

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

The Use of a Univariate Times Series Model to Forecast the Behavior of Pork Meat Production in Baja California, Mexico

Alberto Barreras-Serrano, Eduardo Sánchez-López, Cristina Pérez-Linares y Fernando Figueroa-Saavedra*

Instituto de Investigaciones en Ciencias Veterinarias de la Universidad Autónoma de Baja California.

**edsanmxl@hotmail.com*

RESUMEN

Utilizando la serie mensual de toneladas de carne de cerdo producidas en el estado de Baja California, México entre enero 2003 y diciembre 2010, y aplicando la metodología de Box-Jenkins se desarrolló un modelo univariado de series de tiempo autoregresivo de promedios móviles (ARMA). El análisis del correlograma de la serie y la aplicación de la prueba de Dickey-Fuller aumentada indicaron un comportamiento estacional y mediante la revisión de diversas combinaciones autoregresivas AR (p) y de promedios móviles MA (q), dos modelos fueron propuestos y evaluados: un ARMA con un rezago de 12 meses (mes), tanto para su componente autoregresivo como en el de promedios móviles y un AR también con un rezago de 12 mes. Los parámetros de los modelos fueron estimados por mínimos cuadrados utilizando el programa económico Eviews versión 6. Con base a estos resultados y aplicando los criterios de Akaike y Schwarz se inició el proceso de selección del mejor modelo. Para evaluar la presencia de un problema de autocorrelación en ambos modelos se analizó el comportamiento de sus residuales y se utilizó el estadístico Ljung-Box. La revisión de la capacidad predictiva de los modelos mediante estadísticos de calidad de ajuste en unión con los resultados de las pruebas realizadas indicó que el modelo ARMA era el mejor. Se concluye que este tipo de modelos son útiles para predecir en el corto plazo el comportamiento de la producción de carne de cerdo.

Palabras clave: Producción porcina, ARIMA, predicción.

ABSTRACT

Using the monthly data of tons of pork meat produced in the State of Baja California, Mexico between January 2003 to December 2010 and based on the Box-Jenkins methodology an autoregressive moving average (ARMA) model was constructed to represent the behavior of the local production. Using the correlogram and the Dickey-Fuller test on the time series no evidence of non stationary behavior was found, the process was continued with the validation of a group of autoregressive AR (p) and moving average MA(q) combinations until two were selected: a ARMA with a 12 months lag for the autoregressive and moving average processes and a AR also lagged twelve months. To establish which model better represented the data generating process, the regression coefficients together with the Akaike and Schwarz criteria were used, and to determine the presence of autocorrelation, the correlograms were inspected and a Ljung-Box test was applied, based on this results the ARMA model was selected, it was also found that the same model had better forecasting characteristics that the AR model. It was concluded that this type of time series model may be considered as a useful tool to provide short term forecasts for the production of pork meat.

Key words: Pork production, ARIMA, forecasting.

INTRODUCCIÓN

La producción de carne de cerdo (*Sus scrofa domestica*) en el estado de Baja California, México es una actividad pecuaria que presenta una tendencia negativa, como lo demuestra el hecho de que, entre enero 2003 y diciembre 2010, la producción presentó una caída del 66% [20]; este comporta-

miento negativo, pero con una tasa de declinación menor, se observó a nivel nacional, donde entre 1980 y 2008, la disminución promedio fue del 3%, siendo esta baja atribuida a los menores precios que tiene la carne de cerdo importada [4]. Considerando el crecimiento poblacional que presenta dicho Estado es posible pensar que, la creciente demanda está siendo atendida mediante la introducción e importación de carne de cerdo.

Un factor relevante que puede afectar negativamente los niveles de utilidad de pequeños y medianos productores es la limitada información en que basan sus decisiones [1] y por ello, el acceso y uso de las predicciones y estimaciones de producción que establecen las agencias gubernamentales del sector agropecuario son factores que influyen positivamente sobre la toma de decisiones de los integrantes de dicho sector, por lo que las predicciones generadas deben ser insesgadas y eficientes [19], debido a esto se ve como una ventaja, tanto para los productores como los diseñadores de política pública agropecuaria, disponer de herramientas de estimación que apoyen al conocimiento del comportamiento del mercado de su producto, respaldadas por el acceso a información actualizada y una buena capacidad para predecir el rumbo del mercado [13].

Dada la variabilidad que presenta la producción de carne de cerdo, su crecimiento negativo, la influencia que sobre ella tienen factores externos como la competencia con importaciones de factores internos como el alto costo de inversión [2] y considerando como objetivo el profundizar en el conocimiento del comportamiento de la oferta, la selección y estimación de un modelo estadístico con adecuada capacidad predictiva para representar al proceso generador de información (PGI) se convierte en un objetivo de importancia.

En el análisis económico, los modelos de regresión lineal multivariados han sido ampliamente utilizados con fines predictivos, sin embargo, sus resultados han sido pobres [9] y por ello, los economistas han recurrido a los modelos de series de tiempo univariados, logrando con ello mejores predicciones, pero con la desventaja de que la construcción del modelo no tiene un fundamento teórico, pues se basa en el uso del comportamiento de la misma variable para realizar la predicción [3]. Sin embargo y a diferencia de las variables económicas, en el estudio del comportamiento de las producciones agropecuarias, la fundamentación teórica del modelo no es relevante, lo cual incrementa la aplicabilidad de un modelo de series de tiempo con el propósito de predecir su comportamiento y contribuir desde esa perspectiva a entender mejor el proceso real.

En la estimación de series temporales, la metodología de Box-Jenkins ha sido ampliamente utilizada, dados sus buenos resultados [22], el método consta de tres etapas para la selección de un modelo autoregresivo de promedios móviles (ARMA), que de la mejor manera represente PGI: la identificación, estimación y revisión diagnóstica, las cuales son apoyadas por el principio de parsimonia [5]. El modelo ARMA combina los procesos autoregresivo AR(p) y de promedios móviles

MA(q), se le denomina con las siglas ARMA (p,q), y es representado con la siguiente forma general [3] :

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

donde:

Φ y θ_2 : Son los parámetros del modelo

Y_{t-i} : Es la variable Y con i rezagos

u_{t-i} : Es el error con i rezagos

y se debe cumplir la condición de que: $|\Phi| < 1$

Un modelo multivariado desarrollado en 1985 para los Estados Unidos para predecir la producción porcícola tuvo buenos resultados predictivos [21], no obstante, en una revaluación de éste realizada en 1997, la cual incluyó una comparación con un modelo de series de tiempos autoregresivo integrado de promedios móviles (ARIMA) se determinó que este último modelo lograba resultados predictivos superiores que la especificación original [16].

La información antes revisada respaldó el desarrollo de un grupo de modelos de series de tiempo univariado tipo ARMA o ARIMA que permitieran seleccionar, el que mejor pronostique el comportamiento de la producción de carne de cerdo en el estado de Baja California, México.

MATERIALES Y MÉTODOS

Debido a la naturaleza del modelo empleado, tan solo es necesario una serie temporal de producción de carne de cerdo y por ello se utilizaron las toneladas mensuales de canales procesadas en salas de matanza, de enero 2000 a diciembre 2010, reportadas por el Servicio de Información Agroalimentaria y Pesquera [20]. El tipo de estudio fue descriptivo retrospectivo, estimando y evaluando modelos de series de tiempo univariados tipo ARIMA que describan y pronostiquen el comportamiento de la variable, utilizando para ello la metodología de Box –Jenkins [10].

Un modelo ARMA solo puede ser utilizado cuando el comportamiento de la serie Y_t es estacionario, ya que en una serie estacionaria los valores tienden a regresar a su valor medio fluctuando alrededor de este con un rango más o menos constante [11], si el comportamiento de la serie es no estacionario todos los resultados del análisis de regresión no son válidos [3], cuando el comportamiento estacionario no es evidente, la serie es considerada como no estacionaria y es necesario eliminar la tendencia que presentan los datos antes de proceder a la estimación del modelo seleccionado y para ello se utiliza la diferenciación [12]. Las primeras diferencias de la serie Y_t se logran mediante la siguiente ecuación:

$$\Delta Y_t = Y_t - Y_{t-1}$$

En el caso de que este procedimiento no logre la estacionariedad, se continúa diferenciando hasta lograr un comportamiento estacionario de Y_t . Cuando las primeras diferencias logran eliminar la tendencia, se dice que el modelo está integrado en orden uno y se denota como $I(1)$ de tal manera que la abreviación ARMA ahora es ampliada con la I y se convierte en un modelo ARIMA [3].

Siguiendo la metodología de Box-Jenkins, la identificación del modelo inició determinando la posible estacionariedad de la serie a través de tres evaluaciones: la primera es la revisión del comportamiento de la producción a lo largo del tiempo, ya que además de los indicadores de un comportamiento no estacional como lo son la ausencia de una media o varianza constante y una clara tendencia, se obtiene información sobre valores extremos o cambios estructurales de los datos [8], en segundo lugar se realizó la revisión de los comportamientos de las funciones de autocorrelación (AC) y de autocorrelación parcial (ACP) del correlograma, pues se considera que si estas funciones en los distintos rezagos se ubican alrededor del cero indican un comportamiento estacionario de la serie [10] y como último paso para determinar la posible estacionariedad de la serie, se aplicó la prueba de Dickey y Fuller aumentada (PDFA), considerando tres posibles formas en la descripción del proceso: sin intercepto ni tendencia, con solo intercepto y con ambas [15].

En el caso de que la serie resultara no estacionaria, esta sería transformada obteniendo las primeras diferencias de la variable restando a cada valor el inmediato anterior [9] y se sometería a una nueva PDFA, si la no estacionariedad de la variable persiste, entonces se continuaría diferenciando, hasta alcanzarla. Una vez lograda o confirmada la estacionariedad, el procedimiento continuó identificando los órdenes p y q del probable modelo ARMA mediante la observación el comportamiento de las gráficas de las funciones AC y ACP. A partir de la definición inicial de valores p y q se propusieron varios modelos alternativos con diversas combinaciones AR (p) y MA (q).

Los modelos propuestos son comparados entre sí utilizando el valor de los coeficientes y los criterios de información de Akaike (AIC) y de Schwarz (SC) [22]. Con los probables modelos seleccionados, se realiza la revisión diagnóstica utilizando la gráfica de los residuales en busca de valores extremos y evidencia de periodos, en los cuales el modelo no se ajusta a los datos y aplicando el estadístico Q de Ljung-Box para determinar la presencia de autocorrelación [3]. Adicionalmente se evalúa la capacidad predictiva del modelo como criterio de ratificación, para lo cual se utilizaron los siguientes estadísticos de calidad del ajuste [17]: error promedio porcentual absoluto (EPAP), raíz cuadrática media del error (RCME), el coeficiente de desigualdad de Theil (CDT), la proporción de sesgo (PS), la proporción de la varianza (PV), la proporción de covarianza (PCV). Las estimaciones, pruebas de hipótesis y evaluaciones fueron realizadas con la ayuda del programa econométrico Eviews, versión 6 [18].

RESULTADOS Y DISCUSIÓN

Para apoyar en la determinación del comportamiento de la serie, fue realizada una inspección visual de la gráfica de la producción de carne de cerdo (FIG. 1), la cual sugirió una posible no estacionariedad, dada la clara tendencia negativa que presenta, aunque se observan incrementos periódicos en el último bimestre de cada año.




FIGURA 1. EVOLUCIÓN DE LA PRODUCCIÓN DE CARNE DE CERDO (TON) EN BAJA CALIFORNIA (2003-2010).

Siguiendo el método de Box-Jenkins se revisó el correlograma de la serie sin que el comportamiento de las autocorrelaciones y autocorrelaciones parciales respaldaran la conclusión de la estacionariedad.

Como procedimiento final para establecer si la serie es estacionaria se llevó a cabo la prueba de raíz unitaria de Dickey-Fuller aumentada para la variable *prodcerdo* y el resultado de la prueba en un modelo con intercepto y tendencia fue de rechazo de la hipótesis de presencia de raíz unitaria en los tres niveles de significancia utilizados, este resultado en unión con la conducta de la serie y su correlograma indican un comportamiento estacionario y por lo tanto, la obtención de las primeras diferencias de la serie se hizo innecesaria.

La fase de identificación continuó con la selección y evaluación de un grupo de posibles procesos con diferentes combinaciones p y q , mediante la revisión de sus correlogramas. Como resultado de este procedimiento fueron seleccionados dos modelos: Un ARMA con un rezago igual a 12, tanto para el proceso autoregresivo como el de promedios móviles y un AR con un rezago igual a 12, los cuales fueron estimados mediante mínimos cuadrados ordinarios obteniéndose los resultados que se muestran en TABLAS I y II, respectivamente.

La revisión diagnóstica de los dos modelos utilizando la significancia de los coeficientes de regresión así como los valores para los criterios de Akaike y de Schwarz sugirieron que, el modelo ARMA es el más apropiado para representar el proceso generador de información. Los valores del estadístico Q del correlograma de ambos modelos fueron revisados (TA-

TABLA I
ESTIMACIÓN DE PARÁMETROS Y CRITERIOS DE EVALUACIÓN DEL MODELO ARMA

Variable	Coeficiente	Error Estándar	Estadístico t	Prob>t
AR[12]	0,909798	0,009686	93,92797	0,0000
MA[12]	-0,854679	0,045196	-18,91031	0,0000
R ²	0,602179	Media [prodcerdo]		114,3855
R ² ajustada	0,597268	σ [prodcerdo]		29,62276
E. E. de la regresión	18,79895	Criterio de Akaike		8,729281
Sum resid. al cuadrado	28625,45	Criterio de Schwarz		8,787566
Log verosimilitud	-360,2651	Criterio de Hannan-Quinn		8,752696
Durbin-Watson	1,642746			

TABLA II
ESTIMACIÓN DE PARÁMETROS Y CRITERIOS DE EVALUACIÓN DEL MODELO AR

Variable	Coeficiente	Error Estándar	Estadístico t	Prob>t
AR[12]	0,906433	0,020195	44,88357	0,0000
R ²	0,370596	Media [prodcerdo]		114,3855
R ² ajustada	0,370596	σ [prodcerdo]		29,62276
E. E. de la regresión	23,50122	Criterio de Akaike		9,163957
Sum resid. al cuadrado	45289,21	Criterio de Schwarz		9,193100
Verosimilitud log	-379,3042	Criterio de Hannan-Quinn		9,175665
Durbin-Watson	1,720233			

BLAS III y IV) y se encontró que en el caso del modelo seleccionado no se observaba un problema de autocorrelación, mientras que el modelo AR (12) si presentaba el problema, estos últimos resultados respaldan la selección del modelo ARMA (12, 12).

Para la confirmación de la calidad de ajuste del modelo seleccionado, se evaluó la precisión predictiva de ambos modelos a partir de la comparación de los valores de los estadísticos EPAP, RCME, CDT, PS, PV Y PC, los resultados se muestran en la TABLA V.

El modelo ARMA muestra un mejor ajuste de acuerdo a los estadísticos utilizados y considerando que, tanto el valor del CDT como el de la RCME del primer modelo indican una superioridad predictiva [14], la cual es respaldada por el valor inferior a 0,1 de la PS, por otra parte el valor más alto de PV indica que el modelo ARMA muestra una menor capacidad para replicar la variabilidad del PGI, la PCV es más alta para el primer modelo lo cual hace ver una menor correlación entre las predicciones y los valores reales finalmente el valor del error promedio porcentual absoluto más pequeño para el primer modelo también respalda su selección [17].

Establecida la mejor capacidad predictiva del modelo ARMA se generó una serie de pronósticos para los datos originales (Prodcerdof) usando una predicción dinámica la cual fue comparada gráficamente con los datos originales (FIG. 2).

Finalmente se llevó a cabo una comparación entre los valores reales y pronosticados para los meses de enero, febrero y marzo del 2011 y los resultados pueden ser vistos como un respaldo de la adecuada capacidad predictiva del modelo seleccionado, pues como se observa en la TABLA VI, las diferencias entre los valores son pequeñas.

Los resultados de este trabajo coinciden con los reportados en la literatura [16], en cuanto a que el uso de modelos ARIMA son una buena opción para representar la oferta de producción de carne de cerdo y establecer pronósticos de corto plazo de buena calidad. Resultó interesante el comportamiento estacional que presentó la variable en este trabajo, pues no coincide con lo observado en los Estados Unidos [7], situación que pudiera deberse a que la alta tecnificación que presenta la producción porcina estadounidense contribuye a reducir los efectos estacionales y explica la diferencia de conducta de la serie estudiada.

Debido a que la fase de identificación del modelo se fundamenta en la evaluación del correlograma, la metodología de Box y Jenkins es descrita como pragmática [6], pues prescinde de una fundamentación teórica, por lo que el proceso subyacente no requiere ser comprendido y explicado, ni es necesario aplicar pruebas de hipótesis. Los modelos ARMA presentan una limitación importante ya que solo son útiles cuando se utilizan para establecer pronósticos de corto plazo, por lo que si

TABLA III
CORRELOGRAMA Y ESTADÍSTICOS Q PARA EL MODELO ARMA

Autocorrelación	Correlación Parcial	AC	ACP	Q	P
. *	. *	1	0,085	0,085	0,6168
. *	. *	2	0,179	0,173	3,3925
. *	. *	3	0,147	0,125	5,3083
. .	. .	4	0,036	-0,012	5,4226
. *	. *	5	0,185	0,145	8,5095
* .	* .	6	-0,105	-0,154	9,5134
. .	. .	7	-0,013	-0,056	9,5298
. .	. .	8	-0,030	-0,030	9,6124
* .	* .	9	-0,160	-0,130	12,049
. .	. .	10	-0,045	-0,037	12,247
* .	. .	11	-0,094	0,006	13,109
. .	. .	12	0,005	0,060	13,111
. .	. *	13	0,038	0,078	13,255
. .	. .	14	-0,004	0,043	13,257
. *	. *	15	0,130	0,100	15,014
. .	. .	16	0,025	-0,010	15,082
. *	. .	17	0,108	0,039	16,334
. .	* .	18	0,019	-0,070	16,374
. .	. .	19	0,054	0,012	16,697
. .	* .	20	0,004	-0,075	16,699
* .	* .	21	-0,086	-0,081	17,542
* .	* .	22	-0,089	-0,098	18,463
* .	* .	23	-0,173	-0,115	21,998
** .	* .	24	-0,229	-0,176	28,251

AC: Autocorrelación, ACP: Autocorrelación Parcial, Q: estadístico, P: nivel de significancia.

TABLA IV
CORRELOGRAMA Y ESTADÍSTICOS Q PARA EL MODELO AR

Autocorrelación	Correlación Parcial	AC	ACP	Q	P
. *	. *	1	0,04	0,104	0,9283
. **	. **	2	0,36	0,227	5,7638
. *	. *	3	0,87	0,154	8,8399
. .	. .	4	0,60	-0,016	9,1616
. *	. *	5	0,57	0,086	11,387
* .	* .	6	-0,80	-0,142	11,967
* .	* .	7	-0,090	-0,152	12,726
. .	. .	8	-0,051	-0,037	12,966
* .	* .	9	-0,179	-0,110	16,016
* .	. .	10	-0,071	-0,012	16,502
* .	. .	11	-0,069	0,055	16,966
** .	* .	12	-0,255	-0,192	23,434
. *	. **	13	0,143	0,218	25,485
* .	. .	14	-0,080	0,013	26,147
. *	. *	15	0,138	0,139	28,114
. *	. .	16	0,101	0,050	29,189
. .	. .	17	0,053	0,026	29,485
. *	. .	18	0,161	-0,027	32,310
. .	. .	19	0,046	-0,032	32,538
. .	. .	20	0,051	-0,056	32,834
. .	* .	21	-0,047	-0,163	33,083
* .	* .	22	-0,120	-0,104	34,742
. .	. .	23	-0,016	0,034	34,773
** .	** .	24	-0,228	-0,212	41,000

AC: Autocorrelación, ACP: Autocorrelación Parcial, Q: estadístico, P: nivel de significancia.

TABLA V
EVALUACIÓN DE LA CAPACIDAD PREDICTIVA DE LOS MODELOS ARMA Y AR

Estadístico	ARMA (12,12)	AR (12)
Error promedio porcentual absoluto [EPAP]	11,71078	18,09481
Raíz cuadrática media del error [RCME]	18,53982	26,54661
Coefficiente de desigualdad de Theil[CDT]	0,080367	0,118519
Proporción de sesgo [PS]	0,056398	0,219146
Proporción de varianza [PV]	0,085418	0,001214
Proporción de covarianza [PCV]	0,858184	0,779640




FIGURA 2. COMPARACIÓN DEL COMPORTAMIENTO ENTRE LA SERIE REAL [PRODCERDO] Y LA PRONOSTICADA [PRODCERDOF].

TABLA VI
COMPARACIÓN DE LOS VALORES REALES Y PRONOSTICADOS PARA LOS TRES PRIMEROS MESES UBICADOS FUERA DE LA MUESTRA

Mes	Valor real [Ton.]	Pronóstico [Ton.]
Enero del 2011	71	64,32
Febrero del 2011	70	68,14
Marzo del 2011	74	74,63

Ton.:Toneladas.

se requiere una predicción de mayor plazo es recomendable el uso de modelos multivariados [17]. Debido a lo antes expresado es posible comprender por qué en el análisis econométrico, la metodología ha sido adoptada con lentitud, sin embargo, para el caso de series como la que se utilizó en este trabajo, las situaciones antes mencionadas no tienen la relevancia que se les otorga en economía, pues el objetivo que persigue el análisis es contar con un instrumento cuya aplicación es para predecir un comportamiento [8].

CONCLUSIONES E IMPLICACIONES

De acuerdo con los resultados de este estudio, cuando la serie es estacionaria, los modelos ARMA pueden considerarse como una opción viable para describir el comportamiento de la producción porcícola y para establecer pronósticos con buenas características predictivas, aún cuando la serie en estudio presenta una gran variabilidad, no obstante, en este caso y en concordancia con lo reportado por la literatura, es claro que este tipo de modelos tienen más utilidad para realizar predicciones de corto plazo. Resulta muy atractivo que el proceso pueda ser aproximado a partir de la transformación de la misma variable sin necesidad de establecer relaciones contemporáneas, ya que esto disminuye el tiempo que requiere la construcción del modelo y facilita la obtención de información sobre el comportamiento futuro de una variable que podrá ser utilizada, tanto para la toma de decisiones de los productores de cerdos, como para el diseño o ajuste de la política pública que está dirigida a la actividad, pero con la consideración que la capacidad predictiva del modelo disminuye su calidad cuando es usada para pronósticos de largo plazo.

REFERENCIAS BIBLIOGRÁFICAS

[1] AKTER, S.; RAHMAN, S. Agribusiness forecasting with univariate time series modeling techniques: The case of a dairy cooperative in the UK. **J. Farm Manag.** 11:747-764. 2010.

[2] APOSTOLOPUOLOS, C.; THEODOLOPOULOU, H.; PETRAKOS, G.; THEODOLOPOULOS, G. Factors affecting the regional meat productivity of commercial pig units in Greece. **Agric. Econ. Rev.** 1: 39-46. 2001.

[3] ASTERIOU, D.; STEPHEN, G.H. ARIMA models and the Box-Jenkins methodology. In: **Applied econometrics a modern approach**. Palgrave MacMillan. New York. 397 pp. 2007.

- [4] BOBADILLA, S.E.; ESPINOZA, O.A.; MARTÍNEZ, C.F. Dinámica de la producción porcina en México de 1980 a 2008. **Rev. Mex. Cien. Pec.** 1 [3]:251-268. 2010.
- [5] BOX, G.P.; JENKINS, G.M. Stochastic model building. In: **Time series analysis, forecasting and control**. Holden Day. Oakland. 555 pp. 1976.
- [6] BROOKS, C. Univariate time series modelling and forecasting. In: **Introductory Econometrics for Finance**. 2nd Ed. Cambridge University Press. Cambridge, Massachusetts. 648 pp. 2008.
- [7] COLINO, E.V.; IRWIN, S.H.; GARCIA, P. "How Much Can Outlook Forecasts be Improved? An Application to the U.S. Hog Market. 2008." **Proceedings of the NCCC-134 Conference on Applied Commodity Price Analysis, Forecasting, and Market Risk Management**. St. Louis, MO. On line: <http://www.farmdoc.uiuc.edu/nccc134>. 09/12, 2011.
- [8] ENDERS, W. Stationary time-series models. In: **Applied econometrics Time Series**. Wiley. Hoboken N J, USA. 460 pp. 2004.
- [9] EVANS, M.K. Univariate time-series model and forecasting. In: **Practical Business forecasting**. Blackwell Publishers. Malden, Massachusetts. 501 pp. 2003.
- [10] GUJARATI, D.N.; PORTER, D.C. Econometría de series de tiempos. En **Econometría**. 5ª Ed. Mac Graw Hill. México D. F. 921 pp. 2010.
- [11] HARRIS, R.; SOLLIS, R. Short and long run models. In: **Applied time series modeling and forecasting**. John Wiley & Sons. West Sussex, UK. 302 pp. 2005.
- [12] KENNEDY, P. A. Time series econometrics. In: **A guide to econometrics**. 5th Ed. MIT press. Cambridge, Massachusetts. 623 pp. 2003.
- [13] MYERS, R.J.; SEXTON R.J.; TOMEK W.G. A century of research on agricultural markets. **Amer. J. Agric. Econ.** 92[2]: 376-402. 2010.
- [14] NANDA, S. Forecasting: Does the Box-Jenkins method work better than regression? **Vikalpa**. 1:53-62. 1988.
- [15] NGURAH A., I.G. Additional testing hypotheses. In: **Time series data analysis using Eviews**. Singapore: John Wiley & Sons. 609 pp. 2009.
- [16] NWOHA, J.; MANFREDO, M.; DITSCH, M.; LEUTHOLD, R. A Reexamination of a Popular Econometric Model of Pork Supply and Forecasting Performance vs. ARIMA and Composite Approaches. 1997. **Proceedings of the NCR-134 Conference on Applied Commodity Price Analysis, Forecasting and Market Risk Management**. Chicago, IL. On line: <http://www.farmdoc.uiuc.edu/nccc134>. USA.08/08, 2011.
- [17] PINDYCK, R.S.; RUBINFELD D.L. Estimación y pronóstico con modelos de series de tiempo. En: **Econometría modelos y pronósticos**. 4^a Ed. Mc Graw-Hill. México D. F. 661 pp. 2001.
- [18] QUANTITATIVE MICRO SOFTWARE. Eviews 6. Irvine, California. 2007.
- [19] SANDERS, D.R.; MANFREDO, M.R. USDA Production Forecasts for Pork, Beef, and Broilers: An Evaluation. **J. Agric. Res. Econ.** 27(1): 114-127. 2002.
- [20] SISTEMA DE INFORMACIÓN AGROPECUARIA Y PESQUERA. Avance mensual de la producción pecuaria por Estado 2010. Secretaría de Agricultura, Ganadería, Desarrollo Rural Pesca y Alimentación. En Línea: www.siap.gob.mx. 06/21/ 2011.
- [21] STILLMAN, R.A. A quarterly model for livestock industry. USDA, Economic Research Service Technical Bulletin, 1711, 1985. On line: <http://naldc.nal.usda.gov/download/CAT87201614/PDF>. 08/10/2011.
- [22] VOGELVANG, B. Univariate times series models. In: **Econometrics. Theory and applications with Eviews**. Pearson Education Limited. Essex, England. 363 pp. 2005.