



Madera y Bosques

ISSN: 1405-0471

publicaciones@ecologia.edu.mx

Instituto de Ecología, A.C.

México

Broz, Diego R.; Viego, Valentina N.
Predicción de precios de productos de *Pinus spp.* con modelos ARIMA
Madera y Bosques, vol. 20, núm. 1, 2014, pp. 37-46
Instituto de Ecología, A.C.
Xalapa, México

Disponible en: <http://www.redalyc.org/articulo.oa?id=61730576004>

- ▶ Cómo citar el artículo
- ▶ Número completo
- ▶ Más información del artículo
- ▶ Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto



Predicción de precios de productos de *Pinus spp.* con modelos ARIMA

Forecasting prices of manufactured *Pinus spp.* using ARIMA models

Diego R. Broz¹ y Valentina N. Viego²

¹ Doctorando en Ingeniería, Universidad Nacional del Sur. Buenos Aires, Argentina. diego.broz@uns.edu.ar

² Departamento de Economía. Universidad Nacional del Sur. vviego@criba.edu.ar

RESUMEN

En el noreste argentino se encuentra el polo forestal de mayor importancia del país, concentrado en las provincias de Misiones y Corrientes, siendo *Pinus spp.* L. la de mayor producción, las cuales abastecen a gran número de actividades industriales. Esto evidencia la necesidad de aplicar herramientas de gestión forestal para tomar mejores decisiones de inversión y manejo de los montes. Los modelos de gestión forestal suelen utilizar distintas técnicas, entre ellas simulación, basadas en investigación operativa, y econométricas. Generalmente, las técnicas económétricas suelen ser utilizadas para proyecciones de precios y retornos. Una clase importante de modelos con datos longitudinales es la familia de los modelos autorregresivos de media móvil, conocidos como ARIMA, por sus siglas en inglés, generalmente aplicados para describir tendencias y generar predicciones a partir de valores pasados de las series. En particular, la variación de precios forestales es una de las principales fuentes de incertidumbre en la planificación forestal. Sin embargo, es escasa aún la aplicación de técnicas y modelos de predicción en el área forestal, especialmente a nivel sudamericano. Los modelos ARIMA exhiben buen desempeño predictivo en el corto plazo, aunque pierden capacidad de pronóstico en horizontes alejados y presentan algunos otros inconvenientes. Se propone un modelo autorregresivo de media móvil (ARIMA) basado en la metodología de Box-Jenkins para predecir los precios de cuatro productos de *Pinus spp.* para el noreste argentino. Para ello se utilizan series temporales de precios correspondientes al periodo julio 2002-septiembre 2013. Los modelos propuestos predicen precios futuros con errores de predicción entre 0,9% y 1,8%.

PALABRAS CLAVES: Media móvil, modelos autorregresivos, multiproducto forestal, predicción de precios.

ABSTRACT

Northeastern Argentina is the forest area of greater importance in the country, concentrated in the provinces of Misiones and Corrientes, with *Pinus spp.* L., the species with higher production, which supplies raw materials to a large number of industrial activities. This highlights the need to implement forest management tools to make better decisions in investment and management of forests. Forest management models often use different techniques, including simulation, based on operational research, and econometric tools. Usually, the econometric techniques tend to be used for projections of prices and returns. An important class of models with longitudinal data is the family of Autoregressive moving average models, known as ARIMA, by its acronym in English, usually applied to describe trends and generate predictions from values passed from the series. In particular, the variation of prices of forest products is one of the main sources of uncertainty in forest planning. Nevertheless, the application of techniques and prediction models in the forestry area, especially at the South American region is still low. ARIMA Models exhibit good predictive short-term performance, although they lose ability to forecast in distant horizons and have some other disadvantages. Various autoregressive moving average models (ARIMA) based on Box-Jenkins methodology are proposed to predict future prices of four products for *Pinus spp* manufactured in Northeast Argentina. Estimations were carried out with time series of prices of the four products covering the period July 2002-September 2013. The proposed models predict future prices with forecast errors between 0,9% and 1,8%.

KEY WORDS: Moving average, autoregressive models, multi-forest, price forecasts.

INTRODUCCIÓN

En el noreste argentino se encuentra el polo forestal de mayor importancia del país; en las provincias de Misiones y Corrientes se concentra más de 60% de la producción forestal nacional. En particular, Misiones dedica más de 360 mil hectáreas a la actividad forestal, siendo *Pinus spp.* L. la de mayor proporción (82%, equivalente a 302 383 ha), las cuales abastecen a 640 actividades industriales de un total de 731 que se desarrollan en la provincia (SIFIP, 2012). Lo mencionado evidencia la necesidad de aplicar herramientas de gestión forestal para tomar mejores decisiones de inversión y manejo de los montes.

Los modelos de gestión forestal suelen utilizar distintas técnicas, entre ellas simulación, basadas en investigación operativa, y económicas (Buongiorno y Gilless, 1987; Buongiorno y Gilless, 2003). Generalmente, las técnicas económicas suelen ser utilizadas para proyecciones de precios y retornos (Arce, 1997).

Una clase importante de modelos con datos longitudinales es la familia de los modelos autorregresivos de media móvil, conocidos como ARIMA (AR: autorregresivo; I: integrado, MA: media móvil), por sus siglas en inglés, generalmente aplicados para describir tendencias y generar predicciones a partir de valores pasados de las series (Brooks, 2008).

En particular, la variación de precios forestales es una de las principales fuentes de incertidumbre en la planificación forestal (Leskinen y Kangas, 1998). El mismo autor recalca la importancia de los precios de venta para lograr una gestión racional y el nivel de actividad de una región. La previsión acertada de precios interviene críticamente en decisiones tácticas (talar o esperar) y a la vez sirve como herramienta de transacción. Con todo, es escasa aún la aplicación de técnicas y modelos de predicción en el área forestal, especialmente a nivel sudamericano.

Las estimaciones de modelos ARIMA cuentan con algunos antecedentes en estudios de precios de productos forestales como Oliveira *et al.* (1977); Leskinen y Kangas (1998); Gong (1999) y Yin (1999), para madera aserrada y pulpa de madera; Koutroumanidis *et al.* (2009) para pre-

cios de leña en Grecia; Mei *et al.* (2010) en el caso de derechos de tala y especies aserradas en 12 regiones forestales estadounidenses. Otros trabajos los utilizan para pronosticar la demanda de madera rolliza en Venezuela (Carrero *et al.*, 2008) o evolución de la vegetación (Fernández Manso *et al.*, 2001). En América latina, el país con más aplicaciones (publicadas en revistas académicas) de esta clase de modelos es Brasil con grupos de investigación radicados en el Departamento de Ciencias Forestales de la Universidad Federal de Lavras y la Universidad de Viçosa (Coelho Junior *et al.*, 2006; Silva-Soares *et al.*, 2008; Silva-Soares *et al.*, 2010; Araujo-Cerdeiro *et al.*, 2010, entre otros). En contraste, no se registran en la literatura antecedentes de aplicación de esta metodología en la temática forestal para Argentina.

Es importante aclarar que los modelos ARIMA exhiben buen desempeño predictivo en el corto plazo, aunque pierden capacidad de pronóstico en horizontes alejados. Además, presentan inconvenientes si las series involucradas han experimentado cambios estructurales en su trayectoria. Por último, la mejor especificación surgida para una especie, periodo muestral y localización no puede ser extrapolada a otras circunstancias (Brooks, 2008; Enders, 2009).

OBJETIVO

El objetivo del trabajo es evaluar la capacidad predictiva de los modelos ARIMA aplicados a los precios de multiproductos forestales industrializables para la zona norte de Misiones (Argentina), siguiendo la metodología de Box-Jenkins. Como objetivos específicos se pretende difundir una herramienta para la toma de decisiones del sector e ilustrar que la metodología genera resultados satisfactorios en el corto plazo sin necesidad de recurrir a modelos estructurales.

MATERIALES Y MÉTODOS

Datos y fuentes

Las series de precios están conformadas por cuatro clases de productos clasificados por el diámetro en punta fina



(menor diámetro industrializable de un tronco o fuste, DPF) según criterio del COIFORM (Colegio de Ingenieros Forestales de Misiones, Argentina. <http://www.coiform.com.ar/>), siendo la primer clase, C1, de características pulpables aceptando rollos de hasta 8 cm DPF; la C2 de 18 cm a 24 cm DPF con características para aserrío fino; C3 de 25 cm a 29 cm DPF para aserrío grueso y C4 de 30 cm a 35 cm DPF para laminable. La serie utilizada pertenece a los registros del COIFORM. En la figura 1 se aprecia la evolución de la serie de precios.

Método

Se aplica la metodología propuesta por Box y Jenkins (1976), que consiste en estimar modelos autorregresivos de media móvil (ARIMA) con el fin de encontrar el mejor ajuste para datos longitudinales. Los modelos ARIMA predicen los valores futuros de la serie a partir de su comportamiento pasado, sin necesidad de identificar los factores subyacentes en los movimientos de la variable en el tiempo. Por este motivo, se les conoce como modelos no estructurales.

El caso más simple de modelos no estructurales para datos longitudinales es el proceso de media móvil. Sea u_t (con $t = 1, 2, \dots, T$) un proceso ruido blanco, con $E(u_t) = 0$ y $\text{var}(u_t) = \sigma^2$, luego:

$$y_t = \mu + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

$$y_t = \mu + \sum_{i=1}^q \theta_i u_{t-i} + u_t$$

En este caso, t es el tiempo; $E(u_t)$ es la esperanza matemática de u_t ; $\text{var}(u_t)$ es la varianza constante; σ^2 es una varianza; y_t es la media móvil; μ es un parámetro perteneciente a la media móvil.

Un proceso de media móvil es una combinación lineal de procesos de ruido blanco, de modo que y_t depende de valores presentes y pasados de un término de perturbación caracterizado como ruido blanco. De este modo, $E(y_t) = \mu$.

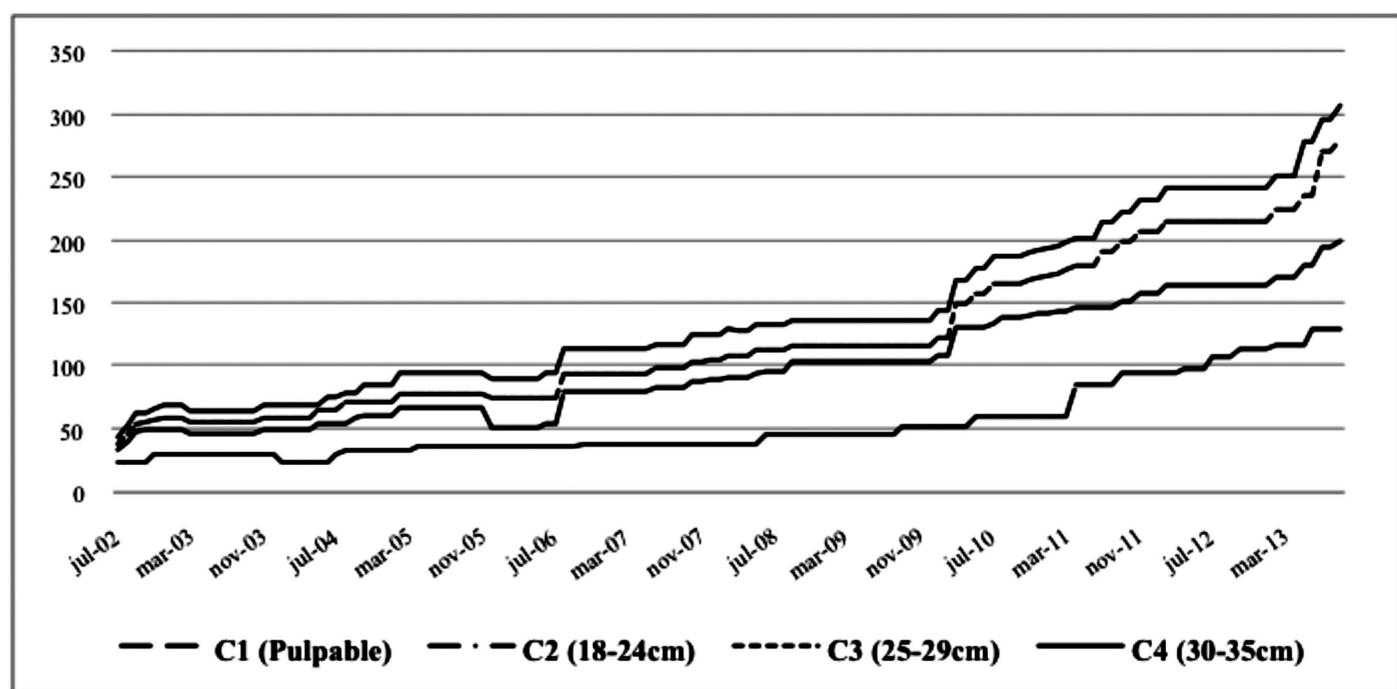


FIGURA 1. Evolución de precios (\$AR) por clase de producto. Julio 2002-septiembre 2013.

En un modelo autorregresivo, AR, el valor presente de y depende de valores pasados de y más un término de error. Un proceso autorregresivo de orden p se expresa:

$$y_t = \mu + u_t + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p}$$

$$y_t = \mu + \sum_{i=1}^p \varphi_i y_{t-i} + u_t$$

En este caso φ y ϕ son parámetros autorregresivos.

En el caso de modelos AR, una propiedad deseable es la estacionariedad de los coeficientes; de no cumplirse esta condición, el modelo provocaría que los valores previos del término de error tengan un efecto no decreciente sobre el valor de y_t a medida que pasa el tiempo, lo cual resulta contraintuitivo y en muchos casos poco factibles. La estacionariedad de un modelo AR de orden p se visualiza en raíces de la ecuación característica dentro del círculo unitario (Viego y Broz, 2012; Brooks, 2008).

De este modo, un modelo ARMA (p, q) (modelo mixto que incluye tanto términos autorregresivos, AR, como de medias móviles, MA) refiere a una serie que sigue un proceso que puede ser modelado con p términos autorregresivos y q términos de media móvil. Se debe aclarar, no obstante, que las series involucradas deben ser estacionarias; es decir, no presentar ningún tipo de tendencia en la media o su varianza. Si las series objeto de pronóstico cumplen esta condición, se dice que son integradas de orden 0, $I(0)$. Sin embargo, la mayor parte de las series económicas expresan algún tipo de tendencia que las vuelve no estacionarias. Con todo, aunque una serie pueda seguir un proceso no estacionario, es frecuente que sus diferencias sean estacionarias. Por ello, la identificación de modelos ARIMA requiere conocer el grado de integración de las series a predecir y, por ende, la cantidad de veces que debe ser diferenciada una serie hasta conseguir una progresión estacionaria. De este modo, se dice que una serie sigue un proceso ARIMA (p, r, q) donde p y q representan los términos autorregresivos y de media móvil respectivamente y r denota el grado de integración.

La metodología implica 5 grandes pasos:

a. *Eliminación de tendencias en la media (conocida como tendencia determinística) y en la varianza (tendencia estocástica), con el objetivo de conseguir estacionariedad en las series involucradas.* En este paso corresponde asimismo determinar si hay algún tipo de estacionalidad que deba ser modelado. Este paso es fundamental para determinar el orden de integración de la serie y , por ende, la cantidad de veces que debe ser diferenciada para obtener una secuencia estacionaria. Operativamente, esto se evalúa con la prueba de Dickey Fuller, especificada como sigue:

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

Donde ρ es un coeficiente de autocorrelación; Y_{t-1} es el valor de la variable de interés en el periodo $t-1$ y u_t es el error o ruido blanco. La prueba consiste en evaluar si $\rho=1$, en cuyo caso se concluye que la serie sigue un proceso de caminata aleatoria y, por ende, no estacionario. Restando Y_{t-1} a ambos lados de la expresión anterior, se obtiene que:

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

Donde $D(Y_t)$ representa al término Y_t diferenciado. Si $\rho=1$ es equivalente a probar si $(\rho-1)=1$ en la expresión anterior. Dickey y Fuller (1979) probaron que el coeficiente que acompaña a Y_{t-1} no sigue una distribución conocida. Por este motivo, calcularon sus valores críticos. Asimismo, la prueba puede admitir distintas especificaciones, por ejemplo incluir intercepto o tendencia de tipo determinístico. Dado que los valores críticos se modifican según la especificación que adopte la prueba, es importante revisar si las conclusiones que se derivan de la prueba se mantienen de una especificación a otra. Por otro lado, en un trabajo posterior, Dickey y Fuller (1981) incluyeron rezagos de la primera diferencia de Y_t en la regresión de prueba para admitir la posible existencia de autocorrelación serial. Esta variante se conoce como Dickey Fuller aumentado.

La prueba de Dickey Fuller debe ser aplicada a la serie original y, en el caso de no rechazarse la nula bajo



ninguna especificación (lo cual equivale a admitir que la serie no es estacionaria), debe probarse con la serie en primeras diferencias. El proceso secuencial sigue hasta rechazar la nula. Así, la prueba aplicada secuencialmente permite conocer el orden de integración de las series a predecir.

b. Examen de los gráficos de las funciones de autocorrelación (en adelante FAC) y autocorrelación parcial (en adelante FACP) con el fin de identificar qué componentes autorregresivos o de media móvil utilizar en la estimación del modelo. En particular, los procesos autorregresivos de orden p suelen exhibir una *FAC* de aspecto decreciente en forma exponencial y eventualmente algunos componentes sinusoidales. Esta función debe ser complementada con la *FACP*, que se vuelve cero a partir del rezago $p+1$ en adelante. Varios paquetes estadísticos ofrecen un intervalo de confianza de 95% del valor de la *FACP* (que es aproximadamente $\pm 2/T^{0.5}$, donde T es el tamaño muestral).

Los valores de la *FAC* de un proceso $MA(q)$ se vuelven nulos a partir del retardo $q+1$ en adelante. En este caso, también es posible utilizar el intervalo de confianza para el valor de la *FAC*.

En la práctica, las *FAC* y de *FACP* no muestran procesos autorregresivos o de media móvil puros, sino que más bien corresponden a casos mixtos, difíciles de identificar.

Por ello, este tipo de modelos implican bastante de prueba y error. Recientemente se han propuesto criterios de información (como el de Akaike, Schwartz, etc.) o el error de predicción como guía en la selección del modelo *ARIMA* más adecuado (Brockwell y Davis, 1987; Brockwell y Davis, 2002).

c. Aplicar los algoritmos de cálculo para estimar los coeficientes que mejor ajustan al modelo ARIMA especificado. Los métodos más utilizados son máxima verosimilitud o mínimos cuadrados no lineales.

d. Validación del modelo estimado a fin de verificar que cumpla con las especificaciones de un proceso estacionario univariado. En particular, los residuos deben ser independientes entre sí y tener media y varianza constantes en el tiempo (es decir, deben ser ruido blanco; esto se puede verificar con el contraste de Ljung-Box o mediante el correlograma de los residuos). Si la estimación no es adecuada, se deberá retornar al paso a.

e. Evaluación de la capacidad predictiva del modelo estimado. El error de predicción equivale a la diferencia entre el pronóstico y el valor observado en cada periodo. Dado que el error puede ser positivo o negativo, no es posible sumar los errores de predicción. Por ello, generalmente se toman sus cuadrados (error medio cuadrático,

TABLA 1. Prueba de Dickey Fuller aumentada

Especificación	C1	C2	C3	C4
Con tendencia determinística	-0,4082 (0,9864)	-1,4745 (0,8336)	-0,4594 (0,9843)	-,4552 (0,9845)
Con intercepto	1,9071 (0,9998)	,9241 (0,9956)	2,2872 (0,9999)	2,4294 (0,9999)
Sin intercepto	3,6515 (0,9999)	3,7307 (0,9999)	3,6477 (0,9999)	3,9544 (0,9999)
En primeras diferencias	-11,363 (<0,01)	-11,0161 (<0,01)	-5,4307 (<0,01)	-5,3129 (<0,01)

Nota: Error tipo I entre paréntesis

EMC) o valores absolutos (error medio absoluto, *EMA*). Tomados individualmente, la magnitud de ambas medidas no resulta de utilidad, sino que deben ser comparadas con las que surgen de modelos alternativos para los mismos datos y periodo muestral. El modelo con menores *EMC* o *EMA* será el de mejor capacidad predictiva (en presencia de datos atípicos es más conveniente utilizar el *EMA* que el *EMC* como criterio de evaluación de capacidad predictiva).

Es posible, además, descomponer el error de predicción, en proporción de sesgo, proporción de varianza y de covarianza. El componente de sesgo mide hasta qué punto la media de las predicciones es diferente de la media de los datos observados (es decir, si la predicción está sesgada). Análogamente, el componente de varianza mide la diferencia entre la variación de la predicción y la de los valores observados. El componente de covarianza captura cualquier parte no sistemática del error de predicción (Granger y Newbold, 1986).

La secuencia descrita fue realizada con el paquete estadístico *EViews 7.0*.

RESULTADOS

Los resultados de la aplicación de la secuencia anteriormente descrita a las series de precios de *Pinus* spp. para el periodo jul.-2002 a sept.-2013 pueden resumirse como:

El método de eliminación de tendencias que genera series estacionarias (condición para estimar modelos *ARIMA*) es el de primeras diferencias. La tendencia determinística en este caso no consigue producir series de precios estacionarias. Por otra parte, dado que la evolución de los precios no muestra, durante el periodo analizado, cambios abruptos en su trayectoria, la prueba de Dickey-Fuller arroja resultados confiables como método de verificación de existencia de tendencia estocástica (de todos modos y con el fin de verificar la robustez de la prueba de Dickey Fuller, se aplicó el contraste de Phillips Perron arribando a las mismas conclusiones sobre la caracterización del nivel de integración de las series).

Se concluye, en principio, que las series de precios de las especies forestales bajo análisis son integradas de orden 1 (Tabla 1). En otros términos, los niveles originales exhiben tendencia estocástica que desaparece aplicando primeras diferencias.

El correlograma de las series en primeras diferencias (es decir, estacionarias) permite identificar algunas especificaciones posibles para la estimación de variantes *ARIMA*. En el caso de C1, las *FAC* y las *FACP* son significativas en los rezagos 5, 11 y 15, por lo que se estimaron distintas combinaciones de *ARIMA* (5,11,15; 1; 5,11,15) de la serie diferenciada. Es decir, que el modelo inicial estimado para esta variable incluyó 3 términos autorregresivos y 3

TABLA 2. Especificaciones ARIMA.

	C1	C2	C3	C4
Modelo inicial	ARIMA(5,11,15; 1; 5,11,15) Sólo resulta significativo el término MA(15)	ARIMA(8,18; 1; 8,18) Sólo resulta significativo el término MA(8)	ARIMA(2,1;2) Sólo resulta significativo el término MA(2)	ARIMA(2,6; 1; 2,4) Sólo resultan significativos los términos AR(2) y MA(4)
Mejor variante del modelo inicial*	ARIMA(5; 1; 11,15)	ARIMA(0; 1; 8,18)	ARIMA(0;1;2)	ARIMA(2;1;4)
Residuos son ruido blanco?	sí	sí	sí	sí

* la mejor variante se define como aquella que cumple con las condiciones de estacionariedad e invertibilidad (raíces dentro del círculo unitario), con todos los parámetros del modelo significativos y con menor criterio de información.



TABLA 3. Capacidad predictiva de los modelos propuestos

	C1	C2	C3	C4
Especificación escogida	ARIMA(5;1;11,15)	ARIMA(0; 1; 8, 18)	ARIMA(0; 1; 2)	ARIMA(2; 1; 4)
Error medio cuadrático	2,8729	3,6183	4,6025	4,3522
Error medio absoluto	1,2871	2,1242	2,2613	2,3141
Error medio abs, %	2,2985	2,5067	1,9187	1,7154
Coefic de desigualdad de Theil	0,0230	0,0165	0,0167	0,0138
Proporción de sesgo, %	0,0014	0,0024	0,0049	0,0045
Proporción de varianza, %	0,0144	0,0197	0,0446	0,0330
Proporción de covarianza, %	0,9842	0,9779	0,9505	0,9625

TABLA 4. Valores observados y predichos

Periodo	C1			C2			C3			C4		
	Obs.	Pred.	Dif. %									
ene. 2013	114	113,9	0,13%	165	166,7	-1,0%	216	216,9	-0,43%	242	242,8	-0,35%
feb. 2013	118	113,4	3,87%	172	166,4	3,3%	225	216,9	3,58%	252	242,9	3,61%
mar. 2013	118	120,4	-1,99%	172	173,0	-0,6%	225	225,9	-0,42%	252	252,9	-0,34%
abr. 2013	118	118,5	-0,41%	172	173,3	-0,7%	225	228,2	-1,43%	252	255,4	-1,35%
may. 2013	118	117,7	0,28%	181	174,7	3,5%	236	225,9	4,26%	280	252,9	9,69%
jun. 2013	130	117,7	9,47%	181	182,1	-0,6%	236	236,9	-0,40%	280	282,6	-0,94%
jul. 2013	130	131,9	-1,44%	196	182,3	7,0%	272	239,7	11,86%	297	288,0	3,02%
ago. 2013	130	130,2	-0,13%	196	198,2	-1,1%	272	272,9	-0,35%	297	297,4	-0,14%
sept. 2013	130	131,7	-1,28%	200	197,4	1,3%	281	282,1	-0,38%	308	307,2	0,25%

términos de media móvil en los rezagos 5, 11 y 15, respectivamente; evaluando posteriormente variantes de esta especificación. En el caso de C2 (tomada en primeras diferencias), el correlograma muestra rezagos significativos de la FAC y la FACP en los rezagos 8 y 18, de modo que el proceso que sigue la serie se caracterizó inicialmente como un ARIMA (8,18;1;8,18). La serie C3 diferenciada exhibe un correlograma con valores de la FAC significativos en el retardo 2 y FACP con valores significativamente distintos de cero en el retardo 2. Por ello se estimó inicialmente un modelo ARIMA (2; 1; 2). Por su parte, el correlograma de las primeras diferencias de C4 muestra valores distintos de

cero en los rezagos 2 y 4 y la FACP exhibe valores distintos de cero en los retardos 2 y 6. Se estimó entonces un modelo inicial de tipo ARIMA (2,6;1;2,4).

Como se mencionó anteriormente, el EMC y el EMA no expresan nada por sí solos; la tabla 3 los presenta simplemente para fines expositivos. En cualquiera de los 4 modelos elegidos para predecir las series, la mayor parte del error se encuentra en la porción residual (covarianza), sin evidencias de proporciones significativas en las partes sistemáticas (sesgo y varianza). Además, los modelos propuestos tienen una mejor capacidad predictiva que los pronósticos basados en tendencias determinísticas. A juz-

gar por la figura 1, las series podrían ser igualmente pronosticadas ajustando modelos del tipo $Y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + u_t$, donde t representa el factor temporal; β_i son los parámetros autorregresivos y u_t es el ruido blanco. El ajuste de este tipo de modelos comparado tiene peor desempeño predictivo que los modelos ARIMA aquí propuestos, con mayor EMC y EMA.

La estimación de cada uno de los modelos ARIMA, excluyendo las últimas 9 observaciones de la muestra, permite observar que C1 es la serie con la menor brecha promedio entre valores predichos y observados. En términos de la magnitud de los errores de predicción le siguen los modelos ARIMA propuestos para C2 y C4 respectivamente, aunque cada uno registra una observación con una subestimación del precio predicho de 7% y 10%, respecto del observado. Finalmente, el proceso autorregresivo y de media móvil propuesto para C3 exhibe un desempeño predictivo globalmente satisfactorio, incluso con errores de predicción absolutos menores a los de los modelos propuestos para las otras series de precios; aunque en los períodos de saltos incrementales, evidencia cierto retraso subestimando el alza en torno al 12%.

DISCUSIÓN

El rol cada vez más preponderante que el sector forestal está tomando en Argentina, desde el punto de vista económico, social y ambiental, justifica el uso de herramientas cuantitativas como soporte para la toma de decisiones. En este trabajo se propone una herramienta para la predicción de precios para multiproductos forestales (pulpable, aserrable fino, grueso y laminable) de manera que el planificador de operaciones cuente con una herramienta predictiva robusta para la confección del plan cosecha, el cual tiene un horizonte de aproximadamente 12 a 24 meses.

Los modelos autorregresivos de media móvil suponen un patrón aleatorio en los datos de la serie que se pronostica (Jarret, 1987). Este método identifica un posible modelo de una clase general de modelos a través de un proceso iterativo. Una vez que el modelo es elegido, se compara con los datos históricos. El modelo es

adecuado si los residuos siguen un proceso de ruido blanco (Hanke y Reitsch, 1995). Si el modelo elegido no es el adecuado, este proceso debe repetirse hasta encontrarse un modelo satisfactorio (Jarret, 1987). Si bien es deseable realizar el pronóstico utilizando series “largas”, esta sugerencia no siempre es posible debido a limitaciones en el registro de los datos.

Asimismo, tampoco existe un criterio para evaluar el mínimo de observaciones por encima de las cuales se producen estimaciones confiables. Las literatura sobre la temática evidencia una gran disparidad en tamaños muestrales. Oliveira *et al.* (1977), utiliza 144 observaciones semanales mientras que Coelho Junior *et al.* (2006), 335 observaciones, Silva-Soares *et al.* (2008), 73 observaciones, Araujo-Cerdeiro *et al.* (2010), 163 observaciones, todas ellas mensuales.

Asimismo, Koutroumanidis *et al.* (2009), utilizan 42 observaciones anuales. Con base en esta apreciación, es posible postular que la amplitud muestral aquí utilizada (135 observaciones mensuales) se encuentra dentro del intervalo habitual de los estudios aplicados en la temática.

Por otro lado, la mayor parte de los modelos ARIMA propuestos para pronosticar precios (de cualquier clase de productos) suelen mostrar coeficientes significativos cercanos al periodo actual; es decir, términos AR o MA no superiores en general al rezago 2 o 3. En las series aquí analizadas, sin embargo, se observa que C1 y C2 contienen coeficientes significativos en los rezagos de orden 8, 11 y 15. Habitualmente esto suele ser atribuido a factores estacionales. Además, los gráficos estacionales tradicionales (que calculan la media temporal para cada mes) no muestran una marcada estacionalidad de ciclo mensual. Todo ello podría ser síntoma de la existencia de otro tipo de estacionalidad diferente a la de ciclo mensual en las series de precio de C1 y C2. La caracterización de ese tipo de estacionalidad excede el objetivo del presente trabajo y puede constituir una ruta de análisis de futuros trabajos enfocados en dinámicas de cotizaciones de variedades de madera pulpables y aserrado fino.



CONCLUSIONES

Los modelos ARIMA tienen, por un lado, la ventaja de pronóstico de series basadas en sus propios valores pasados, sin necesidad de recurrir a información adicional. Si la metodología aplicada sigue las recomendaciones de la literatura metodológica, suelen producir ajustes altamente satisfactorios con bajo costo de recolección de datos. En contrapartida, este tipo de modelos exhibe un desempeño pobre en predicciones de largo plazo y en anticipación de movimientos inusuales de las series (Chu, 1978). Esto se debe a que la estimación de modelos ARIMA requiere series estacionarias y sin grandes saltos. Las variaciones en la dinámica temporal de las series deben ser explicadas con los denominados “fundamentos” (es decir, determinantes estructurales y de corto plazo diferentes de los valores previos de las series).

Los modelos de pronóstico propuestos lucen satisfactoriamente en el corto plazo (por ejemplo, generando predicciones a 9 meses) reafirmando lo obtenido por otros autores referidos oportunamente. Las series de precios presentan predicciones con errores estables entre 1% y 2%. Sin embargo, en algunos casos los errores de predicción de los modelos propuestos registran valores de magnitud considerable (entre 7% y 12%) en períodos en los que los precios observados experimentaron alzas incrementales. Asimismo, es posible que las series mensuales de precios de C1 y C2 contengan algún ciclo estacional no habitual que merece ser estudiado con mayor detalle.

La disponibilidad de series temporales de larga duración permite perfeccionar los pronósticos al proporcionar más información para caracterizar los procesos que describen el comportamiento de los precios. A su vez, aportarían más información para identificar con mayor precisión la existencia de ciclos estacionales específicos a ciertos productos y actividades. Por ello, resulta de suma importancia establecer políticas de registro sistemático y oportuno de precios, por su valor potencial como herramienta predictiva.

REFERENCIAS

Araujo-Cordeiro, S., N. Silva-Soares, M. Braga y M. Lopez da Silva. 2010. Previsões do preço de exportação da madeira

serrada de *Pinus* no Brasil. *Scientia Forestalis* 38(36): 205-214.

Arce, J. 1997. Um sistema de programação do transporte principal de multiproductos florestais visando a minimização de costos. Tesis de Maestría. Universidade Federal do Paraná. Curitiba, Brasil. 98 p.

Box, G. y G. Jenkins. 1976. Time series analysis: Forecasting and control. Revised ed. Holden-Day. California. EUA. 575 p.

Brockwell, P.J. y R.A. Davis. 2002. Introduction to time series and forecasting. 2a ed. Springer, Nueva York. 469 p.

Brockwell, P.J. y R.A. Davis. 1987. Time series: Theory and methods. 2a ed. Springer. Nueva York. 519 p.

Brooks, C. 2008. Introductory econometrics for finance. 2a ed. Cambridge University Press. Cambridge, Reino Unido. 648 p.

Buongiorno, J. y J.K. Gilless. 1987. Forest management and economics. 1a ed. Macmillan Publishing. Nueva York. 285 p.

Buongiorno, J. y J.K. Gilless. 2003. Decision methods for forest resource management. 1a ed. Academic Press. California. 439 pp.

Chu, K.Y. 1978. Short-run forecasting of commodity prices: An application of autoregressive moving average models. *IMF Staff Papers* 25(1):90-111.

Coelho Junior, L., J. Rezende, N. Calegario y M. Lopez da Silva. 2006. Análise longitudinal dos preços do carvão vegetal, no estado de Minas Gerais. *Revista Árvore* 30(3):429-438.

Dickey, D. y W. Fuller. 1981. Likelihood ratio statistics for autoregressive time series with a unit root. *Econométrica* 49(4):1057-1072.

Dickey, D. y W. Fuller. 1979. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association* 74(366):427-431.

Enders, W. 2009. Applied econometric times series. 3a ed. Wiley. Nueva Jersey. 544 p.

Fernández Manso, A., J. Delgado y C. Quintano. 2001. Predicción de evolución de la vegetación a partir de análisis de las series temporales del NDVI. Acta IX Congreso Nacional de Teledetección. Lleida, España. 114-117 p. <http://www.aet.org.es/congresos/ix/Lleida22.pdf>

- Gong, P. 1999. Optimal harvest policy with first-order autoregressive prices process. *Journal of Forest Economics* 5(3):413-439.
- Granger, C.W. y P. Newbold. 1986. Economic forecasting; Time-series analysis; Mathematical models. 2a ed. Academic Press. Orlando. EUA. 338 p.
- Hanke, J. y A. Reitsch. 1995. Business forecasting. 5a ed. Prentice Hall. Boston. 605 p.
- Jarret, J. 1987. Business forecasting methods. 1a ed. Blackwell Publishers. Oxford. 240 pp.
- Koutroumanidis, T., K. Loannou y G. Arabatzis. 2009. Predicting fuelwood prices in Greece with the use of ARIMA models, artificial neural networks and hybrid ARIMA-ANN model. *Energy Policy* 37(9):3627-3634.
- Leskinen, P. y J. Kangas. 1998. Modelling and simulation of timber prices for forest planning calculation. *Scandinavian Journal of Forest Research* 13(1):469-476.
- Mei, B., M. Clutter y T. Harris. 2010. Modeling and forecasting pine sawtimber stumpage prices in the US South by various time series models. *Canadian Journal of Forest Research* 40(8):1506-1516.
- Oliveira, R., J. Buongiorno y A. Kmiotek. 1977. Time series forecasting models of lumber cash, futures and basis prices. *Forest Science* 23(2):268-280.
- Silva-Soares, N., M. Lopez da Silva, J.L. Pereira de Rezende, J. Eustaquio de Lima y K. Adame de Carvalho. 2010. Elaboração de modelo de previsão de preço da madeira de *Eucalyptus* spp. *Cerne* 16(1):41-52.
- Silva-Soares, N., M. Lopez da Silva, J. Eustaquio de Lima y S. Araujo Cordeiro. 2008. Análise de Previsões do preço da borracha natural no Brasil. *Scientia Forestalis* 36(80):285-294.
- SIFIP (Sistema de Información Foresto-Industrial Provincial). 2012. <http://extension.facfor.unam.edu.ar/sifip/index.html>
- Viego, V. y D. Broz. 2012. Un modelo de predicción de precios forestales basados en la metodología Box-Jenkins. Acta XXVI Jornadas Técnicas Forestales de Entre Ríos, Argentina.
- Yin, R.S. 1999. Forecasting short-term timber prices with univariate ARIMA models. *South Journal of Applied Forestry* 23(1):53-58.

Manuscrito recibido el 12 de abril de 2012.
Aceptado el 10 de febrero de 2014.

Este documento se debe citar como:
Broz, D.R. y V.N. Viego. 2014. Predicción de precios de productos de *Pinus* spp. con modelos ARIMA. *Madera y Bosques* 20(1):37-46.