

## Pronóstico de la provisión azucarera agroindustrial en Matanzas, Cuba

### Forecasting of the agro-industrial sugar provision in Matanzas, Cuba

Yasmany García-López<sup>1\*</sup> ; Lourdes Yamen González-Sáez<sup>2</sup> ; Juan Alfredo Cabrera-Hernández<sup>3</sup> 

<sup>1</sup>Instituto de Investigaciones de la Caña de Azúcar. Matanzas, Cuba; e-mail: yasmanygarcia31@gmail.com

<sup>2</sup>Universidad de Matanzas, Departamento de Química e Ingeniería Química. Matanzas, Cuba; e-mail: lourdesgonzalez71@gmail.com

<sup>3</sup>Universidad de Matanzas, Observatorio Ambiental COSTATENAS. Matanzas, Cuba; e-mail: alfredojuan1956@gmail.com

\*autor de correspondencia: yasmanygarcia31@gmail.com

**Cómo citar:** García-López, Y.; González-Sáez, L.Y.; Cabrera-Hernández, J.A. 2024. Pronóstico de la provisión azucarera agroindustrial en Matanzas, Cuba. Rev. U.D.C.A Act. & Div. Cient. 27(2):e2555. <http://doi.org/10.31910/rudca.v27.n2.2024.2555>

Artículo de acceso abierto publicado por Revista U.D.C.A Actualidad & Divulgación Científica, bajo una Licencia Creative Commons CC BY-NC 4.0

Publicación oficial de la Universidad de Ciencias Aplicadas y Ambientales U.D.C.A, Institución de Educación Superior Acreditada en Alta Calidad por el Ministerio de Educación Nacional

**Recibido:** marzo 3 de 2024

**Aceptado:** noviembre 25 de 2024

**Editado por:** Helber Adrián Arévalo Maldonado

## RESUMEN

El pronóstico de la provisión azucarera puede ser un instrumento fundamental en la toma de decisiones y en el manejo inteligente de recursos para contribuir con la sostenibilidad de la agroindustria azucarera. Para ello, en el presente trabajo se abordó, como caso de estudio, el análisis del registro histórico del procesamiento industrial de la caña de azúcar en el municipio Calimete, provincia Matanzas, Cuba. Se consideró, en el período de 2004 a 2021, a los kilogramos de azúcar por toneladas de tallos molidos, como indicador de provisión azucarera y se ajustó un modelo ARIMA estacional, con una escala trimestral. El modelo cumplió con los criterios de diagnóstico y de validación. A través del análisis de series de tiempo, se pudo pronosticar el indicador de provisión azucarera, a partir de su comportamiento histórico, lo que puede contribuir a la prevención o mitigación de escenarios futuros no deseados.

Palabras clave: Agroindustria azucarera; Modelo ARIMA; *Saccharum officinarum*; Serie de tiempo; Servicio de provisión.

## ABSTRACT

The forecast of the sugar provision can be a fundamental tool for decision-making and the intelligent management of resources to contribute to the sustainability of the sugar agroindustry. For this purpose, in the present work, the analysis of the historical record of the industrial processing of sugar cane in the Calimete municipality, Matanzas province, Cuba, was addressed as a case study. In the period from 2004 to 2021, the kilograms of sugar per ton of ground stalks were considered as an indicator of sugar provision and a seasonal ARIMA model was adjusted with a quarterly scale. The model met the diagnostic and validation criteria. Thus, through time series analysis, the sugar provision indicator could be forecast based on its historical performance. Which can contribute to the prevention or mitigation of unwanted future scenarios.

Keywords: ARIMA Model; Provision service; *Saccharum officinarum*; Sugar agroindustry; Time series.

## INTRODUCCIÓN

Los ecosistemas y agroecosistemas proveen importantes servicios ecosistémicos que favorecen el bienestar humano. El enfoque de servicios ecosistémicos comprende los términos de provisión, regulación, cultural y soporte (Adhikari & Hartemink, 2016; Waweru *et al.* 2016; De Groot *et al.* 2017). Según Costanza *et al.* (1997), los servicios ecosistémicos son flujos de materiales, energía e información del capital natural, lo que, en combinación con servicios del capital humano, favorecen el bienestar humano. Para Burkhard & Maes (2017) son los aportes de las estructuras y funciones de los ecosistemas, en combinación con otros diversos elementos de entrada y proveen bienestar a la sociedad. Con el paso del tiempo, los conceptos han evolucionado con un sustento ecológico; sin embargo, siempre se enfatiza en el vínculo entre ecosistemas y bienestar humano (De Groot *et al.* 2017).

En la agroindustria azucarera, como la mayoría de los procesos productivos, se persigue el incremento del servicio de provisión, traducido en la cantidad de azúcar producida y, para ello, el ecosistema se ha transformado en campos agropecuarios (García *et al.* 2022) o de fines industriales. En estos contextos, los pronósticos de rendimientos pueden ser utilizados para análisis de oferta y demanda, así como en la construcción de escenarios sobre seguridad alimentaria (Delgadillo-Ruiz *et al.* 2016). Por ello, el uso de modelos para prever los comportamientos de propiedades es una parte importante en el análisis de procesos industriales (Istifanus *et al.* 2018).

Un análisis frecuente en diversas áreas de investigación es la serie de tiempo, donde las tendencias de indicadores para una escala temporal se pueden estudiar, gracias a la existencia de registros históricos (Amaris *et al.* 2017). Los análisis de series de tiempo, mediante la metodología de Box y Jenkins, se emplean en diferentes ámbitos (Alonso, 2021) que, en la actualidad, son más viables, por la existencia de diversos materiales y herramientas estadísticas, como es el caso de la librería *forecast* (Hyndman *et al.* 2018), para el lenguaje de programación (R), así como el libro *Hands-on Time Series Analysis with R*, junto a la librería *TSstudio* (Krispin, 2019).

Las series de tiempo son una sucesión de valores aleatorios, con cierta periodicidad, ya sea anual, semestral, trimestral o diario, de acuerdo con la recopilación de los datos (Krispin, 2019). El beneficio de estos análisis radica en que, a partir de una sucesión pasada del parámetro, se obtiene un posible comportamiento futuro, lo que puede mejorar en sí, la toma de decisiones (Ferreira Bocca *et al.* 2015; Gil, 2016). Según Olivencia Polo *et al.* (2020), la toma de decisiones se caracteriza, con frecuencia, por condiciones de incertidumbre, en donde se requiere de una anticipación, mediante el análisis de dinámicas de datos en el tiempo, para favorecer el entendimiento de comportamientos, asociados a los procesos de soporte. De acuerdo con Rincón-Ruiz *et al.* (2014), esta comprensión es elemental para los servicios ecosistémicos. Así, la integración de big data y algoritmos de aprendizaje estadísticos permiten arribar a aproximaciones robustas, interdisciplinarias y útiles, para un enfoque ecosistémico (Manley *et al.* 2022).

Por tal motivo, el presente trabajo tuvo como finalidad el análisis de datos históricos para predecir, mediante un modelo ARIMA, la provisión azucarera agroindustrial.

## MATERIALES Y MÉTODOS

**Descripción del caso de estudio.** La agroindustria estudiada se ubicó en el municipio Calimete, de la provincia Matanzas, entre las coordenadas 22°25'41" N a 22°36'22" N y 81°11'14" W a 80°48'25" W y se compone de un central para el procesamiento de la caña de azúcar, a fin de obtener diferentes productos requeridos por la sociedad. Para un enfoque ecosistémico se consideró, como indicador de provisión azucarera, la relación de kilogramos de azúcar por tonelada de tallos molidos ( $\text{kg t}^{-1}$ ) (García *et al.* 2022). La utilización de este indicador permite enfocarse en la eficiencia para la obtención de la provisión de azúcar, como beneficio final comercializable. Así, en este trabajo, se abordaron los elementos esenciales para el pronóstico del servicio provisión azucarera (Figura 1).

**Análisis de series de tiempo.** Para los análisis exploratorios, ajuste de modelos y pronóstico de la provisión azucarera, se utilizó el lenguaje de programación (R) software, versión 3.6.0 (R Core Team, 2019). También fueron empleadas las librerías, *TSstudio* (Krispin, 2020) y *forecast* (Hyndman *et al.* 2018).

Para este estudio, los datos de provisión azucarera utilizados fueron consolidados por trimestres, para el período de enero, 2004 hasta mayo 2021. Se utilizó la metodología de Box – Jenkins, una de las más utilizadas, en el análisis de series de tiempo (Sanjeev *et al.* 2015; Mwanga *et al.* 2017; Hassan *et al.* 2019), mediante la cual, se llegó al pronóstico de la provisión azucarera, con un modelo autorregresivo (AR) integrado de medias móviles (MA), conocido como ARIMA [(p; d; q) (P; D; Q)s].

Los puntos clave de la metodología de Box-Jenkins, de acuerdo con Ramasubramanian & Singh (2019), se resumen en:

- a) Verificar si la serie es estacionaria; si no lo es, diferenciarla hasta alcanzarla.
- b) Identificar un modelo tentativo.
- c) Estimar el modelo.
- d) Verificar el diagnóstico (si este no es adecuado, volver al paso b).
- e) Usar el modelo para pronosticar.

En la elaboración del modelo ARIMA para la serie de tiempo, se consideró la existencia de variabilidad estacional, lo que implicó estimar, que la observación de un mismo mes en años diferentes, tienen una pauta de comportamiento similar, por lo tanto, el modelo ARIMA apropiado para este tipo de series, debe recoger los dos tipos de dependencia inter-temporal.

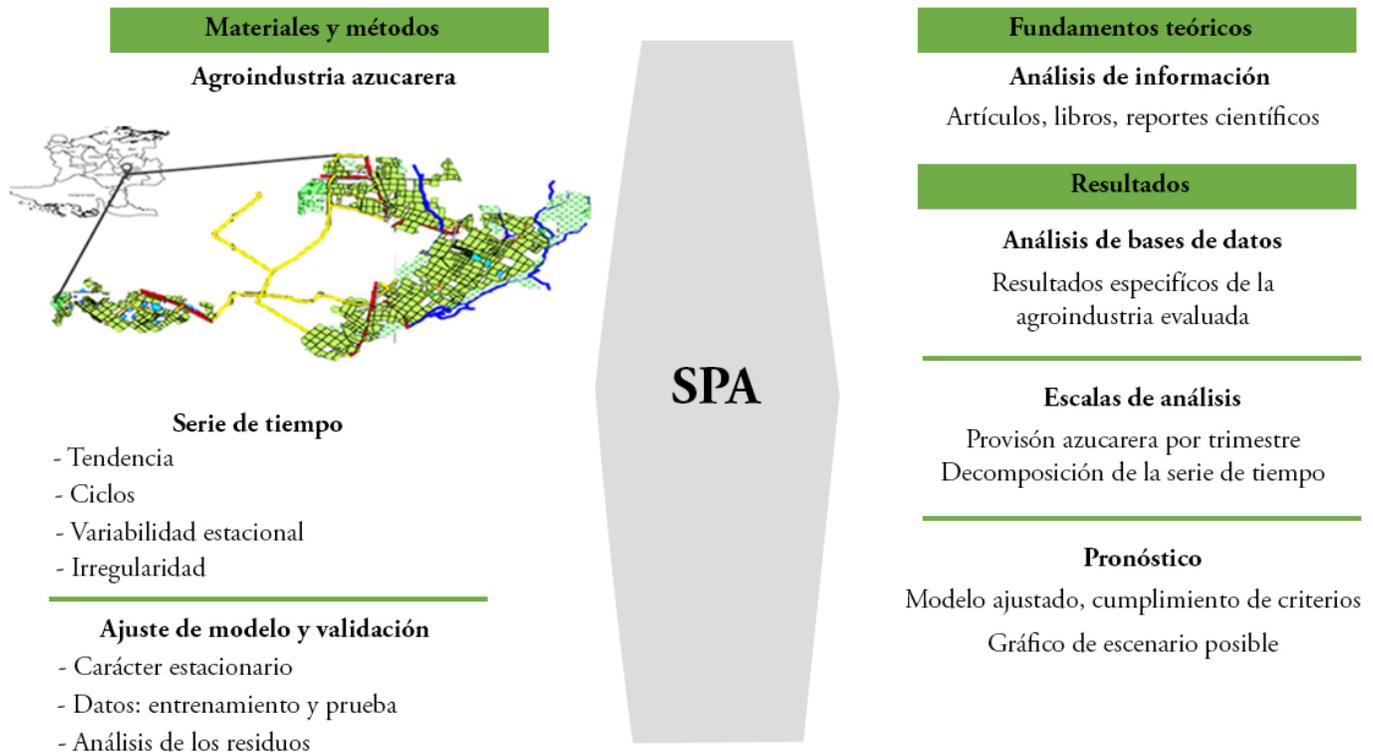


Figura 1. Diagrama general para el pronóstico del servicio de provisión azucarera (SPA).

En la identificación se proponen los modelos ARIMA ( $p, d, q$ ) ( $P, D, Q$ )s, que representan el comportamiento de la serie de tiempo. En primer lugar, se analizó el carácter estacionario. La serie es estacionaria cuando presenta una media y varianza constante. Para el modelo, se seleccionaron los órdenes ( $p, q$ ), que responden a la estructura regular estacionaria, mientras que ( $P, Q$ )s, corresponden a la estructura estacional estacionaria, donde ( $P, p$ ) son el orden del polinomio autorregresivo estacionario; ( $Q, q$ ), el orden del polinomio de medias móviles; ( $D, d$ ), tienen que ver con la derivación necesaria para hacer a la serie estacionaria y ( $s$ ) es el elemento relacionado a la variabilidad estacional, que es igual a 4, en el caso trimestral (Krispin, 2019). El carácter estacionario de la serie se comprueba mediante la prueba estadística de Dickey-Fuller, donde se establece:

1. Planteamiento de Hipótesis

2.  $p\text{-value} < 0,05$

$H_0$ : La serie es no estacionaria.

$H_1$ : La serie es estacionaria.

La selección y estimación de los órdenes ( $p; q$ ) y ( $P; Q$ ), para que el modelo se ajuste a la serie estacionaria, se realizó mediante el estudio de la función de autocorrelación simple (ACF). Con el uso de la función “*auto.arima*” de la librería *forecast*, de Hyndman *et al.* (2018).

En la validación se comprobó que el modelo propuesto se ajustó a los datos y reproduce el comportamiento de la serie de tiempo. Para ello, se consideró el análisis de los residuos del modelo, con el análisis del acercamiento a una distribución normal. En el análisis de normalidad se utilizó el gráfico de histograma, así como la prueba de *Lilliefort*.

Se consideraron, además, las pruebas de Box-Pierce y Ljung-Box y los análisis de errores del modelo, con el análisis de la variación existente entre el valor real de la variable y su valor pronosticado (ecuación 1). También, se utilizaron los criterios Akaike (AIC), su forma corregida (AICc) y el criterio Bayesiano (BIC), acorde con Krispin (2019).

$$e_t = Y_t - F_t \tag{ecuación 1}$$

Donde:

$e_t$  = error del pronóstico en el período  $t$ .

$Y_t$  = valor real de la variable en el período  $t$ .

$F_t$  = valor pronosticado de la variable en el período  $t$ .

Al establecerse observaciones y pronósticos para ( $n$ ) períodos, se pudo calcular los ( $n$ ) errores y se determinaron diferentes mediciones estadísticas, que permiten comparar entre modelos (ecuación 2 a 6). Estas fueron: error medio (*mean error*, o ME), raíz del error

cuadrático medio (*root mean square error*, o RMSE), error absoluto medio (*mean absolute error*, o MAE), error porcentual medio (*mean percentage error*, o MPE) y error porcentual absoluto medio (*mean absolute percentage error*, o MAPE) (Krispin, 2019).

$$ME = \frac{\sum(Y_t - F_t)}{n} \quad \text{ecuación 2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2} \quad \text{ecuación 3}$$

$$MAE = \frac{\sum |Y_t - F_t|}{n} \quad \text{ecuación 4}$$

$$MPE = \frac{1}{n} \sum_{t=1}^n \left( \frac{Y_t - F_t}{Y_t} \right) * 100 \quad \text{ecuación 5}$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| * 100 \quad \text{ecuación 6}$$

## RESULTADOS Y DISCUSIÓN

**Diagnóstico temporal.** La provisión azucarera, expresada en kilogramos de azúcar por tonelada de tallos molidos ( $\text{kg t}^{-1}$ ), según un análisis de series de tiempo, se puede descomponer en cuatro gráficos, que recogen los diferentes componentes relacionados con las variabilidades temporales (Figura 2).

La comprensión de la serie de tiempo se favorece con la descomposición en componentes: aleatorio, estacional y tendencia, además del comportamiento de los datos observado. De acuerdo con Ruiz López (2018), el componente aleatorio, también llamado ruido blanco, se caracteriza por variaciones sin un patrón definido alrededor de una media constante. A su vez, lo estacional sigue un patrón de cambio regular que se completa dentro de un año y se repite en base similar (Krispin, 2019). Por último, la tendencia presenta los efectos sobre la variable estudiada a largo plazo (Montes Páez *et al.* 2016) y, en este caso, se ha caracterizado por un decrecimiento de la provisión azucarera.

Según Grunewald *et al.* (2015), los servicios ecosistémicos se expresan a diferentes escalas de análisis. Lo cierto es que la agroindustria azucarera está marcada por la existencia de variabilidades espaciotemporales, que se origina desde el suelo, el cultivo y su procesamiento. Cada momento de zafra está condicionado por lo obtenido en los diferentes campos de producción del cultivo, como consecuencia de los manejos agrícolas, momento de cosecha y escenarios climáticos.

El rol del clima ha sido investigado por McGree *et al.* (2020) y utilizado como predictor en el análisis de rendimientos azucareros; sin embargo, no es el único factor que influye en los incrementos o decrecimientos de los rendimientos agrícolas e industriales. Conjuntamente, la

combinación de diferentes cultivares de caña de azúcar y composición de cepas pueden incidir en la cantidad de azúcar recuperada (Chiang González *et al.* 2018; Schmitz & Zhang, 2019). Además, las irregularidades del procesamiento de la caña de azúcar afectan la provisión azucarera, relacionados con la eficiencia industrial (García *et al.* 2022).

Se puede agregar que el análisis de los servicios ecosistémicos, en un contexto agroindustrial azucarero, también requiere de la comprensión de escalas de análisis. Escalas mayores permiten observar tendencias generales, mientras que en escalas menores, se observan mayores detalles para los procesos y manejos que inciden en la provisión azucarera. La extracción de sacarosa en una zafra, última etapa de la producción de azúcar arroja menores valores al inicio de la zafra, un aumento a mediados y una disminución hacia el final; sin embargo, se presentan variaciones dentro de cada mes de zafra, relacionado con el ciclo vegetativo del cultivo, los diversos cultivares que llegan al central y con la eficiencia industrial.

**Modelo ajustado para el análisis temporal de la provisión azucarera.** La base de datos recopilada se analizó según sus trimestres y se compararon diferentes modelos. La consolidación en trimestre de la serie respondió, en primera instancia, al interés de reflejar las variabilidades estacionales, que acontecen en las zafra azucareras.

La prueba de Dickey-Fuller, igual a 6,13, para un *lag* de 4 y un *p-value* igual a 0,11, no encuentra evidencias para rechazar la hipótesis nula de que la serie es no estacionaria, por lo que una derivación es de utilidad para el modelado de la misma. El modelo seleccionado ARIMA (0, 1, 1) (2, 1, 2) [4], se puede observar en la figura 3.

El estudio de la serie de tiempo es útil para realizar pronósticos del indicador seleccionado; sin embargo, es muy difícil que el valor pronosticado sea igual al valor real; solo se puede intentar obtener los menores errores posibles (Delgadillo-Ruiz *et al.* 2016). Un error bajo en los datos de entrenamiento, junto con un error alto en los datos de prueba, para los valores de MAPE, es indicio de sobre ajuste del modelo (Krispin, 2019). En este caso, el valor del set de entrenamiento es de 7,3 % y de prueba de 9,5 % (Tabla 1); en Alonso (2021) se aceptan modelos con porcentaje de error de 2,4 %, para entrenamiento y de 9,5 %, en set de prueba, así como de 2,2 y 8,1 %, respectivamente. Otro aspecto para considerar es el gráfico ACF, el cual, se encuentra cercano a cero, lo que indica que los residuos no se desviaron significativamente de un proceso de ruido blanco y son puramente aleatorios (Luis-Rojas *et al.* 2019), aspecto positivo para el modelo ajustado. Además, se considera el comportamiento de los residuos como parte de la valoración integral a realizar en la selección y ajuste de un modelo (Figura 4).

Este caso sugiere que las autocorrelaciones se encuentran dentro del intervalo de confianza. Además, se consideran las pruebas de los residuos Lilliefors, Box-Pierce y Ljung-box, en las cuales, se obtienen valores de *p-value* mayores que 0,05. El modelo seleccionado está compuesto de un coeficiente de media móvil (MA1), en la parte regular de la serie y dos coeficientes auto-regresivos (SAR1 y SAR2), así como dos de media móvil (SMA1 y SMA2). Se expone también el error estándar de cada uno (s.e.) (Tabla 1).

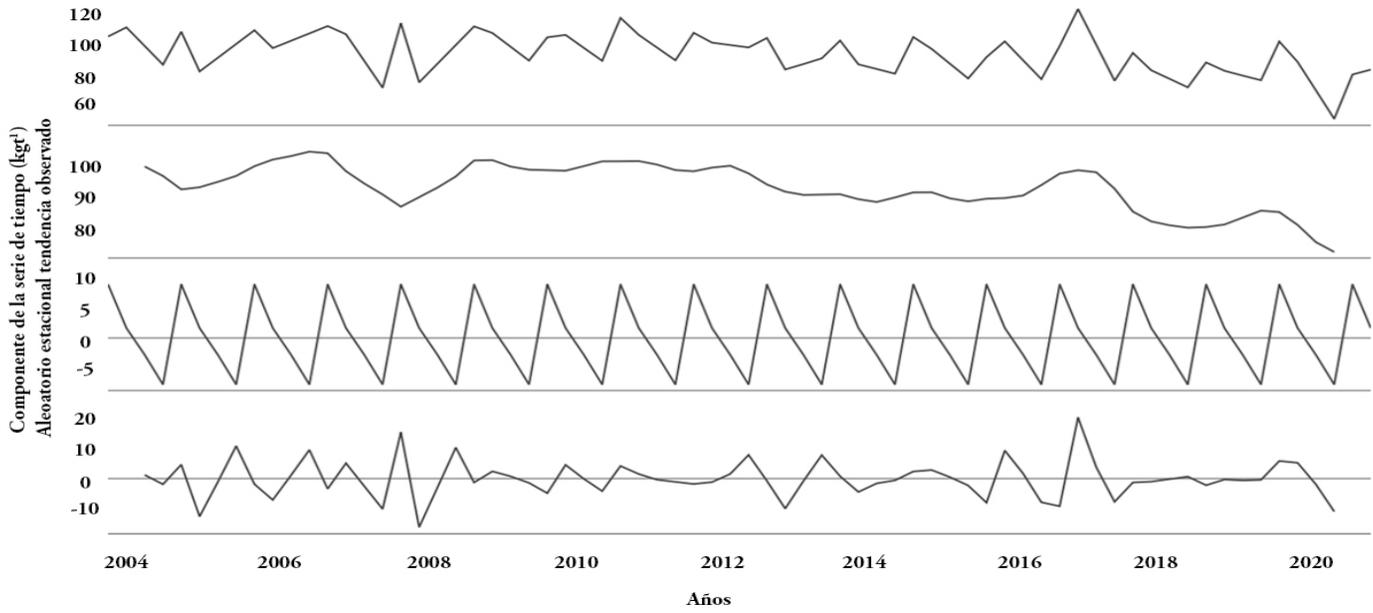


Figura 2. Descomposición de la serie de tiempo.

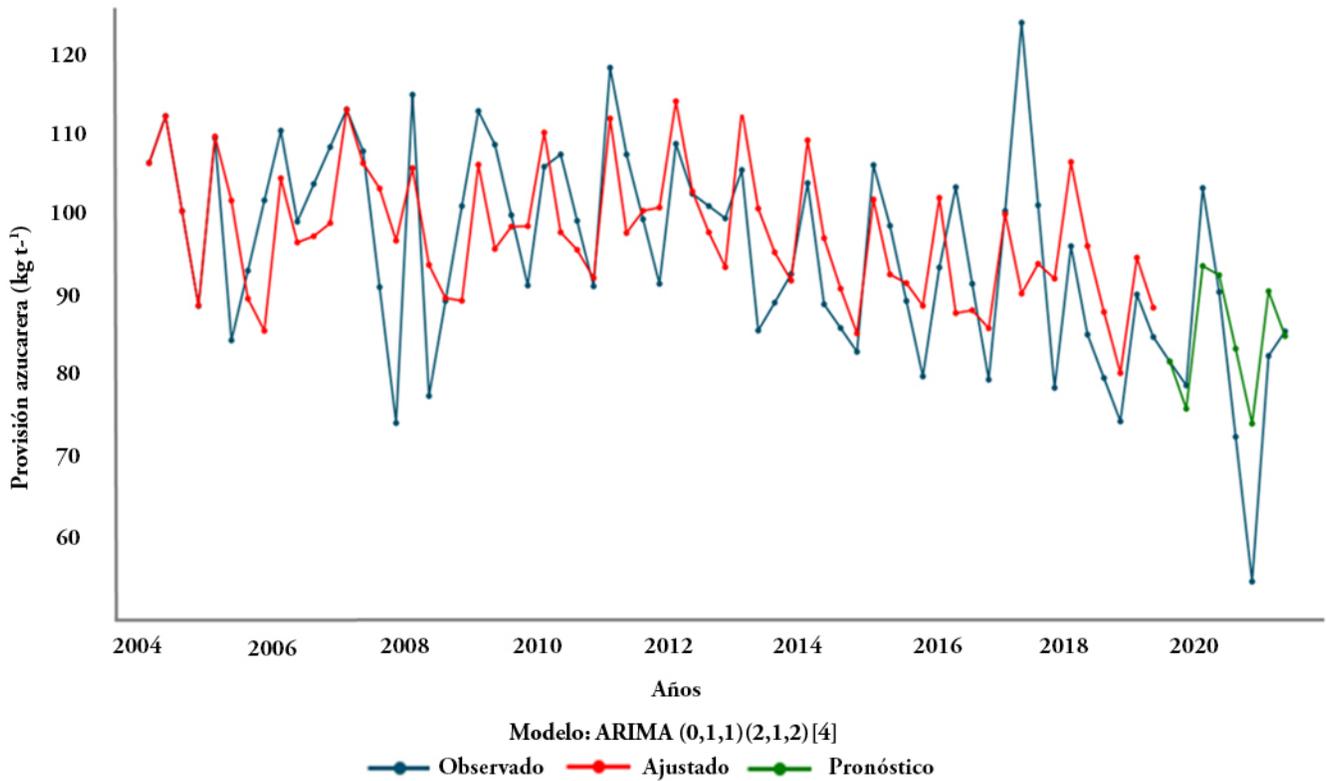


Figura 3. Modelado de la serie de tiempo.

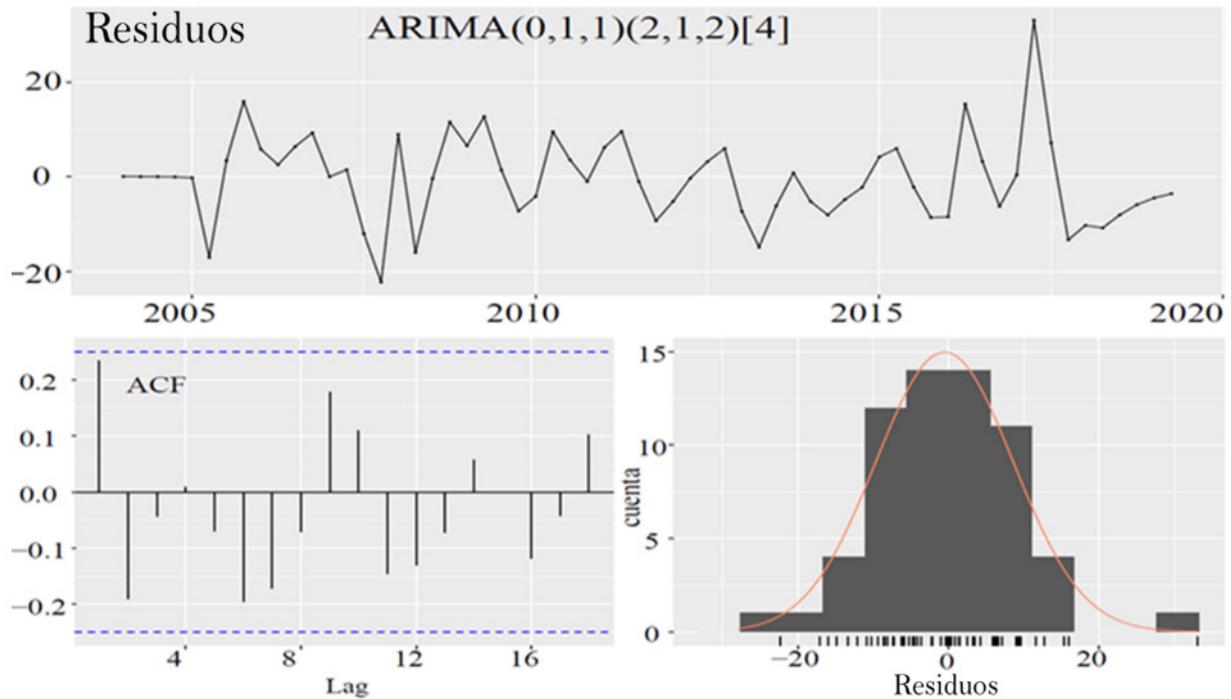


Figura 4. Comportamiento de los residuos del modelo ARIMA.

Tabla 1. Análisis de los residuos y coeficientes del modelo.

		Estadísticas del modelo				
		Set	ME	RMSE	MAE	MPE
ARIMA (0,1,1)(2,1,2)[4]	Entrenamiento	-0,5	9,1	6,8	-1,3	7,3
	Prueba	-3,4	9,0	6,6	-6,0	9,5
	Test de los residuos					
	Test: Lilliefors	Test: Box-Pierce		Test: Ljung-Box		
	p-value = 0,85	p-value = 0,06		p-value = 0,05		
	Coeficientes del modelo					
		MA1	SAR1	SAR2	SMA1	SMA2
		-0,79	-0,79	-0,21	-0,14	-0,57
	s.e	0,19	0,34	0,18	0,34	0,30
	Sigma <sup>2</sup> estimado de 98,37: log likelihood de -213,04 Criterios: AIC=438,09 AICc=439,77 BIC=450,35					

**Pronóstico de la provisión azucarera.** Los resultados descritos en los epígrafes anteriores evidenciaron que la provisión azucarera no presenta un comportamiento homogéneo para cada uno de los días

de zafra. En este trabajo, mediante el modelo ajustado de serie de tiempo, se realiza el pronóstico de la provisión azucarera hasta el 2025 (Figura 5).

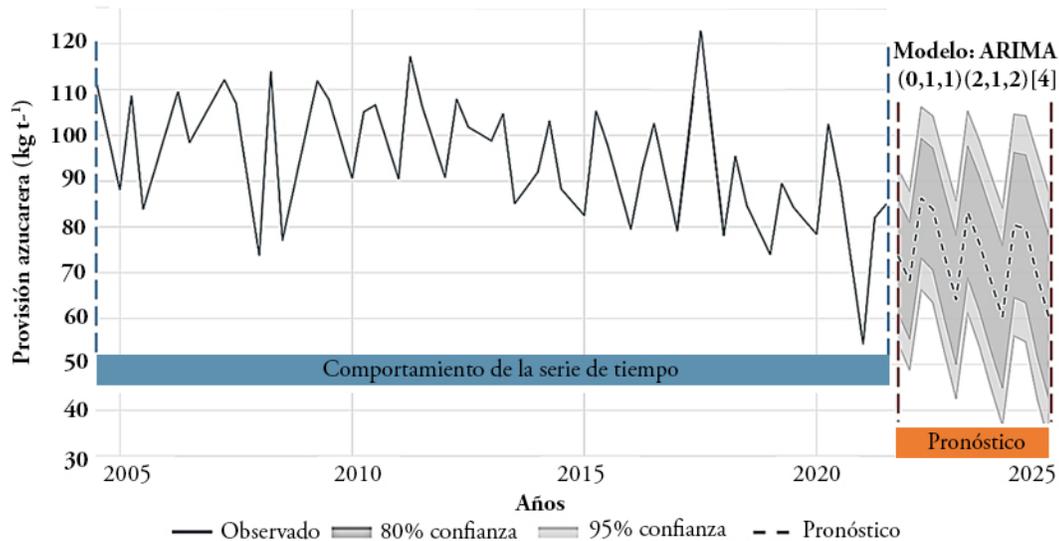


Figura 5. Pronóstico de la provisión azucarera según modelo propuesto en el caso de estudio.

El pronóstico del modelo presenta una tendencia a la disminución en la provisión azucarera de esta agroindustria, si persisten las dinámicas observadas. De acuerdo con Contreras Juárez *et al.* (2016), los pronósticos que se realizan mediante el uso de las series de tiempo tienen la premisa de que se mantendrá la tendencia encontrada, lo que permite obtener valores bastante precisos en el corto plazo. Por ello, el proceso de toma de decisiones debe considerar aspectos relacionados con las pérdidas de azúcar y sus variabilidades espaciotemporales, para hacer frente a esta tendencia.

Los pronósticos son utilizados en la agroindustria azucarera por diferentes autores, para prever escenarios y favorecer la toma de decisiones:

- En Hassan *et al.* (2019), se propone un modelo ARIMA (1, 2, 2), para el pronóstico de la producción de caña de azúcar en Bangladesh.
- En Mwangi *et al.* (2017), se ajustó un modelo ARIMA (2, 1, 2) (2, 0, 3) [4] al comportamiento del rendimiento de la caña de azúcar en Kenya y realizó un pronóstico para el período de 2015 a 2024.
- En Sanjeev *et al.* (2015), se encontró poca desviación entre el rendimiento predicho y el rendimiento real, lo que le permitió el uso de modelos ARIMA (0, 1, 1) y ARIMA (1, 1, 0), para conseguir pronósticos a corto plazo, en tres distritos productores, en Haryana, India.

Estos trabajos exponen los pronósticos enfocados en los rendimientos agrícolas de la caña de azúcar; sin embargo, como se aprecia en esta investigación, los modelos ARIMA también se pueden extender a la provisión final de la agroindustria azucarera, con el cumplimiento de los diferentes criterios de ajuste y validación, que son requeridos para las series de tiempo. Según Cabrera Milanés *et al.* (2015), la aplicación del control estadístico en un proceso puede ser efectivo

en la reducción de los costos durante la producción. También, Delgadillo-Ruiz *et al.* (2016) expresan que existe una mejora en la toma de decisiones, si emplean, de manera adecuada, las técnicas de pronóstico, lo que debe ser una alternativa para los planes de desarrollo futuros.

Como conclusión, el modelo ARIMA (0, 1, 1) (2, 1, 2) [4] se ajustó a la serie histórica del servicio de provisión azucarera y se cumplieron los criterios necesarios para su aceptación.

La obtención de un modelo válido y el pronóstico que este provee se presentó como una forma de valoración para conocer el comportamiento futuro, que puede tener la agroindustria azucarera.

El pronóstico expuesto recoge un comportamiento futuro con tendencia a la disminución, en la provisión azucarera, si persisten las mismas dinámicas; por ello, la toma de decisiones debe considerar el análisis de las causas que afectan la obtención de azúcar, para evitar esta tendencia.

Se hace importante que todos los actores que inciden en la producción, así como los que forman parte de los sistemas de medición y recopilación de datos reciban las capacitaciones pertinentes sobre uso de informaciones en la confección de modelos predictivos, formas de actuación para la mitigación de efectos no deseados y actúen en correspondencia con los resultados que son encontrados.

Es recomendable el empleo de sistemas de control estadístico y de pronósticos frecuentes, para una actualización, que permita predecir los escenarios futuros.

**Conflictos de intereses:** El manuscrito fue preparado y revisado con la participación de los autores y se declara que no existe conflicto de intereses que ponga en riesgo la validez de los resultados presentados. **Financiación:** La recopilación de datos y los análisis

proyecto: “Tecnologías para adecuar los manejos de suelo y cultivo a la variabilidad del sistema agroindustrial azucarero”, desarrollado por el Instituto de Investigaciones de la Caña de Azúcar en Matanzas, Cuba. Contribución de los autores: Yasmany García López: conceptualización, depuración de datos, análisis formal, investigación, validación, visualización, escritura, revisión y edición. Lourdes Yamen González Sáez: conceptualización, supervisión, metodología, revisión y edición. Juan Alfredo Cabrera Hernández: conceptualización, supervisión, metodología, revisión y edición

## REFERENCIAS

- ADHIKARI, K.; HARTEMINK, A. 2016. Linking soils to ecosystem services. A global review. *Geoderma*. 262:101-111. <http://dx.doi.org/10.1016/j.geoderma.2015.08.009>.
- ALONSO, A. 2021. La predicción de series temporales mediante el modelo de regresión. *Anuario Jurídico y Económico Escurialense*. 54:261-280.
- AMARIS, G.; ÁVILA, H.; GUERRERO, T. 2017. Aplicación de modelo ARIMA para el análisis de series de volúmenes anuales en el río Magdalena. *Revista Tecnura*. 21(52):88-101. <http://dx.doi.org/10.14483/udistrital.jour.tecnura.2017.2.a07>
- BURKHARD, B.; MAES, J. 2017. *Mapping Ecosystem Services*. Pensoft Publishers. Sofia. Bulgaria. 365p.
- CABRERA MILANÉS, A.; DE LA CRUZ RIVADENEIRA, O.; GÓMEZ AVILÉS, B.; RODRÍGUEZ BETANCOURT, R. 2015. Integración de métodos estadísticos y económicos para la gestión en el proceso industrial cubano del azúcar de caña. Caso de estudio. *Revista Técnica de la Facultad de Ingeniería Universidad de Zulia*. 38(3):209-215.
- CHIANG GONZÁLEZ, J.; GONZÁLEZ MORALES, V.M.; REYES SÁNCHEZ, Y.; MIÑO VALDÉS, J. 2018. Influencia de las variedades de caña sobre la eficiencia industrial en la fábrica “14 de julio de Cienfuegos. *Centro Azúcar*. 45:41-49.
- CONTRERAS JUÁREZ, A.; ATZIRY ZUÑIGA, C.; MARTÍNEZ FLORES, J.; SÁNCHEZ PARTIDA, D. 2016. Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos percederos. *Estudios Gerenciales*. 32:387-396. <https://doi.org/10.1016/j.estger.2016.11.002>
- COSTANZA, R.; D'ARGE, R.; DE GROOT, R.S.; FARBER, S.; GRASSO, M.; HANNON, B.; LIMBURG, K.; NAEEM, S.; O'NEILL, R.; PARUELO, J.; RASKIN, R.G.; SUTTON, P.; VAN DEN BELT, M. 1997. The Value of the World's Ecosystem Services and Natural Capital. *Nature*. 387:253-260. <http://doi.org/10.1038/387253a0>
- DE GROOT, R.; BRAAT, L.; COSTANZA, R. 2017. A short history of the ecosystem services concept. En: Burkhard, M. (eds.) *Mapping ecosystem services*. Pensoft Publishers. Sofia, Bulgaria. p.31-34.
- DELGADILLO-RUIZ, O.; RAMÍREZ-MORENO, P.P.; LEOS-RODRÍGUEZ, J.; SALAS GONZÁLEZ, J.M.; VALDEZ-CEPEDA, R.D. 2016. Pronósticos y series de tiempo de rendimientos de granos básicos en México. *Acta Universitaria*. 26(3). <http://doi.org/10.15174/au.2016.882>
- FERREIRA BOCCA, F.; ANTUNES RODRIGUES, L.H.; MODESTO ARRAES, N.A.M. 2015. When do I want to know and why? Different demands on sugarcane yield predictions. *Agricultural Systems*. 135:48-56. <http://dx.doi.org/10.1016/j.agsy.2014.11.008>
- GARCÍA, Y.; GONZÁLEZ, L.Y.; CABRERA, J.A. 2022. Aplicaciones de aprendizaje automático para el análisis industrial de la provisión azucarera en Matanzas, Cuba. *Revista U.D.C.A Actualidad & Divulgación Científica* 25(2):e2334. <http://doi.org/10.31910/rudca.v25.n2.2022.2334>
- GIL, V. 2016. Pronóstico de la demanda mensual de electricidad con series de tiempo. *Revista EIA*. 13 (26):111-120. <https://doi.org/10.24050/reia.v13i26.749>
- GRUNEWALD, K.; BASTIAN, O.; SYRBE, R.-U. 2015. Space and time aspects of ES. En: Grunewald, K.; Bastian, O. (Eds.) *Ecosystem Services - Concept, Methods and Case Studies* p.53-65. Berlin (Germany): Springer. <http://doi.org/10.1007/978-3-662-44143-5>
- HASSAN, Z.; SIRAJ-UD-DOULAH; HASAN, K. 2019. Forecasting the production of sugar cane based on time series models in Bangladesh. *Bulletin of mathematics and statistics research*. 7(4):24-32.
- HYNDMAN, R.; ATHANASOPOULOS, G.; BERGMEIR, C.; CACERES, G.; CHHAY, L.; O'HARA-WILD, M.; PETROPOULOS, F.; RAZBASH, S.; WANG, E.; YASMEEN, F. 2018. Forecast: Forecasting functions for time series and linear models. R package version 8.4. Disponible desde Internet en: <https://CRAN.R-project.org/package=forecast>
- ISTIFANUS, B.; EZEKIEL, A.M.; EZEANYA, N.C.; GAGARE, H.U. 2018. Prediction of sugar yield from sugar cane using process modelling. *International Journal of Research in Engineering and Technology*. 07(06). <https://doi.org/10.15623/ijret.2018.0706009>

- KRISPIN, R. 2020. TSstudio: functions for time series analysis and forecasting. R package version 0.1.6. Disponible desde Internet en: <https://CRAN.R-project.org/package=TSstudio>
- LUIS-ROJAS, S.; GARCÍA-SÁNCHEZ, R.; GARCÍA-MATA, R.; ARANA-CORONADO, O.; GONZÁLEZ-ESTRADA, A. 2019. Metodología Box - Jenkins para pronosticar los precios de huevo blanco pagados al productor en México. *Agrociencia*. 53(6): 911-925.
- MANLEY, K.; NYELELE, C.; EGOH, B.N. 2022. A review of machine learning and big data applications in addressing ecosystem service research gaps. *Ecosystem Services*. 57:101478. <https://doi.org/10.1016/j.ecoser.2022.101478>
- MCGREE, S.; SCHREIDER, S.; KULESHOV, Y.; PRAKASH, B. 2020. On the use of mean and extreme climate indices to predict sugar yield in western Fiji. *Weather and Climate Extremes*. 29:100271. <https://doi.org/10.1016/j.wace.2020.100271>
- MONTESPÁEZ, E.G.; CALVETEGONZÁLEZE, E.; ALFONSO, C. 2016. Aplicación de series de tiempo en la realización de pronósticos de producción. *Revista Fuentes*. 14(1):79-88. <https://doi.org/10.18273/revfue.v14n1-2016007>
- MWANGA, D.; ONG'ALA, J.; ORWA, G. 2017. Modeling sugarcane yields in the Kenya sugar industry: A SARIMA Model Forecasting Approach. *International Journal of Statistics and Applications*. 7(6):280-288. <http://doi.org/10.5923/j.statistics.20170706.02>
- OLIVENCIA POLO, F.; FERRERO BERMEJO, J.; GÓMEZ FERNÁNDEZ, J.F.; CRESPO MÁRQUEZ, A. 2020. Failure Mode Prediction and Energy Forecasting of PV Plants to Assist Maintenance Task by ANN Based Models. In: A. Márquez et al. (eds.), *Value Based and Intelligent Asset Management* p.187-209. Switzerland: Springer. [https://doi.org/10.1007/978-3-030-20704-5\\_9](https://doi.org/10.1007/978-3-030-20704-5_9)
- R CORE TEAM. 2019. R: A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria. Disponible desde Internet en: <https://www.R-project.org/>
- RAMASUBRAMANIAN, K.; SINGH, A. 2019. Machine learning using R: With time series and industry-based use cases in R. Second Edition. Springer. New York, USA. <https://doi.org/10.1007/978-1-4842-4215-5>
- RINCÓN-RUÍZ, A.; ECHEVERRY-DUQUE, M.; PIÑEROS, A.M.; TAPIA, C.H.; DAVID, A.; ARIAS-ARÉVALO, P.; ZULUAGA, P.A. 2014. Valoración integral de la biodiversidad y los servicios ecosistémicos: Aspectos conceptuales y metodológicos. Instituto de Investigación de Recursos Biológicos Alexander von Humboldt. Bogotá, Colombia. 151p.
- RUIZ LÓPEZ, H.R. 2018. Pronóstico de las exportaciones del cacao ecuatoriano para el 2018 con el uso de modelos de series de tiempo. *INNOVA Research Journal*. 3(6):9-20. <https://dialnet.unirioja.es/servlet/articulo?codigo=6778620>
- SANJEEV, VERMA, U.; TONK, M. 2015. Time-series modelling for sugarcane yield estimation in Haryana. *International Journal of Applied Mathematics and Statistical Sciences (IJAMSS)*. 4(6):53-62.
- SCHMITZ, A.; ZHANG, F. 2019. The Dynamics of sugarcane and sugar yields in Florida: 1950–2018. *Crop science*. 59:1880-1886. <https://doi.org/10.2135/cropsci2018.11.0674>
- WAWERU, P.; BURKHARD, B.; MULLER F. 2016. A review of studies on ecosystem services in Africa. *International Journal of Sustainable Built Environment*. 5:225-245. <http://dx.doi.org/10.1016/j.ijbsbe.2016.08.005>