;
  band Upper=u95 Lower=l95 x=date
  / LegendLabel="Límites del 95% de confianza";
  series x=fecha y=PPPSG;
run;

proc sgplot data=seriesam;
  where date >= '1jan00'd;
  band Upper=u95 Lower=l95 x=date
  / LegendLabel="Límites del 95% de confianza";
  series x=fecha y=PPPSY;
run;

proc sgplot data=seriesam;
  where date >= '1jan00'd;
  band Upper=u95 Lower=l95 x=date
  / LegendLabel="Límites del 95% de confianza";

```

```

series x=fecha y=PPMAM;
run;

* Gráfica individuales;
PROC GPLOT DATA= seriesam;
PLOT PPHBP*fecha= 1 ;
PLOT PPPSG*fecha= 2 ;
PLOT PPPSY*fecha= 3 ;
PLOT PPMAM*fecha= 4 ;
RUN;
SYMBOL1 I= JOIN V= DIAMOND C=RED ;
SYMBOL2 I= NEEDLE V= DIAMOND C=GREEN ;
SYMBOL3 I= NEEDLE V= DIAMOND C=BLUE ;
SYMBOL4 I= NEEDLE V= DIAMOND C=BLACK ;
run;

* Gráfica de precio del Precio del huevo vs Precio del sorgo ;
PROC GPLOT DATA= seriesam ;
PLOT PPHBP*fecha= 1;
PLOT2 PPPSG*fecha= 2 /overlay;
run;
SYMBOL1 I= JOIN V= DIAMOND C=RED ;
SYMBOL2 I= NEEDLE V= DIAMOND C=GREEN ;
RUN;

* Gráfica de precio del Precio del huevo vs Precio de la Pasta de soya;
PROC GPLOT DATA= seriesam ;
PLOT PPHBP*fecha= 1;
PLOT2 PPPSY*fecha= 2 /overlay;
run;
SYMBOL1 I= JOIN V= DIAMOND C=RED ;
SYMBOL3 I= NEEDLE V= DIAMOND C=BLUE ;
RUN;

* Gráfica de precio del Precio del huevo vs Precio del Maíz amarillo;
PROC GPLOT DATA= seriesam ;
PLOT PPHBP*fecha= 1;
PLOT2 PPMAM*fecha= 2 /overlay;
run;
SYMBOL1 I= JOIN V= DIAMOND C=RED ;
SYMBOL4 I= NEEDLE V= DIAMOND C=BLACK ;
RUN;

/*****ANÁLISIS DE TRANSFERENCIA*****/
/*Ahora se identificará si un modelo de TRANSFERENCIA puede ayudar a
explicar los cambios detectados del PPHBP
con las variables de intervención*/

* 8.1 Identificación, ajuste y gráfica del modelo para el Precio del sorgo
(PPPSG);

/*MODELO 3 ARIMA(2,1,0)*/
PROC ARIMA DATA=seriesam;
IDENTIFY VAR=LPPPSG(1) NLAG=30;
ESTIMATE P=(5,8) Q=(0);

```

```
ESTIMATE P=(5,8) Q=(0)method=ml NOINT OUTSTAT=resLPPPSG; * Mejor modelo: (1
- 0.15988 B**(3) - 0.55865 B**(14))= (1 - 0.09603 B**(1) - 0.7317 B**(14))
at
con sigma2=0.003687; * SBC= -542.14;
FORECAST ID= fecha OUT=fLPPPSG LEAD=0;
run;
```

```
PROC PRINT DATA=fLPPPSG;
RUN;
PROC GPLOT;
PLOT (LPPPSG FORECAST)*fecha/OVERLAY;
RUN;
```

```
data fLPPPSG;
set fLPPPSG;
rename residual=rLPPPSG;
proc print data=fLPPPSG;
run;
```

```
PROC ARIMA data=seriesam;
IDENTIFY VAR=LPPHBP(1) NLAG=30;
ESTIMATE P=(0)(12) Q=(2)(12) method=ml NOINT; * SBC= -322.599;
run;
```

*8.2 Prewhiten de la variable Precio del hueblo blanco pagado al productor LPPHBP;

```
PROC ARIMA data=seriesam;
IDENTIFY VAR=LPPHBP(1) NLAG=30;
ESTIMATE P=(0)(12) Q=(2)(12) method=ml NOINT; * SBC= -322.599;
FORECAST ID=FECHA OUT=fLPPHBP lead=12;
run;
```

```
proc print data=fLPPHBP;
run;
proc gplot; plot (LPPHBP FORECAST)*fecha/overlay; run;
```

```
data fLPPHBP; set fLPPHBP; rename residual=rLPPHBP;
proc print data=fLPPHBP; run;
```

```
*8.3 Impresión de residuales;
data juntos; merge fLPPPSG fLPPHBP; keep rLPPPSG rLPPHBP;
proc print data=juntos; run;
```

* 9. Para encontrar la asociación entre precio del SORGO y el precio del huevo blanco pagado al productor

Se calcula la función de autocorrelación entre:
la variable "blanqueada" X_t : Precio del Sorgo y
la variable "blanqueada" Y_t : Precio del huevo blanco pagado al productor

Para lograr esto se calcula: $\alpha_t = (1 - \beta X_t) X_t$ y

$\beta_t = (1 - \beta) / (1 - \beta Y_t) Y_t$;

```
proc arima data=juntos;
identify var=rLPPHBP crosscorr=(rLPPPSG) ;
run;
```

```

* 10. Posibles modelos para estimar el efecto del precio del sorgo sobre el
precio del huevo blanco pagado al productor;
* 10.1 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/ (0,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.101785 AIC -347.366 SBC -330.536
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.2 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/ (1,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12); *
Error Std Estimación 0.101785 AIC -347.366 SBC -330.536 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.3 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/ (1,2) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12); *
Error Std Estimación 0.099277 AIC -357.279 SBC -337.111 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.4 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/ (1,3) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12); *
Error Std Estimación 0.09885 AIC -356.246 SBC -336.106 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.5 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/ (1,0) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12); *
Error Std Estimación 0.101785 AIC -347.366b SBC -330.536 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.6 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/ (2,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12); *
Error Std Estimación 0.099277 AIC -357.279 SBC -337.111 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.7 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\delta(B)=(1-\delta_1B-\delta_2B^{**2})$ ;

```

```

proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(/(3,1) LPPPSG ) plot method=ML noint P=(0)(12) Q=(2)(12); *
Error Std Estimación 0.09885 AIC -356.246 SBC -336.106 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.8 Aquí identificamos que b=1, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(1$(1,2) LPPPSG ) plot method=ML noint P=(0)(12) Q=(2)(12);
* Error Std Estimación 0.099291 AIC -353.664 SBC -333.524 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.9 Aquí identificamos que b=1, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(1$(1) LPPPSG ) plot method=ML noint P=(0)(12) Q=(2)(12); *
Error Std Estimación 0.10203 AIC -344.6 SBC -327.794 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.10 Aquí identificamos que b=1, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(1$(1,3) LPPPSG ) plot method=ML noint P=(0)(12) Q=(2)(12);
* Error Std Estimación 0.098931 AIC -352.951 SBC -332.839 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.11 Aquí identificamos que b=1, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(1$(2,1) LPPPSG ) plot method=ML noint P=(0)(12) Q=(2)(12);
* Error Std Estimación 0.099291 AIC -353.664 SBC -333.524 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.12 Aquí identificamos que b=1, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(1$(3,1) LPPPSG ) plot method=ML noint P=(0)(12) Q=(2)(12);
* Error Std Estimación 0.098931 AIC -352.951 SBC -332.839 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.12 Aquí identificamos que b=1, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;

```

```

estimate input=(1$(1)/(3,1) LPPPSG ) plot method=ML noint P=(0) (12)
Q=(2) (12); * Error Std Estimación 0.099187 AIC -351.008 SBC -327.545 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(1$(1)/(2) LPPPSG ) plot method=ML noint P=(0) (12)
Q=(2) (12); * Error Std Estimación 0.101282 AIC -343.385 SBC -323.246 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.13 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(0,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.101543 AIC -342.507 SBC -325.725 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.14 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(1,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.101543 AIC -342.507 SBC -325.725 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.14 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2$(1,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.101543 AIC -342.507 SBC -325.725 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.15 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(1,2) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.099424 AIC -351.227 SBC -331.116 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.16 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(1,3) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.097063 AIC -349.392 SBC -329.31 *
Todos los parámetros son significativos;

```

```

forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.17 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(1,0) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.101543 AIC -342.507 SBC -325.725 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.18 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(2,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.099424 AIC -351.227 SBC -331.116*
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.19 Aquí identificamos que b=2, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(2/(3,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.097063 AIC -349.392 SBC -329.31 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.20 Aquí identificamos que b=3, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(3/(1,2) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.100541 AIC -345.68 SBC -325.597*
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.21 Aquí identificamos que b=0, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(3/(1,3) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.101021 AIC -343.018 SBC -322.964 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.22 Aquí identificamos que b=0, w=wo, delta(B)=(1-delta1B-delta2B**2);
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(3/(1,0) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
* Error Std Estimación 0.101687 AIC -340.676 SBC -323.916 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

```



```

* 10.23 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\Delta(B)=(1-\Delta_1B-\Delta_2B^2)$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(3/(2,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.100541 AIC -345.68 SBC -325.597*
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.24 Aquí identificamos que  $b=0$ ,  $w=w_0$ ,  $\Delta(B)=(1-\Delta_1B-\Delta_2B^2)$ ;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(3/(3,1) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
*Error Std Estimación 0.101021 AIC -343.018 SBC -322.964 *
Todos los parámetros son significativos;
forecast id=fecha out=LPPHBP_LPPPSG1 lead=0;
run;

* 10.3 EL MEJOR MODELO DE FUNCION DE TRANSFERENCIA CON UN SOLO INPUT  $Y_t=$ 
PPHBP  $X_t=$ PPPSG);
*ESTE ES EL MEJOR MODELO*;
proc arima data=seriesam;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1)) noprint center;
estimate input=(0$/(1,2) LPPPSG ) plot method=ML noint P=(0) (12) Q=(2) (12);
/* Error Std Estimación 0.099277 AIC -357.279 SBC -337.111 *
Todos los parámetros son significativos*/
forecast id=fecha out=LPPHBP_LPPPSG3 lead=0;
run;

proc print data=LPPHBP_LPPPSG3;
run;

/* Gráfica de datos originales de una manera más sencilla */
symbol1 i=join c=blue;
symbol2 i=join c=black;
symbol3 i=join c=red;
symbol4 i=join c=red;
proc gplot data=LPPHBP_LPPPSG3;
plot (forecast LPPHBP u95 195)*fecha/overlay;
run;

proc arima data=seriesam;
identify var=LPPPSG(1) noprint;
estimate P=(5,8)Q=(0)noconstant;
identify var=LPPHBP(1)crosscorr=(LPPPSG(1))nlag=30;
estimate P=(0) (12) Q=(2) (12) input=(1$ (2)/(1,2)LPPPSG)
noconstant printall
altparm maxit=30 backlim = -3 plot;
forecast lead= 12;
run;

proc arima data=seriesam;
identify var=LPPPSG(1) noprint center;
estimate P=(5,8)Q=(0)noconstant;
identify var=LPPHBP(1)crosscorr=(LPPPSG(1))nlag=30;
estimate P=(0) (12) Q=(2) (12) input=(0$/(1,2)LPPPSG)

```

```

noconstant printall
plot method=ML noint;
forecast id=fecha out=LPPHBP_LPPPSG4 lead= 12;
run;

proc print data=LPPHBP_LPPPSG4;
run;

/* Gráfica de datos originales de una manera más sencilla */
symbol1 i=join c=blue;
symbol2 i=join c=black;
symbol3 i=join c=red;
symbol4 i=join c=red;
proc gplot data=LPPHBP_LPPPSG4;
  plot (forecast LPPHBP u95 195)*fecha/overlay;
run;

* 10.3 EL MEJOR MODELO DE FUNCION DE TRANSFERENCIA CON UN SOLO INPUT  $Y_t =$ 
PPHBP  $X_t =$ PPPSG);
*ESTE ES EL MEJOR MODELO*;

proc arima data=seriesam;
identify var=LPPPSG(1) noprint center;
estimate P=(5,8)Q=(0)noint;
identify var=LPPHBP(1) crosscorr=(LPPPSG(1))nlag=30;
estimate P=(0)(12) Q=(2)(12) input=(1$/ (1,3) LPPPSG)
noconstant printall
plot method=ML noint;
forecast id=fecha out=LPPHBP_LPPPSG5 lead= 24;
run;

proc print data=LPPHBP_LPPPSG5;
run;

/* Gráfica de datos originales de una manera más sencilla */
symbol1 i=join c=blue;
symbol2 i=join c=black;
symbol3 i=join c=red;
symbol4 i=join c=red;
proc gplot data=LPPHBP_LPPPSG5;
  plot (forecast LPPHBP u95 195)*fecha/overlay;
run;

```