

PRONÓSTICOS DEL VOLUMEN DE VENTA DE MANGO MEDIANTE MÉTODOS UNIVARIADOS EN SERIES TEMPORALES

MANGO SALES VOLUME FORECAST BY USING UNIVARIATE METHODS IN TIME SERIES

Autor: Reinaldo Alvarez Carrera

Institución: Empresa Agroindustrial Ceballos, Ciego de Ávila, Cuba

Correo electrónico: esp1_inform@dcballos.co.cu

RESUMEN

La elaboración de pronósticos a menudo se puede ver afectada por la insuficiencia o escasez de información para construir modelos explicativos y la carencia de observaciones para construir modelos de pronóstico con datos de frecuencia anual. Por ello, esta investigación emplea métodos univariados para la elaboración de pronósticos ante la escasez de información y usa pronósticos de frecuencia mensual para ofrecer soluciones a las problemáticas inicialmente planteadas. En este sentido, se utilizaron ocho métodos de pronóstico univariados, donde, debido a las características de las ventas, dos de ellos fueron métodos especializados para pronosticar en presencia de demanda intermitente. Además, se propuso una medida de evaluación de pronósticos para el caso en que se desee obtener la importancia combinada de los pronósticos a más de un nivel de agregación. Los modelos ganadores fueron un Alisamiento Exponencial con componente de error multiplicativa, tendencia aditiva y estacionalidad aditiva y un Alisamiento Exponencial con componente de error multiplicativa, tendencia aditiva-amortiguada y estacionalidad aditiva, cuyos valores para la medida de evaluación propuesta fueron de 11464.41 y 16883.80 respectivamente y las sumas de los pronósticos de la etapa esperada de venta solo se desviaron en un 3.49 % y un 1.19 % respectivamente.

Palabras clave: Mango como fruta fresca, Medidas de error, Modelos univariados, Pronósticos de ventas, Series temporales.

ABSTRACT

Forecasting can often be affected by insufficiency or shortage of information to build explanatory models and a deficiency of observations to build forecasting models with annual data. For this reason, this research uses univariate methods to prepare forecasts in presence of information shortage and uses monthly frequency forecasts to offer solutions to the problems initially mentioned. In this sense, eight univariate

forecasting methods were used, where, due to the characteristics of sales, two of them were specialized methods to forecast in the presence of intermittent demand. In addition, a forecast evaluation measure was proposed for the case in which it is desired to obtain the combined importance of the forecasts at more than one level of aggregation. The winning models were an Exponential Smoothing with a multiplicative error component, additive trend and additive seasonality and an Exponential Smoothing with a multiplicative error component, additive-damped trend and additive seasonality, whose values for the proposed evaluation measure were 11464.41 and 16883.80 respectively, and the sums of the forecasts for the expected sales season were only deviated by 3.49 % and 1.19 % respectively.

Keywords: Error measures, Mango as fresh fruit, Sales forecasting, Time series, Univariate models.

INTRODUCCIÓN

Actualmente, los pronósticos han ganado mucho en frecuencia y diversidad de usos, desde predecir comportamientos de fenómenos naturales hasta la próxima palabra que escribirá un usuario en su teléfono móvil inteligente. El hecho de poder anticiparse con determinado nivel de certidumbre a los acontecimientos futuros, permite tener respuestas más rápidas y precisas ante escenarios venideros y así centrarse mayormente en los comportamientos futuros más probables como una guía para organizar mejor el personal y los recursos en el entorno empresarial.

Elliott, Granger y Timmermann (2006) plantean que los pronósticos hacen uso de la información que se tiene disponible, con el objetivo de razonar acerca del posible comportamiento de sucesos futuros. Agregan que estas informaciones pueden ser: suposiciones, modelos formales, datos, etc. y que técnicamente, se refieren a lo que puede decirse sobre el futuro a partir de lo que se conoce hasta el presente.

El tema relacionado con los pronósticos es muy amplio y como afirma Gujarati y Porter (2010), sólo para el caso de los pronósticos económicos se han escrito libros especializados. A este tipo de pronósticos se suman los de muchas otras disciplinas de las ciencias técnicas y sociales y el incremento en el uso de métodos de aprendizaje automatizado (*machine learning*).

Esta investigación tiene un enfoque relacional y pretende construir modelos univariados de series de tiempo que puedan generar pronósticos precisos sobre la cantidad de mango como fruta fresca vendida por la Empresa Agroindustrial

Ceballos. La elección se debe fundamentalmente a que los métodos univariados para series de tiempo permiten construir modelos de pronósticos usando sólo las mediciones de una variable y en ocasiones no es posible tener acceso a mediciones meteorológicas o de otro tipo para plantear modelos explicativos.

Inicialmente, se investigó acerca del desempeño en los pronósticos de los métodos estadísticos y los métodos de aprendizaje automatizado (AU). El estudio realizado por Makridakis, Spiliotis y Assimakopoulos (2018) comparó el desempeño de ambos grupos de métodos, donde se elaboraron pronósticos para un total de 1045 series de tiempo de frecuencia mensual, que fueron usadas en la competencia de pronósticos M3 (Makridakis y Hibon, 2000). Aquí se demostró que los métodos estadísticos dominaron en todos los horizontes de pronósticos, pues mostraron los mejores valores para las medidas de evaluación de pronósticos que fueron utilizadas en el estudio. Incluso, pudieron observar que los métodos de AU incurrieron en un costo computacional considerablemente superior.

Aunque otro estudio (Cerqueira, Torgo y Soares, 2019) encontró resultados donde se comprobó que para series de tiempo con mayor cantidad de observaciones que las usadas en Makridakis, Spiliotis y Assimakopoulos (2018), los métodos de AU tuvieron en parte mejor desempeño. Otra reciente investigación (Makridakis, Hyndman y Petropoulos, 2020) afirma que los métodos de AU demostraron ser, hasta el momento de su terminación, menos precisos que los métodos estadísticos en los resultados de los pronósticos. Este último estudio, incluyó el análisis de la reciente competencia internacional de pronósticos M4 (Petropoulos y Makridakis, 2020; Makridakis, Spiliotis y Assimakopoulos, 2020), la cual utilizó alrededor de 100000 series de tiempo con diversas longitudes y 61 métodos de pronósticos.

La literatura científica acerca de métodos estadísticos para pronósticos que permiten hacer uso del enfoque univariado contiene trabajos como (Fildes *et al.*, 1998) donde se utilizaron los métodos siguientes: Naive1, *Single Exponential Smoothing*, *Holt's Exponential Smoothing* (Makridakis *et al.*, 1982), *Damped Exponential Smoothing* (Gardner y McKenzie, 1985), *Robust Trend* (Grambsch y Stahel, 1990), ARIMA (método automático) (Stellwagen y Goodrich, 1991) y ARARMA (Parzen, 1982).

Otro trabajo (Gooijer y Hyndman, 2005) realiza una amplia revisión y menciona los métodos de alisamiento exponencial, donde especifica que los más usados son: *Simple Exponential Smoothing*, *Holt's Linear Method*, *Holt-Winters' Additive Method*

y *Holt-Winters' Multiplicative Method* (Hyndman et al., 2002). También, nombra el método conocido como Filtro de Kalman (*Kalman's Filter*) (Harvey, 1990), los modelos ARIMA univariados (Box y Jenkins, 1976) y otros modelos autorregresivos como *self-exciting threshold AR* (SETAR) (Tong, 1983), *continuous-time threshold AR* (CTAR) (Brockwell y Hyndman, 1992), *smooth transition AR* (STAR) (Sarantis, 2001) y *threshold AR(1)* (Franses, Paap y Vroomen, 2004).

Adicionalmente, Kourentzes y Athanasopoulos (2020) afirman que el método ETS (*Error-Trend-Seasonal* o *Exponential Smoothing*) (Hyndman et al., 2008), ha sido ampliamente usado por brindar una precisión de pronósticos relativamente buena, además de confiabilidad y transparencia.

Una situación que presenta este estudio es que las observaciones de frecuencia anual disponibles no suman la cantidades aconsejadas para aplicar métodos de Alisamiento Exponencial (30 observaciones) (Kourentzes y Athanasopoulos, 2020) y basados en la Teoría Box-Jenkins (50 observaciones pero se recomiendan 100) (Box y Jenkins, 1976). Esto conlleva a replantear el análisis usando observaciones de frecuencia mensual y así sobrepasar las 100 observaciones.

Por otra parte, el mango es un cultivo de temporada (solamente se puede cosechar durante una etapa del año) y ello condiciona que sus ventas sean intermitentes. La **Figura 1** muestra que la etapa de cosecha de la planta (crecimiento del fruto) en nuestro país está comprendida desde los meses abril hasta septiembre (IIFT, 2005).

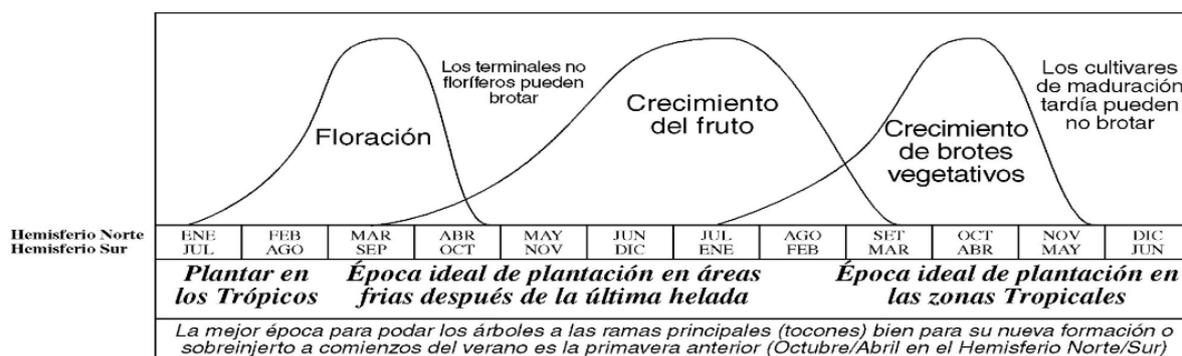


Figura 1 Ciclo del fenológico del mango. Tomado de (IIFT, 2005).

Por tanto, fue necesario realizar una revisión bibliográfica acerca del uso de métodos univariados en la elaboración de pronósticos y de métodos empleados para pronosticar procesos con demanda intermitente en datos de series de tiempo.

Kourentzes y Athanasopoulos (2020) presenta una revisión muy completa y actualizada sobre la demanda intermitente o demanda esporádica y exponen que la mayoría de los métodos son modificaciones al método original propuesto por Croston, (1972) o grandemente inspiradas por este. También, menciona otros métodos para demanda intermitente como Bootstrapping (Syntetos, Zied Babai y Gardner, 2015), redes neuronales y AU (Kourentzes, 2013; Nikolopoulos, Babai y Bozos, 2016) y los métodos basados en modelos, entre los cuales cita a Svetunkov y Boylan (2017). No obstante, proponen un método más apropiado que los anteriores para generar pronósticos de demanda intermitente con tendencia y estacionalidad. Este método está basado en Jerarquías Temporales (JT) (Athanasopoulos *et al.* 2017) y programado en un paquete para el Software R (Hyndman *et al.*, 2018) con el nombre THIEF (*Temporal Hierarchical Forecasting*). El presente trabajo construye ocho modelos usando métodos de Alisamiento Exponencial, métodos ARIMA y de JT con el objetivo de encontrar el de mayor precisión en los pronósticos de las ventas de mango.

MATERIALES Y MÉTODOS

La presente investigación utilizó los datos de venta de mango como fruta fresca a entidades del turismo, por parte de la Empresa Agroindustrial Ceballos. Los valores históricos se encuentran desde el año 2003 hasta el año 2016, de entre los cuales seleccionó el intervalo 2003 – 2015 para realizar la construcción de los modelos y el año 2016 fue usado para comprobar la calidad de los pronósticos.

Se trabajó con una frecuencia mensual para los datos, con el objetivo de cubrir los requerimientos necesarios para plantear modelos ETS y ARIMA.

Las variables usadas para el análisis fueron: la cantidad total de kg de mango vendidos por cada mes (*cantidad*) y una variable binaria que representa el uso o no de una cámara de maduración (*cam_mad*) antes de enviar el producto al cliente. La tabla 1 muestra las estadísticas de ambas variables.

Tabla 1 Estadísticas de las variables cantidad y cam_mad.

Estadísticas	cantidad	cam_mad
Media	6819.491	0.071429
Mediana	0.000000	0.000000
Máximo	64584.73	1.000000
Mínimo	0.000000	0.000000

Desviación estándar	12376.52	0.258309
Cant. Observaciones	168	168

Se escogieron como herramientas de análisis dos softwares: primeramente el Eviews en su versión 11 (IHS Markit, 2019a) para graficar la serie *cantidad*, en la aplicación de test estadísticos, filtros, la construcción de modelos automáticos ETS y ARIMA y la obtención de gráficos de pronósticos. En segundo lugar, se escogió el Software R (R Core Team, 2019) (versión de servidor 3.6.3), con el paquete THIEF (versión 0.3 como parte de la versión 8.11 del paquete forecast (Hyndman ... *et al.*, 2018)) para aplicar los métodos especializados en pronósticos de demanda intermitente.

Se comenzó con el análisis del gráfico de la serie *cantidad* (**Figura 2**).

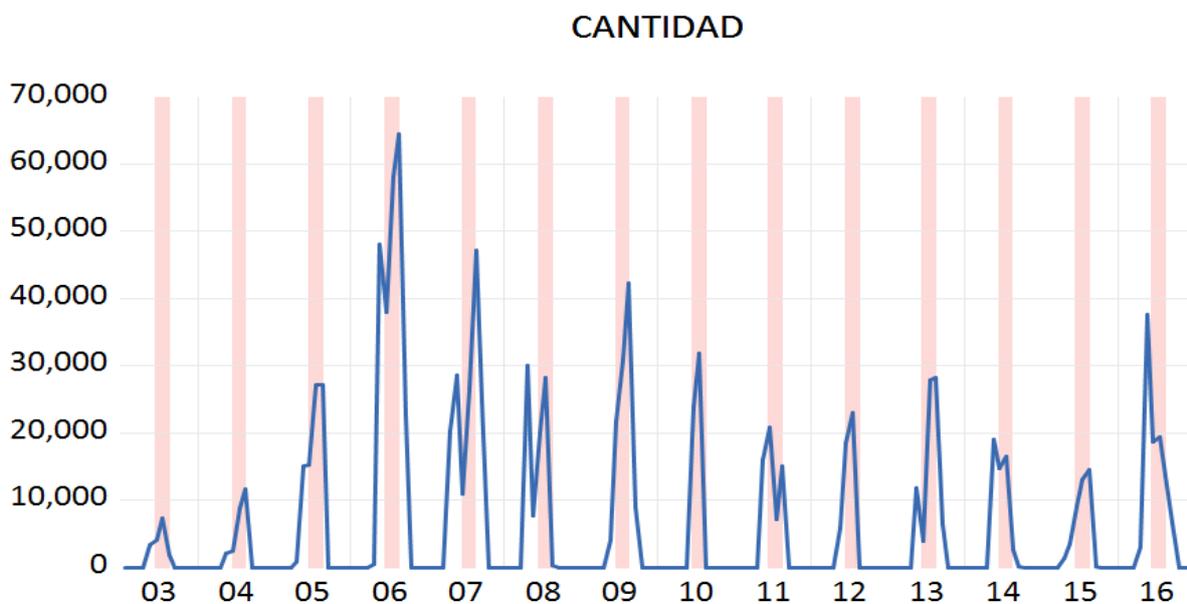


Figura 2 Gráfico de la variable cantidad para los años 2003 a 2016. Captura tomada de Eviews.

Se confirmó que el comportamiento de las ventas era consistente con la etapa donde hay disponibilidad de frutos según el patrón mostrado en la **Figura 1**. Sin embargo, el área sombreada en cada año corresponde a los meses de mayor demanda esperada (junio hasta agosto) y se observan los siguientes comportamientos irregulares: los años 2006 y 2007 muestran una demanda muy alta y los años 2008, 2011 y 2014 muestran una demanda mayor, fuera de los meses de mayor demanda esperada.

Los expertos de la empresa argumentaron que los altos valores de venta en 2006 y 2007 se debían al uso de una cámara de maduración, lo que permitió un mejor aprovechamiento del producto en su forma fresca. Por esta razón, se consideró incluir la variable *cam_mad* en algunos modelos.

Luego, fue necesario investigar la existencia de una tendencia en la serie y se aplicó el filtro de Hodrick-Prescott (Hodrick y Prescott, 1997) implementado en Eviews. El proceso de filtrado mostró una tendencia que se asemeja más a la forma amortiguada (*dampened*) que a la forma lineal (*linear*).

También se analizó la variable dependiente *cantidad* en búsqueda de raíces unitarias, para determinar si estaba apta para aplicar un análisis ARIMA. La estacionariedad de la serie se comprobó mediante la prueba de raíces unitarias Augmented-Dickey Fuller (Dickey y Fuller, 1979) con intercepto y tendencia. También, se corroboró que no existía evidencia para negar la estacionariedad de la serie al aplicar la prueba de KPSS (Kwiatkowski *et al.*, 1992) con intercepto y tendencia. Estos resultados mostraron que la variable *cantidad* era apropiada para realizar análisis ARIMA sin necesidad de aplicarle transformaciones.

Posteriormente, a partir de la bibliografía revisada sobre métodos univariados para realizar pronósticos, se escogió hacer uso del framework ETS (IHS Markit, 2019b) que se encuentra implementado en el software econométrico Eviews. Este framework permite especificar la búsqueda automatizada de modelos ETS hallando las combinaciones de las componentes de error (*error*), tendencia (*trend*) y estacionalidad (*season*), conjuntamente con el ciclo estacional, el criterio de selección y otros parámetros especificados. Como resultado, construye un resumen que muestra un ranking de los mejores modelos en base al criterio de selección especificado, junto con los valores de pronóstico y sus gráficos correspondientes.

Por otra parte, determinó construir modelos ARIMA mediante la opción Pronósticos Automáticos ARIMA (*Automatic ARIMA Forecasting*) implementada en el Eviews. Este proceso obtiene un grupo de modelos mediante la combinación de los términos anteriormente especificados y construye un resumen que contiene un ranking de modelos seleccionados en cuando al criterio de selección que se haya especificado para la búsqueda automática. También, muestra una tabla con los valores de pronósticos y e incluye sus gráficos asociados.

Por último, se plantearon modelos de JT usando la metodología THIEF. Este método recibe como entrada un objeto de tipo series de tiempo y calcula los pronósticos en dependencia de los parámetros especificados a la función *thief*. Luego, devuelve como salida otro objeto que contiene los valores pronosticados.

RESULTADOS Y DISCUSIÓN

Al aplicar el proceso automatizado de obtención de modelos ETS se obtuvo un grupo de modelos, de los cuales se seleccionaron tres, por las razones que se exponen a continuación:

- Modelo 1: ETS con componente de error multiplicativo, ninguna tendencia y estacionalidad aditiva (ETS M, N, A). Este fue el modelo ganador según el criterio de selección.
- Modelo 2: ETS con componente de error multiplicativo, tendencia aditiva y estacionalidad aditiva (ETS M, A, A). Este fue el segundo lugar, pero mostraba una tendencia aditiva, además de estacionalidad, lo cual se asemeja al proceso a pronosticar y se consideró apropiado incluirlo.
- Modelo 3: ETS con componente de error multiplicativo, tendencia aditiva-amortiguada y estacionalidad aditiva (ETS M, AD, A). Este modelo es semejante al segundo, pero la tendencia se ajusta más a la observada después de aplicar el filtro de Hodrick-Prescott.

El modelo 4 fue el mejor modelo obtenido mediante el proceso automatizado para obtener modelos ARIMA con las siguientes especificaciones:

- Búsqueda de hasta 12 términos AR (autorregresivos)
- Hasta 12 términos MA (medias móviles o *moving average*)
- 1 término SAR (autorregresivo estacional o *seasonal autorregresive*)
- 1 término SMA (medias móviles estacional o *seasonal moving average*)
- Periodicidad de 12 tiempos.

El modelo 5 fue el mejor modelo obtenido mediante el proceso automatizado para obtener modelos ARIMA con especificaciones iguales a las del modelo 4, pero en la búsqueda se incluyó como regresor la variable *cam_mad*. Esta inclusión se tuvo en cuenta para modelar el uso de la cámara de maduración.

El modelo 6 se obtuvo de forma manual, a partir del análisis del correlograma de la variable *cantidad* y la especificación de los términos AR y MA siguiendo la metodología expuesta en (Gujarati y Porter, 2010). Se identificaron e incluyeron

todos los términos influyentes mostrados en el correlograma, dos términos estacionales (un SAR y un SMA porque el cultivo tiene una característica estacional) y el regresor *cam_mad*. Luego, se eliminaron los términos que se mostraban menos significativos en la regresión y que después de reestimar la ecuación, mantenían el correlograma de los residuales como ruido blanco, aumentaban el R^2 ajustado y disminuían el valor de *SIGMASQ* (varianza del error cuando el método de estimación especificado es el de máxima verosimilitud) (Figura 3).

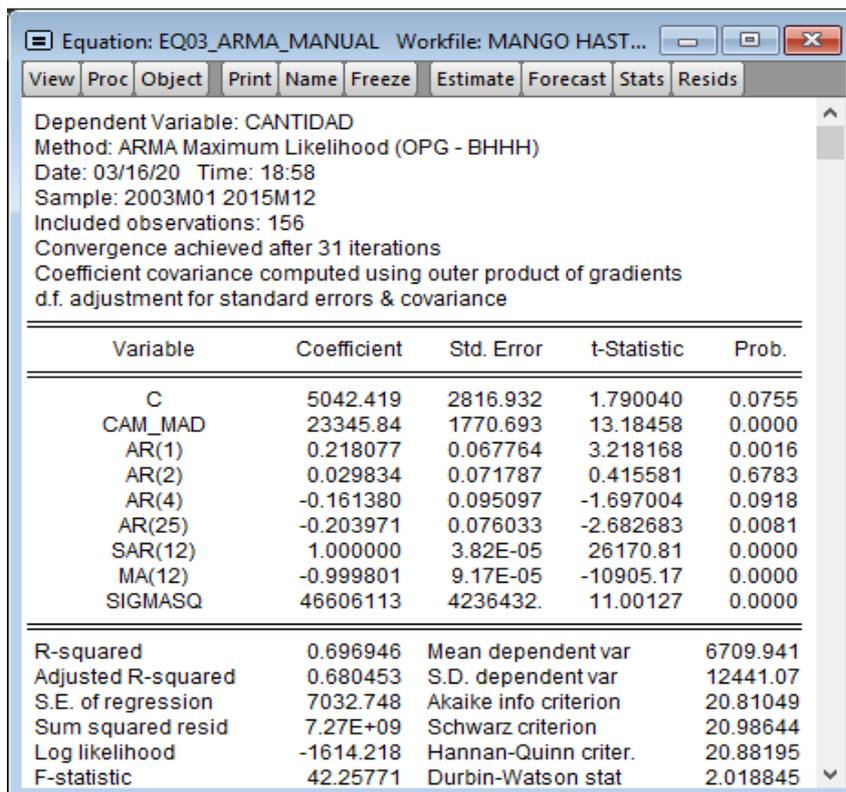


Figura 3 Modelo ARIMA obtenido de forma manual según la metodología expuesta en (Gujarati y Porter, 2010).

Los modelos 7 y 8 fueron obtenidos usando la metodología THIEF con métodos de pronóstico basados en ETS automático y ARIMA automático respectivamente.

La Tabla 2 muestra un resumen de las especificaciones de cada modelo según fueron hechas sus softwares correspondientes. Los primeros 3 modelos muestran la especificación y los siguientes muestran los comandos usados para generarlos.

Tabla 2 Especificación de los modelos de pronóstico.

Modelo	Especificación	Software
1	Error – M, Tendencia – N, Estacionalidad – A	Eviews
2	Error – M, Tendencia – A, Estacionalidad – A	Eviews

3	Error – M, Tendencia – AD, Estacionalidad – A	Eviews
4	ls cantidad c ar(1) ar(2) ar(3) ar(4) ar(5) ar(6) sar(12) ma(1) ma(2) ma(3) sma(12)	Eviews
5	ls(df) cantidad c cam_mad ar(1) ar(2) ar(3) sar(12) ma(1) ma(2) sma(12)	Eviews
6	ls(optmethod=opg, df) cantidad c cam_mad ar(1) ar(2) ar(4) ar(25) sar(12) sma(12)	Eviews
7	fc_ets_train <- thief(ts_mango_train, m = frequency(ts_mango_train), h = frequency(ts_mango_train), usemodel = "ets")	R
8	fc_arima_train <- thief(ts_mango_train, m = frequency(ts_mango_train), h = frequency(ts_mango_train), usemodel = "arima")	R

Después de tener conformados los 8 modelos, se procedió a la evaluación de los pronósticos y fue necesario definir la medida de evaluación de pronósticos a utilizar para comparar la calidad de los mismos.

Un estudio en Hyndman (2006) aprueba el uso de MAE (*Mean Absolute Error* o Error Absoluto Medio), debido a que permite percibir sin dificultad la diferencia entre los pronósticos y los valores reales y no tiene inconvenientes para ser usada con datos de series de tiempo pertenecientes a demanda intermitente. Por otra parte, IHS Markit (2019c) aconseja usar MAE para comparar modelos diferentes obtenidos a partir de la misma serie de tiempo.

No obstante, el problema que se trató tiene la particularidad de que puede interesar no sólo el pronóstico mensual, sino también el volumen total del año. Entonces se plantea un método para calcular una medida basada en MAE, la cual se nombrará THMAE por *Temporal Hierarchies' Combined Mean Absolute Error* o Error Absoluto Medio Combinado de Jerarquías Temporales.

Este cálculo parte del principio de que es posible construir con seguridad los datos de niveles de agregación mayores (frecuencias temporales menores, por ejemplo: anual) a partir de los datos de niveles de agregación menores (frecuencias temporales mayores, por ejemplo: mensual). Entonces, se obtiene el MAE del menor de los niveles de agregación y se procede a calcular los MAE de los niveles de agregación superiores en forma escalada. Esto se realiza mediante la sumatoria (en dependencia de la frecuencia) de los valores reales y los valores de pronóstico del intervalo de pronóstico en el nivel de agregación anterior para construir los valores reales y valores de pronóstico para el nivel de agregación actual. Después, se aplica la fórmula convencional para calcular MAE a este nivel y se repite el proceso con

todos los niveles siguientes hasta que se hayan calculado los MAE de todos los niveles de agregación. Por ejemplo, para el modelo 1 se tienen el proceso siguiente:

Tabla 3 Construcción del nivel de agregación anual a partir del nivel de agregación mensual.

Nivel de agregación	Real	Pronósticos
Mensual	0	-1508.23
	0	-1450.90
	0	-1409.28
	2939	3208.97
	37563.6	12340.15
	18695	16015.87
	19482	23480.47
	13692	18930.21
	6552	5389.94
	0	496.67
	0	-300.53
	0	-671.70
	0	-1508.23
Total	98923.6	74521.65
Anual	98923.6	74521.65
MAE	24401.95	

Luego se combinan en una suma ponderada para determinar los mejores pronósticos. La especificación de la medida puede tener la siguiente forma:

$$THCMAE_{mensual,anual} = c_{mensual} \cdot MAE_{mensual} + c_{anual} \cdot MAE_{anual} \quad (1)$$

donde $c_{mensual}$ y c_{anual} son coeficientes que representan pesos asignados al MAE de cada frecuencia temporal e indican el nivel de importancia en el cálculo combinado. Siendo $0 \leq c_{mensual} \leq 1$, $0 \leq c_{anual} \leq 1$ y $c_{mensual} + c_{anual} = 1$.

La ecuación (1) se puede escribir de forma general usando la siguiente notación:

$$THCMAE_{f_1, \dots, f_n} = \sum_{i=1}^n c_i \cdot MAE_{f_i} \quad (2)$$

Donde c_i son los coeficientes que representan los pesos asignados al MAE de cada frecuencia temporal y que indican el nivel de importancia en el cálculo combinado, con $i = 1, 2 \dots$, con $0 \leq c_i \leq 1$ y $\sum_{i=1}^n c_i = 1$. Siendo n el número total de frecuencias

temporales usadas y las f_i denotan la frecuencia temporal i , con $i = 1$ para la frecuencia temporal mayor (ejemplo: horaria) e $i = n$ para la frecuencia temporal menor (ejemplo: anual), aunque se puede invertir el orden para comodidad de quien use la notación.

Se reconoce que los MAE reales obtenidos mediante la elaboración pronósticos a niveles de agregación superiores al nivel base, no necesariamente coinciden con los MAE de los niveles de agregación construidos porque, aunque los valores reales del intervalo coincidan, es muy probable que los pronósticos no lo hagan. No obstante, este planteamiento se considera como una alternativa viable ante la escasez de observaciones para obtener pronósticos confiables.

El caso analizado, tuvo una asignación de un 30 % (0.3) de importancia para la precisión de los pronósticos mensuales y de un 70 % (0.7) para la precisión de los pronósticos anuales construidos. La Tabla 4 muestra el resumen de las medidas utilizadas para determinar el mejor modelo.

Tabla 4 Medidas de error para los pronósticos del año 2016.

Modelo	Nombre	MAE (mensual)	MAE (anual)	THCMAE (0.3, 0.7)
1	ETS M, N, A	3700.72	24401.95	18191.58
2	ETS M, A, A	5862.88	13865.06	11464.41
3	ETS M, AD, A	6043.98	21529.43	16883.80
4	ARIMA Auto	4049.11	41965.97	30590.91
5	ARIMA Auto (cam_mad)	4176.77	28487.82	21194.50
6	ARIMA manual (cam_mad)	4159.04	35578.00	26152.31
7	THIEF ETS	4481.82	39966.34	29320.98
8	THIEF ARIMA	5112.37	42097.10	31001.68

Los resultados mostraron que el modelo 2, basado en ETS con componente de error multiplicativa, tendencia aditiva y estacionalidad aditiva, fue el de mejor resultado con un THCMAE de 11464.41, seguido del modelo 3 basado en ETS con componente de error multiplicativa, tendencia aditiva-amortiguada y estacionalidad aditiva, que presentó un THCMAE de 16883.80.

Una comprobación adicional, mostró que la suma de los valores de pronósticos en la etapa de ventas esperada (abril hasta septiembre) de 2016 fueron de 95467.09 y 100101.52 para los modelos 2 y 3 respectivamente, contra un real de 98923.6, para un 3.49 % y un 1.19 % de desviación, a pesar de que el 2016 fue atípico (**Figura 2**).

Es importante destacar que estos resultados no demuestran que los métodos ganadores son mejores que los métodos THIEF, pues la mayor potencialidad de THIEF está en pronosticar demanda intermitente irregular, mientras que en este caso se tiene una demanda intermitente, pero con un comportamiento bastante regular. Esta investigación muestra que el comportamiento de los modelos 2 y 3 fue el mejor para las condiciones analizadas y haciendo uso de una medida que combina la importancia de varios niveles de agregación, construidos a partir del nivel base.

CONCLUSIONES

El uso de la frecuencia temporal y los modelos de pronóstico univariados resultaron opciones útiles para obtener las predicciones mensuales de las ventas de mango como fruta fresca en la Empresa Agroindustrial Ceballos. De esta forma, se pudo pronosticar ante escasez de información e insuficiente cantidad de observaciones para la elaboración de pronósticos anuales. Por otra parte, la medida propuesta resultó ser útil para identificar modelos de interés, en este caso, dando un 70 % de importancia a los que lograran un acumulado anual cercano al real y un 30 % de importancia a la precisión de los valores pronosticados por meses.

Finalmente, se identificaron dos modelos que mostraron los valores menores de la medida propuesta para evaluación de pronósticos y se observaron resultados con desviaciones de solo un 3.49 % y un 1.19 % para la etapa de ventas esperada.

REFERENCIAS BIBLIOGRÁFICAS

- ATHANASOPOULOS, G. ... [et al.] (2017). Forecasting with temporal hierarchies. *European Journal of Operational Research*, Vol. 262, No. 1, pp. 60-74.
- BOX, G.E.P. y JENKINS, G.M.: (1976). Time series analysis: forecasting and control. Revised. San Francisco: Holden-Day.
- BROCKWELL, P.J. y HYNDMAN, R.J. (1992). On continuous-time threshold autoregression. *International Journal of Forecasting*, Vol. 8, No. 2, pp. 157–173.
- CERQUEIRA, V., TORGO, L. y SOARES, C. (2019). Machine Learning vs Statistical Methods for Time Series Forecasting: Size Matters.
- CROSTON, J.D. (1972). Forecasting and Stock Control for Intermittent Demands. *Journal of the Operational Research Society*, Vol. 23, No. 3, pp. 289–303.
- DICKEY, D.A. y FULLER, W.A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical*

- Association*, Vol. 74, No. 366a, pp. 427-431.
- ELLIOTT, G., GRANGER, C.W.J. y TIMMERMANN, A. (2006). Handbook of economic forecasting. First Ed. Amsterdam: Elsevier North-Holland.
- FILDES, R. ...[et al.] (1998). Generalising about univariate forecasting methods: further empirical evidence. *International Journal of Forecasting*, Vol. 14, pp. 339-358.
- FRANSES, P.H., PAAP, R. y VROOMEN, B. (2004). Forecasting unemployment using an autoregression with censored latent effects parameters. *International Journal of Forecasting*, Vol. 20, No. 2, pp. 255–271.
- GARDNER, E. y MCKENZIE, E. (1985). Forecasting Trends in Time Series. *Management Science*, Vol. 31, pp. 1237-1246.
- GOOIJER, J.G. de y HYNDMAN, R.J.(2005). 25 Years of IIF Time Series Forecasting: A Selective Review. Monash, Australia: 2005. 12/05.
- GRAMBSCH, P. y STAHEL, W.A. (1990). Forecasting demand for special telephone services: A case study. *International Journal of Forecasting*, Vol. 6, No. 1, pp. 53-64.
- GUJARATI, D.N. y PORTER, D.C. (2010). *Econometría Quinta Edición*.
- HARVEY, A.C. (1990). Forecasting, structural time series models and the Kalman filter. Cambridge, Massachusetts: Cambridge University Press.
- HODRICK, R.J. y PRESCOTT, E.C. (1997). Postwar U . S . Business Cycles: An Empirical Investigation. *Journal of Money, Credit and Banking*, Vol. 29, No. 1, pp. 1-16.
- HYNDMAN, R.J. (2006). Another look at Forecast-accuracy Metrics for Intermittent Demand. *Foresight*, No. 4, pp. 43-46.
- HYNDMAN, R.J. ... [et al.] (2018). Forecast: Forecasting functions for time series and linear models. version 8.4.
- HYNDMAN, R.J. ...[et al.] (2008). Forecasting with exponential smoothing: The state space approach. Springer Science & Business Media.
- HYNDMAN, R.J. ...[et al.] (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, Vol. 18, No. 3, pp. 439–454.
- IHS MARKIT, (2019^a). *Eviews 11*. 2019. version 11.
- IHS MARKIT: (2019^b). *Eviews 11 User's Guide I*. Irvine, CA.

- IHS MARKIT: (2019c). Eviews 11 User's Guide II. Irvine, CA.
- IIFT (2005). El cultivo del mango en Cuba. Jagüey Grande, Matanzas, Cuba.
- KOURENTZES, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, Vol. 143, No. 1, pp. 198-206.
- KOURENTZES, N. y ATHANASOPOULOS, G. (2020). Elucidate structure in intermittent demand series. *European Journal of Operational Research*, Vol. 288, No. 1, pp. 141-152.
- KWIATKOWSKI, D. ...[et al.] (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?. *Journal of Econometrics*, Vol. 54, No. 1-3, pp. 159-178.
- MAKRIDAKIS, S. ...[et al.] (1982). The Accuracy of Extrapolation (Time Series) Methods: Results of a Forecasting Competition. *Journal of Forecasting*, Vol. 1, No. June, pp. 111-153.
- MAKRIDAKIS, S. y HIBON, M. (2000). The M3-competition: Results, conclusions and implications. *International Journal of Forecasting*, Vol. 16, No. 4, pp. 451-476.
- MAKRIDAKIS, S., HYNDMAN, R.J. y PETROPOULOS, F. (2020). Forecasting in social settings: The state of the art. *International Journal of Forecasting*, Vol. 36, No. 1, pp. 15-28.
- MAKRIDAKIS, S., SPILLOTIS, E. y ASSIMAKOPOULOS, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLOS ONE*, Vol. 13, No. 3, pp. 1-26.
- MAKRIDAKIS, S., SPILLOTIS, E. y ASSIMAKOPOULOS, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, Vol. 36, No. 1, pp. 54-74.
- NIKOLOPOULOS, K., BABAI, M.Z. y BOZOS, K. (2016). Forecasting supply chain sporadic demand with nearest neighbor approaches. *International Journal of Production Economics*, Vol. 177, pp. 139-148.
- PARZEN, E. (1982). ARARMA models for time series analysis and forecasting. *Journal of Forecasting*, Vol. 1, pp. 67-82.
- PETROPOULOS, F. y MAKRIDAKIS, S. (2020). The M4 competition: Bigger. Stronger. Better. *International Journal of Forecasting*, Vol. 36, No. 1, pp. 3-6.
- R CORE TEAM, (2019). *R: A language and environment for statistical computing*. Vienna, Austria: R Foundation for Statistical Computing.

- SARANTIS, N. (2001). Nonlinearities, cyclical behaviour and predictability in stock markets: International evidence. *International Journal of Forecasting*, Vol. 17, No. 3, pp. 459–482.
- STELLWAGEN, E.A. y GOODRICH, R.L. (1991). *Forecast Pro-Batch Edition*. Belmont, MA: Business Forecast Systems, Inc.
- SVETUNKOV, I. y BOYLAN, J.E. (2017). Multiplicative State Space Models for Intermittent Time Series. Lancaster: November.
- SYNTETOS, A.A., ZIED BABAI, M. y GARDNER, E.S. (2015). Forecasting intermittent inventory demands: simple parametric methods vs. bootstrapping. *Journal of Business Research*, Vol. 68, No. 8, pp. 1746-1752.
- TONG, H. (1983). Threshold models in non-linear time series analysis. 1. New York: Springer-Verlag, Lecture Notes in Statistics.