



APLICACIÓN DE UN MODELO ARIMA PARA PRONOSTICAR LA PRODUCCIÓN DE LECHE DE BOVINO EN BAJA CALIFORNIA, MÉXICO

[USING AN ARIMA MODEL TO FORECAST BOVINE MILK PRODUCTION IN BAJA CALIFORNIA, MEXICO]

Eduardo Sánchez-López, Alberto Barreras-Serrano*, Cristina Pérez-Linares, Fernando Figueroa-Saavedra and José Angel Olivas-Valdez

Instituto de Investigaciones en Ciencias Veterinarias, Universidad Autónoma de Baja California, A. Obregón y J. Carrillo s/n Col Nueva, Mexicali, Baja California, 21100, Tel. (686) 5636906, e-mail: edsanmxl@hotmail.com, abarreras@uabc.edu.mx, cristinapl@yahoo.com, fernando_figueroa@uabc.edu.mx, olivasja@uabc.edu.mx

**Corresponding author*

RESUMEN

El objetivo fue aplicar un modelo de series de tiempo univariado tipo ARIMA en la descripción y pronóstico del comportamiento de la producción lechera de bovino en el estado, aplicando para ello la metodología de Box y Jenkins. La serie de producción mensual de litros leche de enero del 2000 a diciembre del 2009 fue utilizada en el estudio. El análisis del correlograma y la aplicación de la prueba de Dickey y Fuller aumentada indicaron que la producción lechera presentaba un comportamiento estacional. Del análisis de diversas combinaciones AR(p) y MA(q), dos modelos fueron propuestos y evaluados: ARMA (1,1) y ARMA (2,2). Los parámetros fueron estimados por mínimos cuadrados. Con base a éstos y aplicando los criterios de Akaike y Schwarz (18.06, 18.13 y 18.20, 18.27, respectivamente) se definió el mejor modelo. Adicionalmente se analizaron los residuales y la capacidad predictiva de cada modelo a través de los estadísticos de calidad de ajuste, resultando como mejor el ARMA (1,1). Se concluye que este tipo de modelos son de utilidad tanto para describir como para predecir el comportamiento de la producción lechera.

Palabras claves: Producción lechera; ARIMA; pronóstico.

INTRODUCCIÓN

A nivel nacional la industria láctea es la tercera actividad industrial alimentaria más importante del país y para crecer depende de la producción de leche de bovino, la cual durante el período 2003-2011 ha tenido una tasa media de crecimiento nacional de 1.3%. En el estado de Baja California la producción

SUMMARY

An ARIMA model was constructed to represent the behavior of local milk production, using the monthly data between January of 2000 and December of 2009 for milk production in the state of Baja California, Mexico. The three step methodology described by Box and Jenkins for model selection and estimation was applied. Both, the correlogram behavior and the Dickey-Fuller test were used to determine if the series was stationary. The series resulted stationary and no differencing needed, then the process of model selection was performed and as result of this two ARMA models (1,1 and 2,2) were proposed. The parameters of model were estimated by ordinary least squares and the statistics and regression results in conjunction with the Akaike and Schwarz criteria (18.06, 18.13 y 18.20, 18.27, respectively) with the results of the correlogram of each model were used to determine which model better represented the data generating process. The results indicated the (1,1) model was better in fitting, thus this model had better forecasting characteristics. It was concluded that this type of time series model can be considered as a useful tool to describe and forecast milk production however its usefulness is restricted to short term forecasts.

Key words: milk production; ARIMA; forecasting.

de leche en una importante actividad pecuaria como lo demuestra el hecho de que en el 2009 el valor de la producción ascendió a \$873,311,000 (SIAP, 2011), sin embargo, a pesar del crecimiento poblacional en el estado y contrario al comportamiento productivo nacional, la producción lechera local muestra una tendencia negativa con una gran variabilidad (Figura 1). Este comportamiento puede ser explicado por la

salida del mercado de las explotaciones tecnificadas las cuales ofertan un porcentaje importante de la producción (Secretaría de Fomento Agropecuario, 2011), pero que enfrentan a costos más elevados y se ven afectados por la variabilidad de los precios internacionales de su producto (Secretaría de Economía, 2012), siendo este último punto de gran importancia pues es factible para los consumidores bajacalifornianos la compra de leche pasteurizada en los Estados Unidos cuando los precios de ese país son menores.

En general un factor importante que influye sobre la toma de decisiones de los integrantes del sector agropecuario son las predicciones y estimaciones de producción que establecen las agencias gubernamentales por lo que esta debe ser insesgada y eficiente (Sanders and Manfredo, 2002), y por ello se ve como una ventaja tanto para los productores estatales como los diseñadores de política pública agropecuaria disponer de herramientas que apoyen al conocimiento del comportamiento del mercado de su producto y da valor al acceso a información actualizada y a una buena habilidad para predecir el rumbo del mercado (Myers *et al.*, 2010)

La gran variabilidad que presenta la producción de leche en el estado de Baja California y su decrecimiento son factores que respaldan establecer un modelo que represente al proceso generador de información (PGI) y si este cuenta con una estructura sencilla que permite predecir con una aceptable confiabilidad el comportamiento de este producto pecuario, que de acuerdo a Lohano y Soomro (2006) se ve influenciado por factores externos, entre los que destacan las enfermedades y una menor disponibilidad de alimento para el ganado, se estaría apoyando una mejor toma de decisiones productivas y económicas por parte de los productores de leche.

En el análisis económico los modelos de regresión lineal multivariados han sido ampliamente utilizados con fines predictivos, sin embargo, sus resultados han sido pobres (Evans, 2003) por lo que 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, dado que se basa en el uso del comportamiento de la misma variable para realizar la predicción (Asteriou y Hall, 2007). 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 los modelos de series de tiempo en la predicción de su comportamiento y con ello contribuir desde esa perspectiva a entender mejor el proceso real. Allen (1994) reporta que la predicción de producción y precios agrícola con modelos econométricos arroja pobres resultados, sin embargo

encontró que entre las diferentes opciones de modelos los de series de tiempos autorregresivos integrados de promedios móviles (ARIMA) lograba los mejores resultados en cuanto a precisión. Con respecto al uso de modelos univariados para predecir la producción lechera Deluyker *et al.* (1990) los utilizó para modelar la producción lechera a nivel de un establo y Macciota *et al.* (2000) obtuvieron buenos resultados cuando la utilizaron en la identificación de la forma de la curva de lactancia en ovejas, mientras que Akter y Rahman (2010) utilizaron este tipo de modelos a nivel cooperativa. Satya *et al.* (2007) encontró en un estudio sobre la predicción de leche en la India, que un modelo de series de tiempos autorregresivo integrado de promedios móviles (ARIMA) lograba resultados predictivos superiores a los de un modelo de suavizamiento exponencial.

El objetivo de este estudio es describir y pronosticar el comportamiento de la producción lechera de bovino en Baja California, México mediante el uso de un modelo de series de tiempo univariado tipo ARIMA.

MATERIAL Y MÉTODOS

El tipo de estudio fue descriptivo retrospectivo. Se aplicaron los modelos ARIMA para describir y pronosticar la serie del comportamiento mensual de producción de leche reportados por el servicio de información agroalimentaria y pesquera (SIAP, 2010) de la Secretaría de Agricultura, Ganadería, Pesca, y Desarrollo Rural para Baja California. Los datos estadísticos de rendimiento utilizados, registrados como producción diaria en litros, corresponden al período comprendido entre enero del 2000 a octubre del 2009. Los registros fueron procesados como una serie temporal mensual. Los procesos ARIMA se aplican a series estacionarias; es decir, a series de tiempo con media y varianzas constantes (Box y Jenkins, 1976). Este método evita el uso de variables independientes adicionales como tipo de explotaciones existentes, número de explotaciones, entre otras a la variable en estudio, de la cual se considera solo su comportamiento en el pasado y el comportamiento del error (Vogelbang, 2005).

El diseño y ajuste de un modelo ARIMA se realiza en tres etapas sucesivas: la identificación, la estimación y la revisión diagnóstica (Box y Jenkins, 1976), apoyados todos ellos por el principio de parsimonia.

La forma general de un modelo autorregresivo de promedios móviles estacionales (ARMA) de acuerdo a Asteriou y Hall (2007), se muestra en la ecuación 1. Combina los procesos autorregresivos (AR(p)) y de promedios móviles (MA(q)) y se le acompaña en su definición con los órdenes correspondientes (p,q).

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

en el cuál, el valor actual de la serie, Y_t , (variable temporal), puede explicarse en función de p valores pasados $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$, donde p determina el número de rezagos necesarios para pronosticar un valor actual, Φ_i y θ_i son los parámetros del modelo, u_t son valores actuales de la serie influenciados por los valores de una fuente externa. Estos modelos suponen linealidad. El modelo de promedio móviles de orden q está dado por:

$$u_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

donde ε es un proceso de ruido blanco de naturaleza aleatoria (ruido), tal que $\varepsilon_t \sim Niid(0, \sigma^2)$ para todo t .

Sin embargo un modelo ARMA solo tiene utilidad en la estimación cuando Y_t es estacionaria, significando que la media, varianza y covarianza de la serie sean constantes a lo largo del tiempo. Cuando la estacionalidad no es evidente, es necesario su inducción utilizando la diferenciación (Kennedy, 1998). Las primeras diferencias de una serie están dadas por la ecuación 2:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2)$$

La identificación del modelo inicia determinando la estacionalidad de la serie a través de tres evaluaciones: la primera es la revisión de la gráfica de la serie 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 quiebres estructurales de los datos (Enders, 2004), en segundo lugar utilizando el correlograma se lleva a cabo la revisión de la función de autocorrelación (AC), que muestra los coeficientes de correlación del valor actual de la serie rezagado cierto número de períodos, y la función de autocorrelación parcial (ACP), cuyos coeficientes miden la correlación de la serie actual y rezagada después de considerar el poder predictivo de todos los valores de la serie con menores rezagos. Si para ambas funciones se muestra un comportamiento en el que los distintos rezagos se ubican alrededor del cero, respalda un comportamiento estacional (Gujarati y Porter, 2010). Por último se aplica 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 (Ngurah Agung, 2009). En caso de que la serie

resulte no estacional, se tiene que hacer uso tanto de la transformación logarítmica como de las primeras diferencias de la variable (Evans, 2003) para someterse posteriormente a una nueva PDFA. Si la no estacionalidad de la variable persiste, entonces se continúa diferenciando la serie hasta alcanzarla.

En la estimación, el procedimiento continúa identificando los órdenes p y q del probable modelo ARMA mediante la observación del comportamiento de las gráficas de las funciones AC y ACP. A partir de la definición inicial de valores p y q se proponen varios modelos alternativos con diversas combinaciones AR(p) y MA(q). Los modelos propuestos son comparados entre si utilizando el valor de los coeficientes y los criterios de Akaike (AIC) y de Schwarz (SC).

Con los probables modelos seleccionados se realiza la revisión diagnóstica a través del análisis de la gráfica de los residuales en busca de valores extremos y evidencia de períodos en los cuales el modelo no se ajusta a los datos y de la prueba del estadístico Q de Ljung-Box para determinar la presencia de autocorrelación (Pindick y Rubinfeld, 2001). El estadístico Q permite realizar un contraste global de los residuos y determinar si éstos son ruido blanco. Para ello, se acompaña de un nivel de significancia P , que indica el grado de no rechazo de la hipótesis nula (residuos son ruido blanco) y, en consecuencia, cuanto mayor sea dicho nivel, mayor confianza se puede depositar en la hipótesis nula. Adicionalmente se evalúa la capacidad predictiva del modelo como criterio de ratificación para lo cual se utilizan los estadísticos de calidad del ajuste: 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) (Brooks, 2008). Con base a este procedimiento se propusieron dos modelos: ARMA (1,1) y ARMA (2,2). Las estimaciones, pruebas de hipótesis y evaluaciones fueron realizadas con la ayuda del programa econométrico Eviews, versión 7 (Quantitative Micro Software, 2009).

RESULTADOS Y DISCUSIÓN

El comportamiento de la serie producción de leche (prodleche) se observa en la Figura 1 en la que es sugestiva la ausencia de un comportamiento estacional por su tendencia negativa en general, con una variabilidad que se acentúa al inicio, en la parte central se reduce y hacia la parte final con un nuevo incremento.

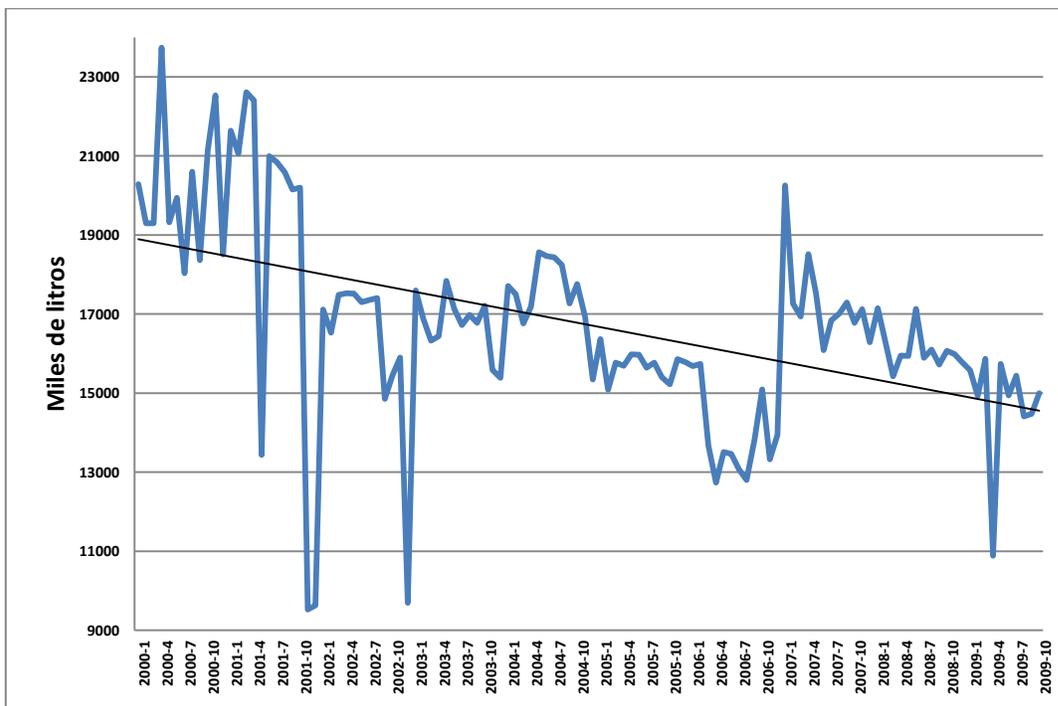


Figura 1. Evolución de la producción de leche en Baja California (2000-2009).

La posible no estacionalidad fue revisada mediante la construcción del correlograma de la variable en su forma original (Tabla 1) sin que éste pudiera respaldar el comportamiento no estacional.

En la hipótesis de no estacionalidad (presencia de una raíz unitaria) para la variable prodleche, el resultado de la prueba Dickey Fuller aumentada para un modelo con intercepto y tendencia fue de rechazo de H_0 a un nivel de significancia de 0.01, por lo que este resultado en unión con la conducta de la serie y su correlograma indican un comportamiento estacional 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. Los parámetros de los modelos de regresión candidatos fueron estimados y sometidos a una prueba de hipótesis de igualdad con cero. Con base en estos resultados y de la aplicación de los criterios AIC y SC resultaron seleccionados los modelos ARMA (1,1) y ARMA (2,2) (Tablas 2 y 3).

Con el fin de iniciar el proceso de selección del modelo final, se llevó a cabo análisis de los coeficientes y estadísticos de ambos modelos encontrándose que el modelo ARMA (1,1) presenta en general mejores resultados y destacan el menor valor tanto del error estándar de la regresión como para los valores de los criterios de Akaike y de Schwarz.

En el análisis de los residuales de ambos modelos (Tabla 4 y 5) en busca de presencia de autocorrelación. Se observó que para el modelo ARMA (1,1) el comportamiento de ellos apoya la ausencia de la condición, dado que gran parte se mantienen dentro de las bandas. Además el comportamiento de los valores del estadístico Q más los valores de significancia presentes en la última columna respaldan el hecho de que el comportamiento de los residuos pueda ser visto como ruido blanco. El análisis del correlograma para el modelo ARMA (2,2) además de los valores del estadístico Q indican presencia de autocorrelación global de los residuos

Tabla 1. Correlograma de la variable prodleche

Autocorrelación	Correlación Parcial	AC	ACP	Q	P	
. ****	. ****	1	0.553	0.553	37.671	0.000
. ***	. *	2	0.440	0.193	61.683	0.000
. ***	. *	3	0.438	0.202	85.707	0.000
. **	. .	4	0.334	-0.003	99.774	0.000
. **	. .	5	0.298	0.044	111.05	0.000
. **	. *	6	0.327	0.112	124.75	0.000
. **	. *	7	0.321	0.086	138.13	0.000
. *	* .	8	0.184	-0.142	142.55	0.000
. *	. .	9	0.192	0.019	147.41	0.000
. *	. .	10	0.197	0.032	152.57	0.000
. *	. .	11	0.186	0.067	157.20	0.000
. **	. *	12	0.229	0.085	164.29	0.000
. *	** .	13	0.087	-0.211	165.32	0.000
. .	. .	14	0.061	-0.036	165.83	0.000
. .	. .	15	0.045	-0.010	166.12	0.000
. .	. .	16	0.040	0.036	166.34	0.000
. .	. .	17	0.017	-0.047	166.38	0.000
. .	* .	18	-0.044	-0.139	166.66	0.000
. .	. .	19	-0.045	-0.012	166.95	0.000
* .	* .	20	-0.154	-0.091	170.41	0.000
* .	. .	21	-0.102	0.062	171.93	0.000
* .	* .	22	-0.130	-0.095	174.44	0.000
* .	. .	23	-0.103	0.040	176.05	0.000
. .	. *	24	-0.009	0.161	176.06	0.000
* .	. .	25	-0.080	-0.008	177.06	0.000

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

Tabla 2. Estimación de parámetros y criterios de evaluación del modelo ARMA (1,1)

Variable	Coficiente	Error Estándar	Estadístico t	P>t
Intercepto	16136.41	827.6410	19.49687	0.0000
AR(1)	0.913675	0.048824	18.71363	0.0000
MA(1)	-0.642386	0.097733	-6.572892	0.0000
R ²	0.378566	Media (prodleche)		16659.88
R ² ajustada	0.367852	σ (prodleche)		2513.272
E. E. de la regresión	1998.245	Criterio de Akaike (AIC)		18.06281
Sum resid al cuadrado	4.63E+08	Criterio de Schwarz (SC)		18.13288
Log verosimilitud	-1071.737	Criterio de Hannan-Quinn		18.09126
Durbin-Watson	1.844735	F		35.33256

AR(1): componente autoregresivo de primer orden,

MA(1): componente de promedios móviles de primer orden

Tabla 3. Estimación de parámetros y criterios de evaluación del modelo ARMA (2,2)

Variable	Coficiente	Error Estándar	Estadístico t	P>t
Intercepto	16622.80	477.8783	34.78459	0.0000
AR(2)	0.784172	0.054255	14.45344	0.0000
MA(2)	-0.488070	1.36E-05	-36009.24	0.0000
R ²	0.286322	Media (prodleche)		16637.51
R ² ajustada	0.273911	σ (prodleche)		2512.059
E. E. de la regresión	2140.548	Criterio de Akaike (AIC)		18.20061
Sum resid . al cuadrado	5.27E+08	Criterio de Schwarz (SC)		18.27105
Log verosimilitud	-1070.836	Criterio de Hannan-Quinn		18.22921
Durbin-Watson	1.46784	F		23.06859

AR(2): componente autoregresivo de segundo orden,
 MA(2): componente de promedios móviles de segundo orden

Tabla 4. Correlograma y estadísticos Q del modelo ARMA (1,1)

Autocorrelación	Correlación Parcial	AC	ACP	Q	P	
. *	. *	1	0.077	0.077	0.7152	
* .	* .	2	-0.074	-0.081	1.3979	
. .	. .	3	0.017	0.030	1.4352	0.231
* .	* .	4	-0.079	-0.090	2.2095	0.331
* .	* .	5	-0.083	-0.067	3.0858	0.379
. .	. .	6	0.046	0.045	3.3532	0.501
. *	. .	7	0.083	0.069	4.2327	0.516
* .	* .	8	-0.150	-0.163	7.1674	0.306
* .	. .	9	-0.074	-0.053	7.8893	0.342
. .	. .	10	-0.013	-0.028	7.9101	0.442
. .	. .	11	0.029	0.053	8.0235	0.532
. *	. *	12	0.157	0.143	11.330	0.332
* .	* .	13	-0.080	-0.149	12.191	0.349
. .	. .	14	-0.064	-0.040	12.752	0.387
. .	. .	15	-0.014	0.007	12.780	0.465
. .	. *	16	0.055	0.086	13.205	0.510
. .	. .	17	-0.005	-0.029	13.209	0.586
. .	* .	18	-0.065	-0.126	13.804	0.613
. .	. .	19	0.003	-0.012	13.805	0.681
* .	* .	20	-0.173	-0.103	18.155	0.446
. .	. .	21	-0.005	0.044	18.159	0.512
. .	* .	22	-0.025	-0.107	18.249	0.571
. .	* .	23	-0.052	-0.101	18.648	0.608
. .	. .	24	0.067	0.066	19.337	0.624
* .	* .	25	-0.098	-0.088	20.804	0.593

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

Estos resultados sugieren que el modelo ARMA (1,1) puede ser la mejor opción para representar el proceso generador de información de interés, coincidiendo con lo reportado por Satya et al. (2007) quienes definen los órdenes $p=1$ y $q=1$ como la estructura de rezago más conveniente, con la diferencia en que el modelo de Satya se integró en orden 1. En la confirmación de la calidad de ajuste del modelo seleccionado, se evaluó su capacidad predictiva a

partir de la generación de una serie de pronósticos para los datos originales (prodlechef) usando una predicción estática, la comparación de la serie original y la pronosticada muestra que el modelo seleccionado permite la obtención de una curva de predicción que logra capturar el comportamiento de la serie adecuadamente excepto en el caso de los picos y crestas pronunciadas (Figura 2).

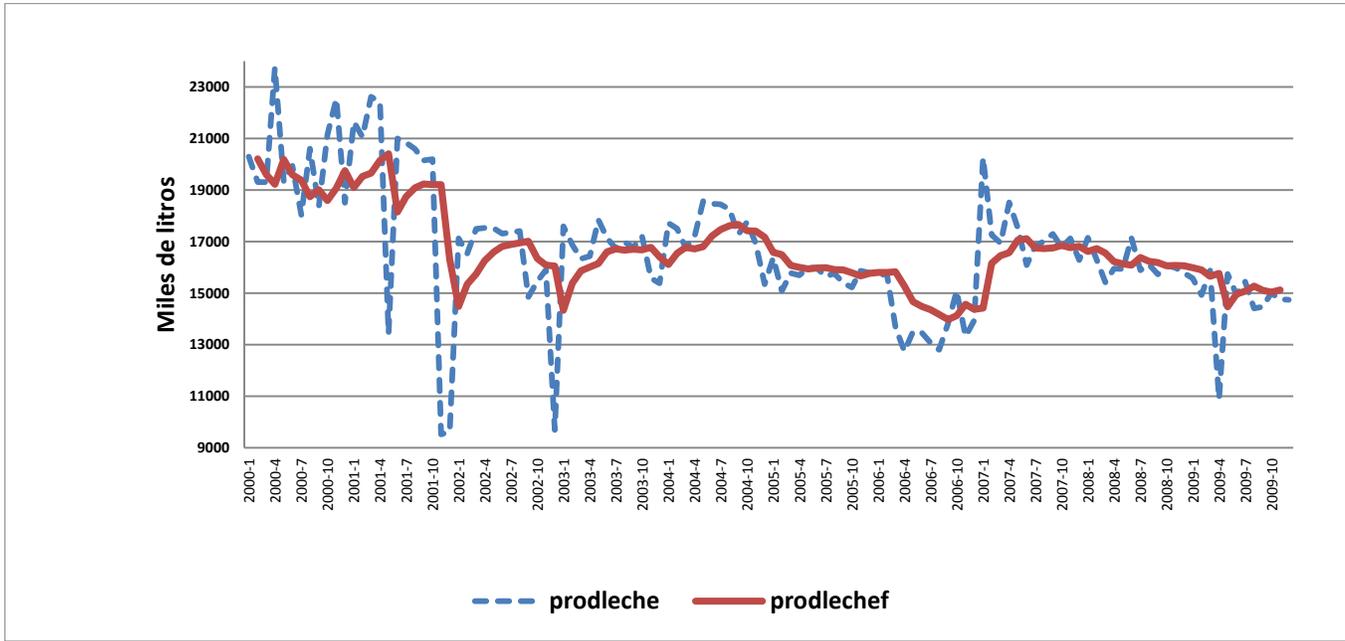


Figura 2. Comparación del comportamiento entre la serie original (prodleche) y la pronosticada (prodlechef).

Tabla 5. Correlograma y estadísticos Q del modelo ARMA (2,2)

Autocorrelación	Correlación Parcial	AC	ACP	Q	P	
. **	. **	1	0.263	0.263	8.3674	
. .	* .	2	-0.034	-0.111	8.5111	
. *	. *	3	0.105	0.157	9.8755	0.002
. .	* .	4	-0.054	-0.149	10.241	0.006
. .	. .	5	-0.038	0.052	10.421	0.015
. .	. .	6	0.069	0.034	11.022	0.026
. *	. *	7	0.095	0.098	12.179	0.032
* .	* .	8	-0.125	-0.205	14.189	0.028
. .	. .	9	-0.063	0.054	14.704	0.040
. .	* .	10	-0.017	-0.077	14.740	0.064
. .	. *	11	0.055	0.180	15.137	0.087
. *	. .	12	0.140	0.029	17.770	0.059
. .	* .	13	-0.050	-0.108	18.113	0.079
* .	. .	14	-0.080	-0.054	18.994	0.089
. .	. .	15	-0.030	0.024	19.116	0.120
. .	. *	16	0.044	0.091	19.381	0.151
. .	* .	17	-0.019	-0.085	19.433	0.195
* .	* .	18	-0.071	-0.100	20.148	0.214
. .	. .	19	-0.032	-0.022	20.299	0.259
* .	* .	20	-0.175	-0.091	24.728	0.133
* .	. .	21	-0.066	0.056	25.366	0.149
. .	* .	22	-0.060	-0.159	25.900	0.169
. .	. .	23	-0.061	-0.010	26.459	0.189
. .	. .	24	0.036	0.047	26.654	0.225
* .	* .	25	-0.100	-0.074	28.162	0.210

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

Como elemento adicional para respaldar la selección del modelo que de mejor manera representaba al PGI

se llevó a cabo una evaluación de la capacidad predictiva de los dos modelos estimados utilizando un

grupo de estadísticos. Los resultados se muestran en el Tabla 6.

El modelo ARMA (1,1) mostró un mejor ajuste de acuerdo al criterio aplicado por Nanda (1988) para determinar el desempeño predictivo de un modelo: menores valores tanto para el coeficiente de desigualdad de Theil como para la raíz cuadrática media del error, la cual es respaldada por el valor más pequeño de PS. Además, por el valor más bajo para PV, el modelo ARMA (1,1) mostró una mayor capacidad de réplica en la variabilidad del PGI. También, el valor menor para el error promedio porcentual absoluto en el primer modelo respalda su selección. Sin embargo, el valor ligeramente mayor en PCV desfavorable para el primer modelo pudiera ser indicador de una baja correlación entre las estimaciones y los valores reales (Pindick y Rubinfeld (2001), situación que puede ser respaldada al observar la Figura 2.

En lo que respecta a la capacidad predictiva del modelo, Enders (2004) recomienda realizar una predicción de valores que no fueron utilizados en la estimación, considerando que los modelos ARIMA son utilizados para predicciones de corto plazo y atendiendo el objetivo de este trabajo se realizó el pronóstico de la producción para noviembre del 2009, los resultados se muestran en el Tabla 7.

Como se observa el modelo sobrestimó la producción por 353.77, esta sobrestimación si bien representa un diferencial de solo 2.4% al revisar la Figura 2 es posible observar que en su parte final, la curva de predicción tiende a sobrestimar la producción, por lo que predicciones a más largo plazo tenderán a

presentar diferenciales mayores con respecto a los valores reales.

Los resultados de este trabajo coinciden con aquellos de Satya et al. (2007) y Deluyker et al. (1990) en cuanto a que el uso de modelos ARIMA son una buena opción para representar la oferta de producción de leche y establecer pronósticos de buena calidad, aún cuando Nanda (1988) encontró que en una comparación de modelos autorregresivos contra modelos estimados por mínimos cuadrados generalizados, éstos últimos mostraban mejor desempeño predictivo situación probablemente explicada por la naturaleza de la información. No obstante los buenos resultados reportados es importante establecer que estos modelos son útiles solo para realizar predicciones a corto plazo pues no tienen la capacidad de considerar en el largo plazo los cambios en la dinámica de la serie (Macciota et al., 2000)

Debido a que la fase de identificación del modelo se fundamenta en la evaluación del correlograma, Brooks (2008) describe a la metodología de Box y Jenkins como pragmática, además, prescinde de un marco conceptual teórico (Griffiths et al., 1993) por lo que el proceso subyacente no requiere ser comprendido y explicado ni es necesario aplicar pruebas de hipótesis. Debido a esto, es posible comprender por qué en el análisis econométrico la metodología ha sido adoptada con reserva, sin embargo, para el caso de series como la que se ilustra 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 el de contar con un instrumento de aplicación para predecir el comportamiento de la variable.

Tabla 6. Evaluación de la capacidad predictiva de los modelo ARMA (1,1) y ARMA (2,2).

Estadístico	ARMA (1,1)	ARMA (2,2)
Error promedio porcentual absoluto (EPAP)	8.051420	9.145700
Raíz cuadrática media del error (RCME)	1972.697	2113.162
Coefficiente de desigualdad de Theil (CDT)	0.058769	0.062822
Proporción de sesgo (PS)	0.000009	0.003770
Proporción de varianza (PV)	0.244900	0.362381
Proporción de covarianza (PCV)	0.755000	0.633840

Tabla7. Comparación entre el resultado real y pronosticado para la producción lechera de noviembre del 2010 (miles de litros)

Producción real	Producción pronosticada	Diferencia en litros	Diferencia porcentual
14,770	15,123.77	353.77	2.4

CONCLUSIONES

La aplicación de esta metodología permitió generar un modelo ARIMA para describir y establecer pronósticos de la producción lechera a corto plazo, aun cuando la serie en estudio presenta gran variabilidad. Es importante evaluar exhaustivamente la presencia de un comportamiento estacional de toda serie pues la selección equivocada de un modelo integrado o de un modelo no integrado produciría resultados predictivos inadecuados.

Resulta muy atractivo que el proceso pueda ser aproximado a partir de la transformación de la misma variable sin necesidad de establecer relaciones contemporáneas, esto en un período corto permite a las dependencias gubernamentales la construcción de modelos predictivos como respaldo para establecer políticas de apoyo al sector. La aplicación de esta metodología puede ser también aprovechada por las organizaciones de productores como instrumento adicional para conocer mejor el comportamiento de su producción de forma agregada y estimar su comportamiento a futuro, de tal forma de disponer de más información para respaldar sus acciones de cabildeo y del proceso de planificación que de manera grupal establecen para respaldar el avance de su actividad productiva. La generación de pronósticos por parte de las dependencias gubernamentales principalmente en periodos estacionales donde la producción presenta variaciones fuertes puede convertirse en un instrumento que de ser conocidos por los productores, les permitiría tomar medidas técnicas para enfrentar o aprovechar estas circunstancias mejorando con ello su capacidad de respuesta.

REFERENCIAS

- Akter, S., Rahman, S. 2010. Agribusiness forecasting with univariate time series modeling techniques: The case of a dairy cooperative in the UK. *Journal of Farm Management*. 11: 747-764.
- Allen, P. G. 1994. Economic forecasting in agriculture. *International Journal of Forecasting*. 10: 81-135.
- Asteriou, D., Hall, S. G. 2007. *Applied econometrics. A modern approach*. New York, USA.
- Box, G., Jenkins, G. 1976. *Time series analysis, forecasting and control*. Holdan Day. Oakland, California, USA.
- Brooks, C. 2008. *Introductory econometrics for finance*. 2nd ed. Cambridge University Press. Cambridge, Massachusetts, USA.
- Deluyker, H. A., Shumway, R. H., Wecker, W. E., Azari, A. S., Weaver, L. D. 1990. Modeling daily milk yield in Holstein cows using time series analysis. *Journal of Dairy Science*. 73:539-548.
- Enders, W. 2004. *Applied econometrics. Time series*. John Wiley and Sons. Hoboken New York. USA.
- Evans, M. K. 2003. *Practical business forecasting*. Blackwell Publishers. Malden Massachusetts USA.
- Gujarati, D. N., Porter, D. N. 2010. *Econometría*. 5ta ed. Mc Graw-Hill. México, D. F.
- Griffiths, W. E., Hill, P. C., Judge, G.G. 1993. *Learning and practicing econometrics*. John Wiley and Sons. Hoboken, New York. USA.
- Kennedy, P. 1998. *A guide to econometrics*. 4th ed. MIT press. Cambridge Massachussets. USA.
- Lohano, H. D., Soomro, F. M. 2006. Unit root test and forecast of milk production in Pakistan. *International Journal of Dairy Sciences*. 1: 63-69.
- Macciota, N.P.P., Cappio-Borlino, A., Pulina, G. 2000. Time series autoregressive integrated moving average modelling of test-day milk yields of dairy ewes. *Journal of Dairy Science*. 83:1094-1103.
- Myers, R. J., Sexton, R. J., Tomek, W. G. 2010. A century of research on agricultural markets. *American Journal of Agricultural Economics*. 92: 376-402.
- Nanda, S. 1988. Forecasting: does the Box-Jenkins method work better than regression? *Vikalpa*. 1: 53-62.
- Ngurah Agung, I. G. 2009. *Time series data analysis using eviews*. John Wiley & Sons. Singapore.
- Pindick, R. S., Rubinfeld, D. L. 2001. *Econometría modelos y pronósticos*. 4ta ed. Mc Graw-Hill. Mexico D.F.

- Quantitative Micro Software, LLC. 2009. *EViews 7 software*. Irvine CA, USA.
- Sanders, D. R., Manfredo, M. R. 2002. USDA production forecasts for pork, beef, and broilers: an evaluation. *Journal of Agricultural and Resource Economics*. 27: 114-127.
- Satya, P., Ramasubramanian, V., Metha, S. C. 2007. Statistical models for forecasting milk production in India. *Journal of the Indian Society of Agricultural Statistics*. 2: 80-83.
- Secretaría de Economía. 2012. Análisis del sector lácteo en México. Dirección General de Industrias Básicas. México D.F.
- Secretaría de Fomento Agropecuario. 2011. Panorama general de la producción lechera en Baja California. Gobierno del Estado de Baja California. Mexicali Baja California.
- SIAP. 2010. Avance mensual de la producción pecuaria por estado 2000-2009. Sistema de información agroalimentaria y pesquera. www.siap.gob.mx
- SIAP. 2011. Avance mensual de la producción pecuaria por estado 2010. Sistema de información agroalimentaria y pesquera. www.siap.gob.mx
- Vogelvang, B. 2005. *Econometric theory and applications with Eviews*. Prentice Hall. Essex. England.

Submitted August 08, 2012– Accepted January 31, 2013
Revised received August 07, 2013