

MODELO DE FUNCIÓN DE TRANSFERENCIA PARA PRONOSTICAR EL PRECIO DEL HUEVO BLANCO, 2000 – 2017

Samuel Luis-Rojas¹, Roberto C. García-Sánchez¹, Roberto García-Mata¹, Oscar A. Arana-Coronado¹, Adrián González-Estrada²

¹Posgrado de Economía. Colegio de Postgraduados. Campus Montecillo. Carretera México – Texcoco km 36.5. Montecillo, Texcoco, Estado de México. 56230.

²Programa Nacional de Economía, INIFAP. Apartado Postal #10. Campo Experimental Valle de México. Carr. Los Reyes – Texcoco. Km 13.5 Coatlinchan. Texcoco. Edo de México. 56250.

*Autor para correspondencia: rcgarcia@colpos.mx

RESUMEN

El huevo es una de las fuentes de proteína más accesible y con disponibilidad amplia en el mercado. El objetivo de este trabajo fue desarrollar un modelo en series de tiempo para pronosticar los precios nominales mensuales de huevo blanco pagados al productor en México (PPHBP) mediante modelos de función de transferencia (MFT) y evaluar su relación con los precios promedios rurales del sorgo (PPSRG). Los parámetros y las predicciones se estimaron con el método de máxima verosimilitud y fueron estadísticamente apropiadas y significativas. El mejor MFT que representó el comportamiento de los PPHBP fue el de 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 un mes después en los PPHBP, disminuyendo la varianza original del PPHBP de 0.01036 a 0.009771 con el modelo de transferencia. El MFT 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, útiles para planificar y tomar decisiones en el sector avícola a corto y mediano plazo.

Palabras clave: avicultura, Box Jenkins, huevo, predicción, SARIMA, sorgo.

INTRODUCCIÓN

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 2018, la participación porcentual de la avicultura en el Producto Interno Bruto (PIB) total fue de 0.89%. En el PIB pecuario participó con 36.6 por ciento (UNA, 2018). El consumo per cápita promedio del huevo en el año 2018 fue de 23 kg; mientras que la producción fue menor que el consumo (2,806,000 t), por lo que para cubrir la demanda se importó 0.92 % del total (UNA, 2018); así como, entre el 1994 y 2018 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 2018 aportaron 75 % de la producción nacional (UNA, 2018). 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 2018, se consumieron 16.2 millones de toneladas de alimento balanceado de los cuales el 63% fue grano forrajero, como el maíz (*Zea mays* L) y sorgo (*Sorghum vulgare*), equivalente a 10.2 millones de toneladas; mientras que, en el mismo año, la avicultura productora de huevo generó 213,000 mil empleos directos y 1,064,000 empleos indirectos (UNA, 2018).

Citation: Luis-Rojas S, García-Sánchez RC, García-Mata R, Arana-Coronado OA, González-Estrada A. 2022. Modelo de función de transferencia para pronosticar el precio del huevo blanco, 2000 – 2017. Agricultura, Sociedad y Desarrollo <https://doi.org/10.22231/asyd.v19i2.1263>

Editor in Chief:
Dr. Benito Ramírez Valverde

Received: November 13, 2019.
Approved: April 16, 2021.

Estimated publication date:
October 14, 2022.

This work is licensed under a Creative Commons Attribution-Non-Commercial 4.0 International license.



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 (*Zea mays* L) y la soya (*Glycine max*). 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.

Luis *et al.* (2019) utilizó una serie temporal univariada de precios mensuales de huevo blanco pagado al productor desde los años 2000 a 2016, y mediante la metodología Box Jenkins demostró que la serie se comporta como un modelo estacional SARIMA (*Seasonal Autorregresive Integrate Movil AVERAGE*) de coeficientes $(0,1,1)X(1,0,1)_{s=12}$ y con los resultados del modelo pudieron realizar estimaciones respecto al precio pagado al productor, hasta diciembre de 2019, sin embargo; en su estudio solo contempló los precios de la variable precios promedios de huevo blanco pagados al productor (PPHBP) y no evaluó el impacto que ejerce el sorgo (*Sorghum vulgare*) en el precio del huevo.

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 dependiente alto 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 MÉTODOS

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:

$$\begin{aligned} Y_t &= v_0 X_t + v_1 X_{t-1} + v_2 X_{t-2} + \dots + N_t \\ Y_t &= (v_0 + v_1 B + v_2 B^2 + \dots) X_t + N_t \\ Y_t &= v(B) X_t + \dots N_t \end{aligned} \tag{1}$$

donde $X_t, X_{t-1}, X_{t-2}, \dots, X_{t-n}$ son los valores presentes y pasados de la serie de entrada; $v(B) = v_0 + v_1 B + v_2 B^2 + \dots + v_n B^n$ es la función de transferencia del filtro de Chiogna (2007); $N(t)$ 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:

$$\sum_{j=0}^{\infty} v_j = g \tag{2}$$

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 las series de *entrada* y *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 se representan por ruido N_t que no son captados por la serie X_t .

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

$$Y_t = v(B) X_t + N_t \tag{3}$$

El modelo (3) se conoce como el modelo de retraso distribuido y es inestimable, debido a que en este aparece un número infinito de parámetros. El 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) finitos, obteniéndose:

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

donde $\omega(B)=\omega_0-\omega_1B-\dots-\omega_sB^s$, 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 $\delta(B)=1-\delta_1B-\dots-\delta_rB^r$ es un polinomio de grado r , indica el tipo de duraciones del impacto transferido desde la entrada a la salida (por ejemplo, temporal o permanente) así pues, b es un parámetro de retardo, que representa el tiempo que transcurre antes de que 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 $\theta(B)=(1-\theta_1B-\theta_2B^2-\dots-\theta_qB^q)$ y $\phi(B)=(1-\phi_1B-\phi_2B^2-\dots-\phi_pB^p)$, 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 (término 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 se supone es una variable aleatoria independientemente distribuida de forma idéntica, muestreada 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 \$MXN kg⁻¹ (UNA, 2018). 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 Secretaría de Economía expresados en \$MXN kg⁻¹, para el mismo periodo (SNIIM, 2018).

Para realizar el análisis, Brocwell (2004), parte de la premisa de que los modelos de este tipo solo se pueden obtener y validar cuando corresponden a series asociadas significativamente. 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 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 DISCUSIÓN

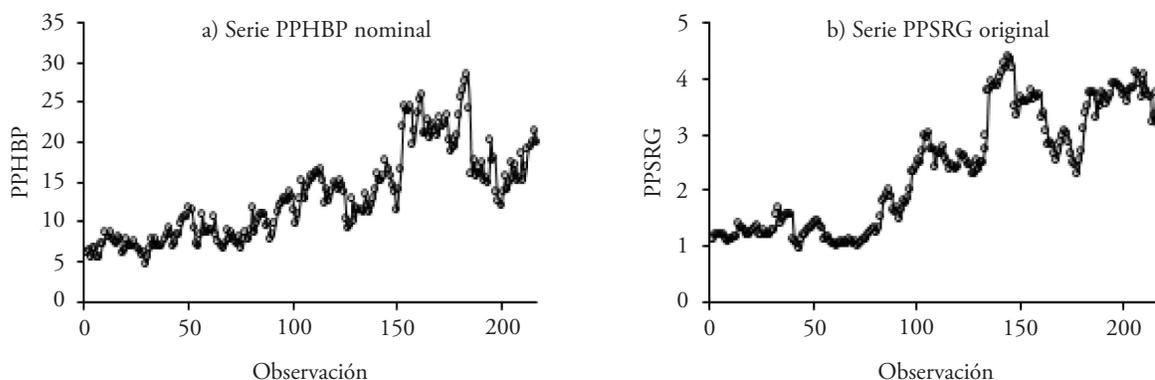
Identificación de los modelos ARIMA para Y_t (PPHBP) y para X_t (PPSRG)

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 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 trasladan 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).

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



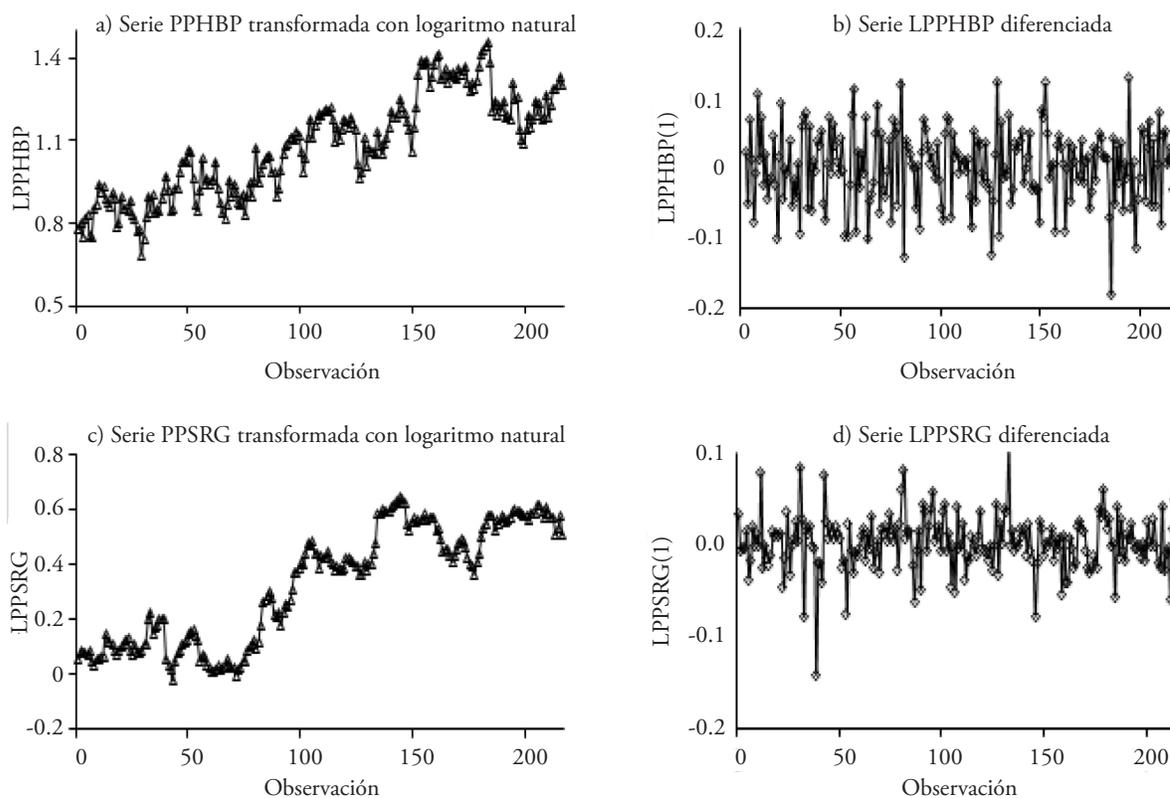
Fuente: elaboración propia con datos de UNA (2018).

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

estacionarias en media y varianza. Por lo tanto, se considera $d = 1$ para ambas series (Figura 2). 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 1).

Etapa 2: Preblanqueo de la serie entrada (*input*)

Después de un análisis en la etapa de preparación de las series, se encontró que la serie de entrada PPSRG viene generada por un suceso ARMA que cumple con las condiciones de estacionariedad e invertibilidad usuales y a_t es un proceso de ruido blanco:



Fuente: elaboración propia con datos de UNA (2018).

Figura 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.

Cuadro 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 ^b	AIC ^c	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			

^b SBC: Criterio Bayesiano de Shwartz, ^c AIC: Criterio de información Akaike, δ_ϵ^2 : Varianza del error.
 Fuente: elaboración propia con los resultados de salida de las transformaciones de LPPHBP(1), PROC ARIMA SAS (2014).

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

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

$$(1 + 0.14669 B^5 + 0.19027 B^8) PPSRG = a_t$$

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

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

Etapa 3: Preblanqueo de la serie salida (*output*)

Se aplicó la misma transformación de preblanqueo a la serie de salida *PPHBP* usando el modelo $SARIMA(0,1,1) X(1,0,1)_{s=12}$. 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 *I* sigue un proceso estacional $ARMA(0,1)X(1,1)$:

$$(1 - \phi_{12} B^{12}) LPPHBP = (1 - \theta_1 B)(1 - \Theta_{12} B^{12}) \beta_t$$

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

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

Etapa 4: Cálculo de la función de correlación cruzada (CCF) entre a_t y β_t

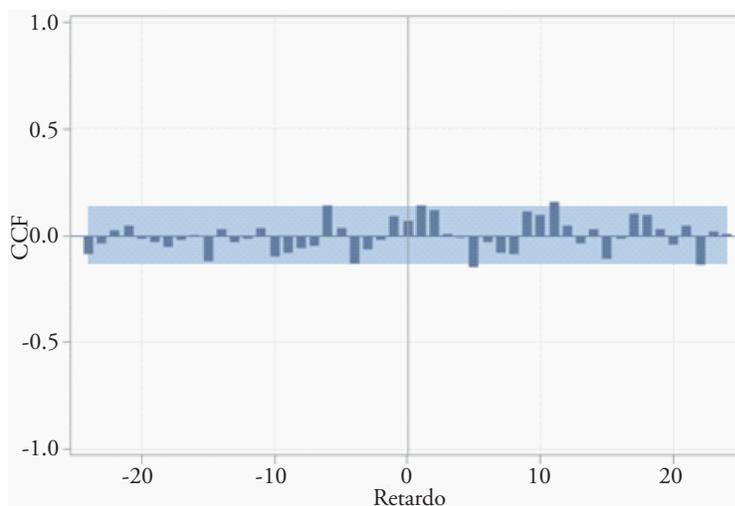
La función de correlación cruzada (CCF) es una medida muy útil de la fuerza y la dirección de la relación entre dos variables aleatorias, es decir, representan la dirección de causalidad (Granger, 1969). En este caso se deben usar series estacionarias, ya que las covarianzas cruzadas sólo podrán interpretarse 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 3).

Etapa 5: 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 $\delta(B)$ y $\omega(B)$, 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. Respeto 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 $(b,r,s) = (1,2,0)$.



Fuente: elaboración propia con los resultados de salida de PROC ARIMA, SAS (2014).

Figura 3. Correlación cruzada entre las series PPSRG (*entrada*) y PPHBP (*salida*) preblanqueadas.

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 6: Estimación de la función de transferencia

La CCF calculada revela una estructura posible, destacando 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). Por lo tanto, ya que se ha identificado el modelo y estimado los parámetros del mismo, el modelo de transferencia final queda de la siguiente forma:

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

Etapa 7: 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 presentan en la Figura 4. La Figura 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 4(b) señala 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 4(c) muestra que las

Cuadro 2. Estimación del modelo de transferencia para la serie de tiempo LPPHBP(1) por máxima verosimilitud.

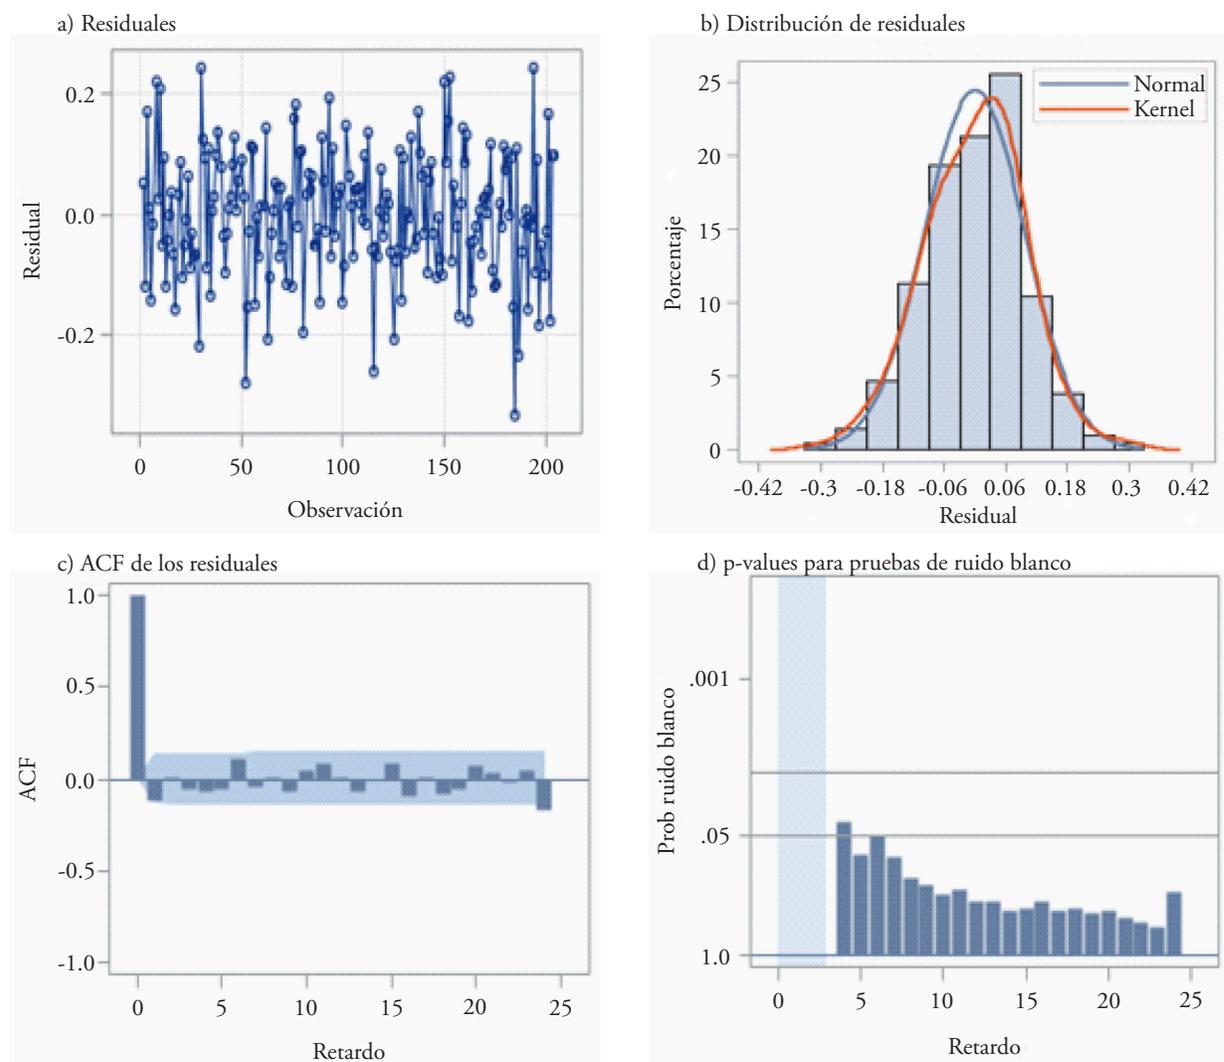
Parámetro	Estimador	Error estándar	Valor t	Aprox. Pr > t	Retardo	Variable	Desp.	SBC ^b	AIC ^a	δ_ϵ^2
MA1,1	0.16074	0.06757	2.38	0.0174	2	LPPHBP	0			
MA2,1	0.93248	0.10891	8.56	<.0001	12	LPPHBP	0			
AR1,1	0.99614	0.01131	88.06	<.0001	12	LPPHBP	0			
NUM1	0.18756	0.05739	3.27	0.0011	0	LPPPSG	1	-332.84	-352.95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

^bSBC: Criterio Bayesiano de Shwartz, ^aAIC: Criterio de información Akaike.

Fuente: elaboración propia con los resultados de salida de PROC ARIMA, SAS (2014).

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 4(d) señala 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.

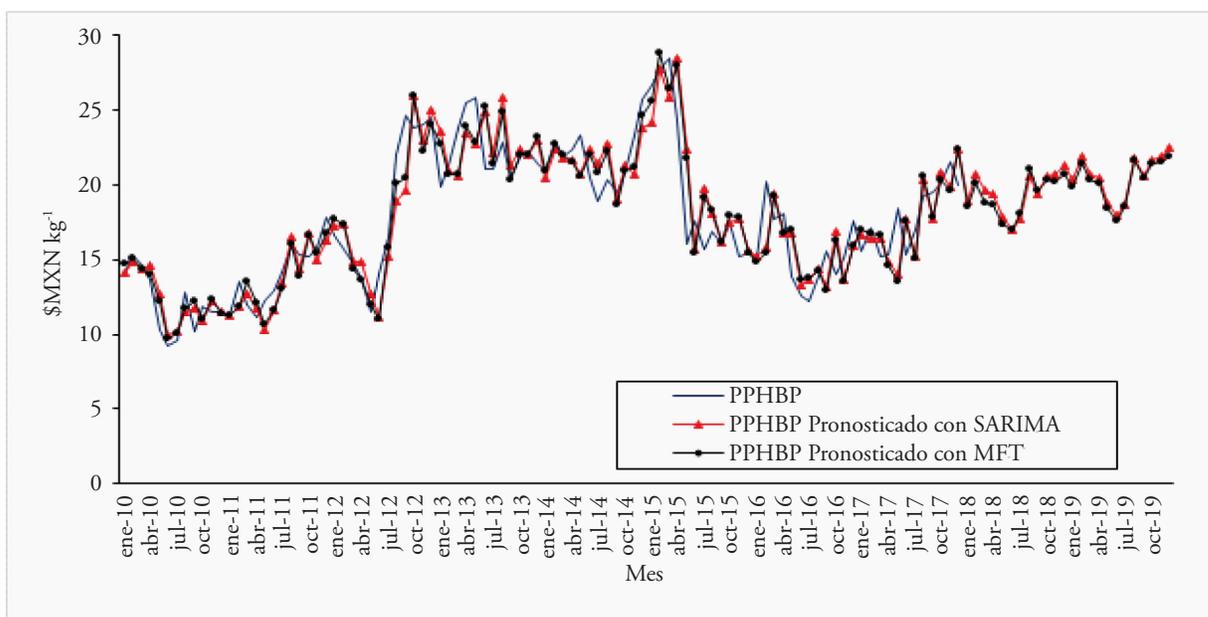
Finalmente, los modelos estimados (SARIMA y MFT) fueron utilizados para hacer predicciones fuera de la muestra para los 24 meses siguientes a la última observación (Figura 5).



Fuente: elaboración propia con los resultados de salida de PROC ARIMA, SAS (2014).

Figura 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) *p-values* para las pruebas de ruido blanco.

Los modelos predicen valores de PPHBP muy próximos a los observados para los meses de los años 2000 a 2017, dado que estos se ubican dentro de la banda de confianza estimada al $\pm 95\%$. Los precios estimados siguen un comportamiento estacional propio de la mayoría de los precios y productos agropecuarios. En el caso de los precios de huevo blanco pagados al productor en México, en los años 2018 y 2019, oscilarán a una TCMA de 0.74% es decir, entre \$16.97 y \$22.47 con el modelo SARIMA. Con el MFT la tasa estimada oscilara 0.58%, es decir entre \$17.46 y \$24.80. Para los años proyectados, los precios nominales tendrán una tendencia al alza, dentro de los rangos antes mencionados, de ahí la importancia de utilizar estos modelos, ya que pueden ser un soporte para la toma decisiones con rigor científico (Figura 5). 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, Maridakis y Wheelwright (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. Se realizó y comprobó la existencia de ruido blanco en los residuales como lo indican los autores. Estos modelos predicen valores de PPHBP muy próximos a los observados, porque estos se ubican dentro de la banda de confianza estimada a $\pm 95\%$ (Cuadro 3). Los efectos del PPSRG sobre los PPHBP indican que el incremento fue de 0.21, es decir, cuando el precio del sorgo (PPSRG) se incrementa en un peso; el precio promedio ($13.12 \text{ \$MXN kg}^{-1}$) del huevo blanco al productor en México (PPHBP) aumenta en $\$0.21 \pm 0.099$ pesos, 30 días después de incremento del primero.



Fuente: elaboración propia con los resultados de salida de PROC ARIMA, SAS (2014).

Figura 5. Precio nominal y pronosticado del huevo blanco pagados al productor en México.

Cuadro 3. Precios nominales observados y estimados de huevo blanco pagados al productor en México, 2017 (\$MXN 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

Fuente: elaboración propia con los resultados de salida de PROC ARIMA, SAS (2014).

Se pronosticaron con relativa precisión los PPHBP utilizando los MFT, mejorando 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. Es preciso señalar, que 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

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.

La inclusión de la variable PPSRG al modelo de función transferencia, mejora la predicción de los PPHBP al disminuir la varianza de 0.01036 a 0.009771 en comparación con el modelo univariante SARIMA, pudiéndose mejorar en la medida que se incluyan más variables de entrada que expliquen el comportamiento de los PPHBP.

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 en ambos casos. 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.

REFERENCIAS

- Box GE, GM Jenkins. 1976. Time Series Analysis: Forecasting and Control. Revised. San Francisco. Ed., Holden-day, 575 p.
- Box GE, GM Jenkins, GC Reinsel. 1994. Time Series Analysis: Forecasting and Control. Englewood Cliffs, NJ. 3rd ed. Ed. Prentice Hall.
- Brockwell PJ. 2004. Representations of continuous-time ARMA processes. *In: Journal of Applied Probability.* 41: 375-382.
- CEDRSSA (Centro de Estudios para el Desarrollo Rural Sustentable y la Soberanía Alimentaria). 2014. Evo-

- lución de los precios del maíz, frijol y sorgo. *In: <http://www.cedrssa.gob.mx/?doc=2643>.*
- Chiogna M, C Gaetan, G Masarotto. 2007. Automatic identification of seasonal transfer function models by means of iterative stepwise and genetic algorithms. *In: J Time Ser Anal*, (29)1: 37–50.
- Chu KY. 1978. Short-run forecasting of commodity prices: An application of autoregressive moving average models. *In: IMF Staff Papers*. 25(1), pp: 90-111.
- Cox DR, GE Box. 1964. An analysis of transformations. *In: Journal of the Royal Statistical Society. Serie B*. 26: 211-252.
- Cruz Jiménez S, García Mata R, Mora Flores JS, García Sánchez RC. 2016. El mercado de huevo para plato en México, 1960 – 2012. *In: Agricultura Sociedad y Desarrollo*. 13(3) pp: 385 - 399.
- García Mata R, García Salazar JA, García Sánchez RC. 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, William J. 1969. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *In: Econometrica*. 37(3):424 – 438.
- Hillmer SC, GC Tiao. 1979. Likelihood Function of stationary Multiple Autoregressive Moving Average Models. *In: Journal of the American Statistical Association* 74. pp: 652 – 660.
- Jarque CM, Anil KB. 1987. A test for Normality of observations and regression residuals. *In: International Statistical Review*. 55(2):163-172.
- Luis Rojas S, García Sánchez RC, García Mata RC, Arana Coronado OA, González Estrada A. 2019. Metodología Box - Jenkins para pronosticar los precios de huevo blanco pagados al productor en México. *Agrociencia*. 53(6): 347 – 365.
- Maridakis SG, Steven CW. 1989. *Forecasting Methods for Management*. 5th Ed. New York: John Wiley & Sons. 470 p.
- Ortega Sánchez de Tagle J. 2014. Plan Rector Visión 2014 – 2024. “Sistema producto huevo para plato”. Imagen Editorial Yire. Cd. de México. 110 p.
- Ramírez Guzmán ME. 1993. SAS macro for analyzing step and impulse response functions derived from transfer function models. *In: http://www.sascommunity.org/wiki/SAS_Global_Forum_Proceedings/SUGI_93*. p: 990 – 995.
- SAS (Statistical Analysis System) 2014. *System for Windows V. 9.4*. Sas Institute Inc. Cary, NC. USA.
- SNIIM (Sistema Nacional de Información e Integración de Mercados). 2017. Secretaría de Economía. <http://www.economia-sniim.gob.mx/nuevo/Home.aspx?opcion=/SNIIM-Pecuarios-Nacionales/SelIng.asp?> Consultado 21 jun, 2017.
- UNA (Unión Nacional de Avicultores). 2018. *Compendio de Indicadores económicos del sector avícola en México año 2017*. 172 p.
- Yafee RA, M McGee. 1999. *Introduction to time Series Analysis and forecasting*. Ed., Academic Press, Inc. Brooklyn, New York. pp: 83 – 89.