

# Revista de Ciencias Sociales



Revista de Ciencias Sociales (RCS)  
Vol. XXVII, Número Especial 4, 2021, pp.  
FCES - LUZ • ISSN: 1315-9518 • ISSN-E: 2477-9431

Como citar APA: Ramírez Castañeda, L. N., Cristancho Cruz, S. L., y Cleves-Leguizamo J. (2021). Modelos de fluctuaciones de precios agrícolas: Estudio comparativo de frutas tropicales frescas en Colombia. *Revista de Ciencias Sociales (Ve)*, XXVII(Especial 4), 197-212.

# Modelos de fluctuaciones de precios agrícolas: Estudio comparativo de frutas tropicales frescas en Colombia

Ramírez Castañeda, Leila Nayibe\*  
Cristancho Cruz, Sandra Liliana\*\*  
Cleves-Leguizamo José-Alejandro\*\*\*

## Resumen

Los cultivos de maracuyá (*Passiflora Edulis* Sims *F. Purpurea* y *F. Flavicarpa*) y granadilla (*Passiflora Ligularis* L.) tienen gran interés económico y productivo en países tropicales, como lo evidencia el incremento sostenido del área de siembra para satisfacer la creciente demanda. Sin embargo, para minimizar los riesgos económicos de los inversionistas, se requiere adecuada planificación de los procesos productivos, estimulando las oscilaciones de los precios. Precisamente, este artículo tiene como objetivo principal analizar las fluctuaciones de los precios de maracuyá y granadilla, con base en los métodos ARIMA (Autoregressive Integrated Moving Average); modelo de componentes no observados y modelos de regresión markovianos, para establecer el mejor desempeño a través de la minimización del criterio de información de Akaike. Para entender el fenómeno estocástico de la serie de tiempo de precios, se analizaron datos provenientes de estadísticas oficiales de estos cultivos en el período de observación 2011-2019. Los resultados demostraron que los modelos ARIMA explican en mejor medida y con mayor exactitud, las fluctuaciones de los precios. Se concluyó que estos modelos son una herramienta idónea para analizar el comportamiento de los precios, contribuyendo a la predicción de los mismos, información valiosa para los tomadores de decisiones.

**Palabras clave:** Passifloras; pronósticos de precios; procesos estocásticos; modelos markovianos; frutas tropicales.

---

\* Doctora (c) en Ingeniería. Maestría en Ingeniería Industrial. Ingeniera Industrial. Profesor Titular en la Universidad Libre, Colombia. E-mail: [leylan.ramirez@unilibre.edu.co](mailto:leylan.ramirez@unilibre.edu.co)  ORCID: <https://orcid.org/0000-0002-0651-0971>

\*\* Estudiante del Doctorado en Educación. Maestría en Educación. Profesor Asociado en la Universidad Libre, Colombia. E-mail: [sandra.cristancho@unilibre.edu.co](mailto:sandra.cristancho@unilibre.edu.co)  ORCID: <https://orcid.org/0000-0001-9799-9305>

\*\*\* Doctor en Agroecología. Profesor Titular en la Universidad Pedagógica y Tecnológica de Colombia, Facultad Seccional Duitama, Escuela de Administración de Empresas Agropecuarias. E-mail: [jose.cleves@uptc.edu.co](mailto:jose.cleves@uptc.edu.co)  ORCID: <https://orcid.org/0000-0001-9717-9753>

Recibido: 2021-05-27 · Aceptado: 2021-08-12

# Models of agricultural price fluctuations: A comparative study on fresh tropical fruits in Colombia

## Abstract

The cultivation of passion fruit (*Passiflora Edulis* Sims *F. Purpurea* and *F. Flavicarpa*) and granadilla (*Passiflora Ligularis* L.) are of great economic and productive interest in tropical countries, which is expressed by the sustained increase of the planting area to meet the growing demand. In order to minimize economic risks for investors, it is necessary to carry out adequate planning of production processes, estimating price fluctuations. The main objective of this article is to analyze price fluctuations, based on ARIMA (Autoregressive Integrated Moving Average) methods; unobserved components model and Markovian regression models, to establish the best performance through the minimization of the Akaike information criterion. To understand the stochastic phenomenon of the price time series, the data series from official statistics of these crops in an observation window between the years 2011-2019 were analyzed. The results showed that ARIMA models explain price fluctuations better and more accurately. It was concluded that this model is an ideal tool to analyze price behavior, contributing to price prediction, which is valuable information for decision makers.

**Keywords:** Passifloras; price forecasting; stochastic processes; Markovian models; tropical fruits.

## Introducción

Los precios de los cultivos son elásticos, inestables y están vinculados a las fuerzas de mercado (demanda y oferta), además, dependen de otros tipos de factores como, por ejemplo: Fecha de siembra, época de cosecha, condiciones climáticas, manejo fitosanitario (plagas, enfermedades, arvenses), además, la disponibilidad de recursos logísticos oportunos y eficientes (Kantanatha, 2007; Cleves, Jarma y Fonseca, 2009; Cleves, Jarma y Acened, 2012).

En los agro negocios, elementos fundamentales para la toma de decisiones son los pronósticos de precios, los cuales son cruciales porque permiten que los tomadores de decisiones puedan establecer cómo planificar correctamente la producción y el mercado (Kantanatha, 2007), así como facilitan la información requerida para aumentar la competitividad (Montecé et al., 2021). Muchos estudios, han estado direccionados a la importancia de los pronósticos de precios

como apoyo a las decisiones (Kazaz, 2004; Kantanatha, 2007; Zhang, Shang y Li, 2011; Lee et al., 2016; Urdaneta y Borgucci, 2018), puesto que conocer el precio futuro permite a los agricultores planificar las actividades agrícolas y estimar su presupuesto (Jadhav, Chinnappa y Gaddi, 2017).

En ese contexto, la necesidad de pronosticar el valor futuro de productos perecederos de corta vida de almacenamiento, es un objetivo principal en numerosas investigaciones alrededor del mundo (Boateng et al., 2017; Dharavath y Khosla, 2019; Paredes-García et al., 2019; Weng et al., 2019; Sabu y Kumar, 2020).

Por ello, la utilización de herramientas de análisis de pronósticos, como los modelos *Autoregressive Integrated Moving Average* (ARIMA) y *Seasonal Autoregressive Integrated Moving Average* (SARIMA) (Reddy, 2019; Sabu y Kumar, 2020), es bastante frecuente en investigaciones a nivel mundial. Con ellas se pretende predecir los valores futuros de productos agrícolas y,

debido a que la desviación del pronóstico obtenido con respecto a los valores observados no es muy alta, se constituyen en herramienta confiables para proyectar precios a futuro de frutas y verduras (Boateng et al., 2017; Jadhav et al., 2017; Pardhi, Singh y Kumar, 2018; Dharavath y Khosla, 2019; Paredes-García et al., 2019; Weng et al., 2019).

Sin embargo, el pronóstico de precios puede fallar debido a factores climáticos, económicos, fitosanitarios, culturales, logísticos, que pueden generar desviaciones importantes del pronóstico frente al valor observado, requiriéndose que el mismo tenga flexibilidad ante las fluctuaciones, que pueden estar entre un 5-10%, dependiendo del cultivo (Jadhav et al., 2017).

En el caso de los *commodities* de origen agrícola, sus precios, comúnmente, presentan un comportamiento estacional que depende de las épocas de cosecha y siembra (Alonso y Arcila, 2013; Reddy, 2019) y sus fluctuaciones están relacionadas con las condiciones macroeconómicas (Costa y Ruffo, 2019). Sin embargo, no existe una metodología idónea para la estimación de los precios de los productos agrícolas y, particularmente, de las frutas pasifloras. Por ello, este artículo tiene como objetivo analizar las fluctuaciones de los precios, con base en los métodos ARIMA, modelo de componentes no observados y modelos de regresión markovianos, a través de la minimización del criterio de información de Akaike.

## 1. Aspectos básicos de las series de tiempo univariadas

Una serie temporal es una colección de observaciones de una variable tomada en secuencias y ordenada en el tiempo (instantes de tiempo secuencial), cuyo objetivo reside en estudiar sus cambios con respecto al tiempo y predecir sus valores futuros; de allí que, a través de técnicas estadísticas, se puede describir su comportamiento en el pasado y predecir su comportamiento futuro (Github, 2020).

Dentro de los análisis de series temporales univariadas, se establecen cinco pasos: Definición del problema, recopilación de información, análisis preliminar que está asociado al análisis descriptivo de los datos, elección del modelo y ajuste. Por otro lado, para la modelación existen los enfoques clásicos que presentan modelos no complejos, entre los cuales se pueden citar los lineales, polinómicos, medias móviles y diferencias estacionales. La desventaja radica en que hay una dependencia fuerte con los datos observados recientes y más débil con los más alejados (Github, 2020).

Otros enfoques son los alisados o suavizados, definidos también como deterministas, los cuales son técnicas de tipo más predictivo que descriptivo. En esta categoría se encuentran modelos NAIVE, modelos de medias móviles y modelos de suavizado exponencial simple. Para las series temporales no estacionales con tendencia, se recomienda el modelo de suavizamiento exponencial *Holt* y para series temporales con tendencia y estacionalidad, el modelo *Holt-Winters*.

Por último, el enfoque *Box-Jenkins*, considera que la serie de tiempo es una realización de un proceso estocástico. Dentro de esta categoría se encuentra los modelos ARIMA y SARIMA, los cuales no reproducen la predicción sin datos faltantes, una característica que puede ser una desventaja si no se cuenta con la información. A continuación, se presentan las técnicas desarrolladas para el análisis agroeconómico de las series de precios, utilizadas en esta investigación.

### 1.1. Modelo ARIMA

Box et al. (2016), han sido ampliamente utilizados en todos los ámbitos científico-técnicos para identificar procesos estocásticos temporales y estimar modelos para su predicción y control. El modelo ARIMA (p, d, q) donde p, se define como el orden del proceso autorregresivo; d, el número de

diferencias que son necesarias para que un proceso sea estacionario; y  $q$ , el orden del proceso de medias móviles, se representa en la Ecuación 1.

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (1)$$

En donde, el parámetro  $d$ , sirve para convertir la serie original en estacionaria, los parámetros  $\phi_1, \dots, \phi_p$  son la parte autorregresiva,  $\theta_1, \dots, \theta_q$  pertenecen a las medias móviles, el término constante  $\phi_0$  y  $\varepsilon_t$  la perturbación estocástica. Esta metodología, se basa en el uso de los datos de una variable para identificar las características de su estructura probabilística subyacente (Dalinina, 2017), en contraposición a los procedimientos tradicionales de identificación de modelos basados en una teoría explicativa del fenómeno en estudio (Ramírez y Potes, 2019).

Además, en principio los modelos ARIMA ( $p, d, q$ ), son modelos no estacionarios, sin embargo, también existen los modelos estacionales auto regresivos, integrados de media móvil ARIMA ( $p, d, q$ ) ( $P, D, Q$ ) o SARIMA ( $p, d, q$ ) ( $P, D, Q$ ), la ventaja de éstos es que la estacionalidad puede ser capturada e incluida en el modelo.

Una de las desventajas de los modelos *Box-Jenkins*, es que se asume que existen valores para cada periodo de tiempo, esto no es común en muchas series de tiempo, lo que sugiere que se deben calcular los datos faltantes para considerar el modelo ARIMA.

e irregulares, que pueden distorsionar los componentes cíclicos estimados en un modelo ARIMA (Hodrick y Prescott, 1997). Este modelo, se basa explícitamente en las propiedades estocásticas de los datos, se ha utilizado para el análisis de series de tiempo macroeconómicas y ha demostrado las limitaciones de otras técnicas (Harvey y Jaeger, 2008). El modelo de componentes no observados propuesto por Stasmodels (2020), se presenta en la Ecuación 2.

$$y_t = \mu_t + \gamma_t + c_t + \sum_{j=1}^k \beta_j x_{jt} + \varepsilon_t \quad (2)$$

Donde los componentes de la serie son descritos por  $\mu_t$  tendencia;  $\gamma_t$  estacionalidad;  $c_t$  ciclicidad;  $\beta_j x_{jt}$  componente explicativo; y  $\varepsilon_t$  error de ruido blanco aleatorio. El modelo permite que los componentes sean dinámicos en el tiempo, esta ciclicidad permite capturar el ciclo económico de la variable en el tiempo en un periodo de 1, 5 y 12 años. Algunas aplicaciones fueron realizadas por Harvey y Jaeger (2008) para estimar el Producto Interno Bruto (PIB), los deflatores de los precios PIB y la base monetaria en USA.

## 1.2. Modelo de componentes no observados

Este tipo de modelo tiene como objetivo argumentar que se pueden considerar los componentes no observados a través de los filtros propuestos por Hodrick-Prescott en 1980, los cuales pueden modelar comportamientos cíclicos espurios, movimientos estacionales

## 1.3. Modelos de regresión markovianos

Son modelos de regresión que exhiben diferentes dinámicas en estados no observados, utilizando parámetros dependientes del estado para acomodar rupturas estructurales u otros fenómenos complejos. Estos modelos se conocen como modelos de Markov porque las transiciones entre los estados no observados siguen una cadena de Markov. Este tipo

de técnica permite modelar la dinámica de los sistemas financieros, puesto que otras investigaciones han revelado que la dinámica de los precios está asociada a comportamientos no lineales (Costa y Ruffo, 2019).

Los primeros ejemplos de aplicación se consideraron para las tasas de fondos federales, los mismos permiten incorporar un intercepto constante, que va cambiando bajo diferentes regímenes. El modelo se indica en la Ecuación 3.

$$r_t = \mu_t S_t + \varepsilon_t \quad (3)$$

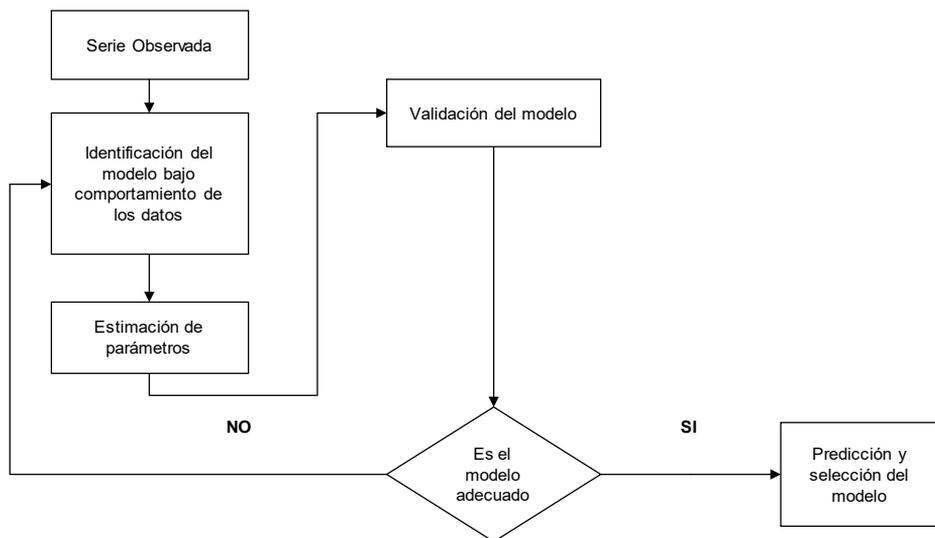
Donde  $S_t \in \{0,1\}$  y  $\varepsilon_t \sim N(0, \sigma^2)$ , además la matriz de transición está acorde tal como se indica en la Ecuación 4.

$$P((S_t = s_t | S_{t-1} = s_{t-1})) = \begin{bmatrix} P_{00} & P_{10} \\ 1 - P_{00} & 1 - P_{10} \end{bmatrix} \quad (4)$$

El modelo calcula los parámetros según la probabilidad máxima  $P_{00}$ ,  $P_{10}$ ,  $\mu_0$ ,  $\mu_1$ ,  $\sigma^2$ .

## 2. Metodología

La metodología para la modelación ya ha sido propuesta para el desarrollo de modelos bajo el enfoque *Box-Jenkins*, a continuación, a través del diagrama de flujo mostrado en la Figura I, se define el proceso.



Fuente: Elaboración propia, 2020 adaptado de Github (2020).

**Figura I: Modelo propuesto para la definición de pronóstico de precios**

A partir del modelo conceptual mostrado en la Figura I, los análisis numéricos siguen la estructura a partir de los datos seleccionados

para este estudio. La colección de datos observados se obtiene a partir de series de tiempo reportadas por la Corporación de

Abastos de Bogotá S.A. (Corabastos), en la ventana de observación temporal mensual de octubre de 2011 a septiembre de 2019 para el cultivo de maracuyá, y de enero de 2009 hasta septiembre de 2019 para granadilla, seleccionadas a partir de la completitud de información y su disponibilidad.

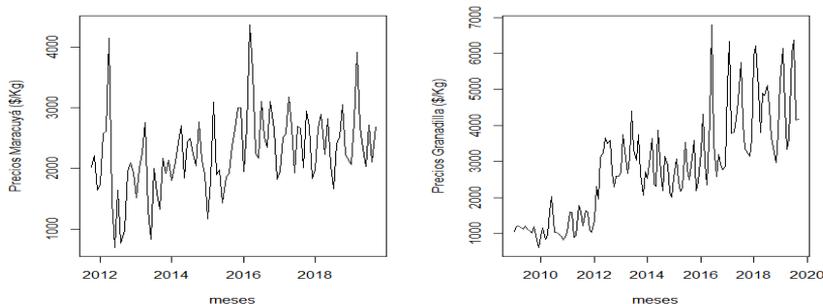
El mercado seleccionado fue el centro de abastecimiento de alimentos más importante de Colombia (Corabastos), las herramientas analíticas utilizadas para el pronóstico de precios fueron los modelos ARIMA, Modelo de componentes no observados (Harvey y Jaeger, 2008), modelos de regresión markovianos y los índices estacionales, con los cuales se construyeron herramientas estadísticas estándar, razones y porcentajes (Jadhav et al., 2017).

Los modelos de predicción seleccionados se establecieron a partir de la revisión analítica de literatura relacionada con pronósticos de precios para productos agrícolas, de acuerdo a las características generales de este tipo de series se pueden considerar modelos univariados, con enfoque estocástico, dada su complejidad debido a efectos macroeconómicos, estacionales, fluctuaciones no estables y dinámicas que deben ser consideradas como componentes que se reflejan en la modelación.

Es importante acotar, que dentro de la selección del mejor modelo para predecir la serie bajo estudio, se usó el criterio de información de Akaike (AIC), puesto que se utiliza para la comparación entre modelos (Schermelleh-Engel, Moosbrugger y Müller, 2003) y ha sido el más estudiado (Cryer y Chan, 2008), para el cual a menores valores de esta medida, mejor el modelo en términos de la calidad relativa con relación a la pérdida de información del modelo estadístico estimado para la serie de precios del cultivo (Ramírez, González y Cleves-Leguizamo, 2021).

### 3. Resultados y discusión

El comportamiento de los precios observados en frutas pasifloras maracuyá y granadilla, indican una tendencia estacional en los precios, lo que ha sido corroborado en los análisis descriptivos en investigaciones precedentes (Boateng et al., 2017; Reddy, 2019; Sabu y Kumar, 2020). Se pudo evidenciar que la fluctuación de los precios es mayor en granadilla, en donde se observa un marcado patrón de tendencia positiva superior en comparación con los precios del maracuyá, como se puede observar en el Gráfico 1.



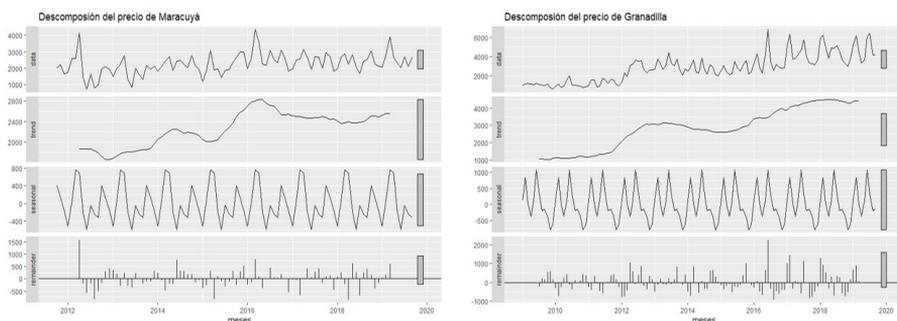
Fuente: Corabastos (2020).

**Gráfico 1: Comportamiento de los precios del maracuyá y granadilla (\$ Col/kg)**

Los precios de maracuyá durante el periodo analizado se han mantenido en promedio en \$2.262,44 por Kilogramo, con una desviación estándar de \$648,21. El valor mínimo alcanzado fue de \$695 y el valor máximo de \$4.363. En el caso de los precios de granadilla, el precio promedio en la misma ventana de observación fue de \$2.853 por kilogramo, una desviación estándar de \$1.448,9, el precio mínimo alcanzado fue \$614 y el máximo de \$6.797 por kilogramo.

Al descomponer la serie en su parte estacional (de tendencia y residual), se pudo constatar una tendencia variable a través de los años. Para el caso del maracuyá en el año 2015,

se presentó una marcada tendencia, de carácter creciente, que se ha mantenido constante en los años subsiguientes. En la granadilla, la tendencia de crecimiento se inició en el año 2011, con patrón continuo hasta la actualidad. En las dos series se observa una marcada estacionalidad de los precios; para maracuyá, los precios altos son alcanzados en abril y los precios bajos en junio. En el caso de granadilla, los precios altos se alcanzan en junio y julio, mientras que los precios bajos en enero. Esta estacionalidad está relacionada con las épocas de cosecha y con los calendarios escolares, como se indica en el Gráfico II.



Fuente: Corabastos (2020).

**Gráfico II: Descomposición de las series de tiempo del precio de maracuyá y granadilla (\$/Kg)**

Las series de precios de maracuyá y granadilla son estacionarias, resultado corroborado por la prueba de Dickey Fuller, con lo cual al 5% de significancia se rechaza la hipótesis nula (Ho). Los resultados de prueba de raíz unitaria que se obtuvo, es opuesto a los resultados encontrados en precios de nuez de areca en Kerala India (Sabu y Kumar, 2020), y en tomates en Ghana (Boateng et al., 2017) (verTabla 1).

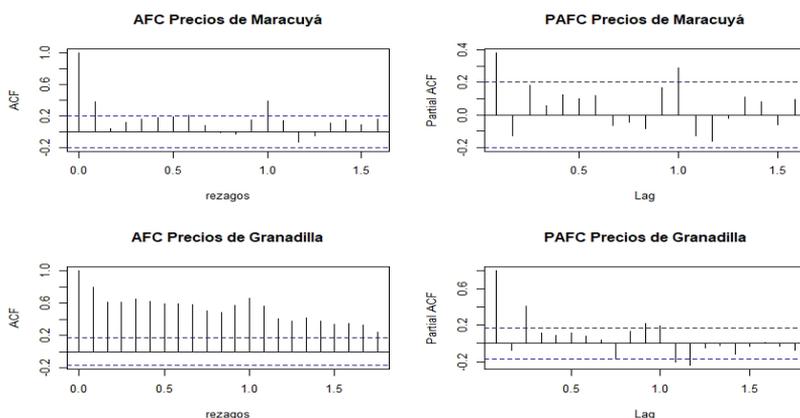
**Tabla 1  
Pruebas de hipótesis de la estacionalidad de la serie Dickey-Fuller**

Maracuyá	Granadilla
Estadístico Dickey-Fuller = - 3,869	Estadístico Dickey-Fuller = - 3,6024
Lag order = 4	Lag order = 5
P-Value = 0.01869	P-Value = 0.03587

Fuente: Elaboración propia, 2020.

Los modelos estacionales presentan características que pueden ser identificadas a través de ACF y PACF, esto permite considerar que los valores que toma la variable observada en el tiempo no son independientes entre sí, sino que un valor determinado depende de valores anteriores. El ACF es la función de autocorrelación, que mide la relación entre dos variables separadas por k periodos, la función

de autocorrelación parcial (PACF), mide la dependencia entre dos variables separadas por k periodos, cuando no se considera la dependencia creada por los retardos intermedios existentes entre ambas. Las funciones de ACF y PACF para cada una de las series observadas, se muestran a continuación en el Gráfico III.



Fuente: Elaboración propia, 2020.

**Gráfico III: Autocorrelaciones simple y parcial para precios de maracuyá y granadilla**

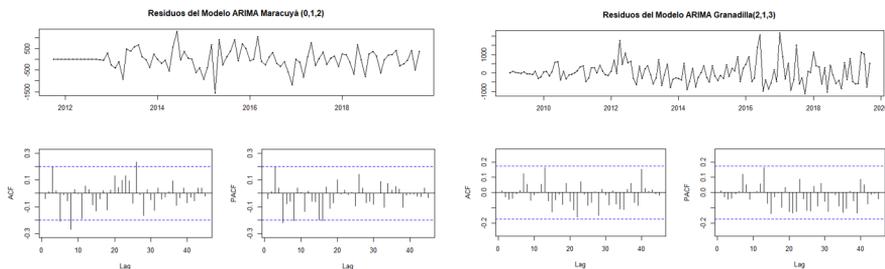
Los gráficos de correlogramas evidencian que las barras tienden a cero, lo que puede considerarse como un comportamiento estacionario de la serie. Adicionalmente, representa el orden del proceso de medias móviles en la parte regular del modelo ARIMA; su decaimiento en el segundo periodo puede significar que se recomienda  $q = 2$ , tanto para la serie de precios de maracuyá como la de granadilla. Usando la función AUTO-ARIMA de la librería FORECAST el mejor modelo ARIMA para cada uno de los precios analizados, se indica en la Tabla 2.

**Tabla 2**  
**Modelos ARIMA para maracuyá y granadilla**

Maracuyá	Granadilla
ARIMA(0,1,2)	ARIM(2,1,3)
AIC=1470,46	AIC= 2025,23

Fuente: Elaboración propia, 2020.

Al obtener los gráficos de residuos de precios de maracuyá y granadilla, para los modelos autorregresivos recomendados ARIMA (0,1,2) y ARIMA (2,1,3), se observan tal como se presenta en el Gráfico IV.



Fuente: Elaboración propia, 2020.

**Gráfico IV: Residuos para los modelos ARIMA (0, 1, 2) y ARIMA (2, 1, 3) de precios para maracuyá y granadilla**

Se puede observar que los residuos no están totalmente centrados en cero, pero los correlogramas no exceden sus valores dentro de los parámetros recomendados para el modelo.

### 3.1. Resultados ARIMA para precios de maracuyá

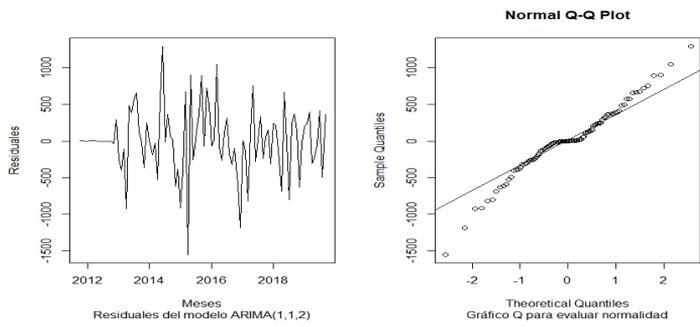
Para mejorar la estimación del modelo propuesto para los precios de maracuyá, se itera bajo diferentes parámetros para el modelo ARIMA, obteniéndose los siguientes resultados que se aprecian en la Tabla 3.

**Tabla 3**  
**Optimización de los parámetros ARIMA para la predicción de los precios de maracuyá**

Modelo ARIMA(p,d,q)(P,D,Q)	AIC
ARIMA(0,1,2) (1,0,0)	1470,016
ARIMA(1,1,0)(2,1,0)	1296,46
ARIMA(1,1,2)(2,1,1)	1285,393
ARIMA(1,1,2)(1,1,1)	1288,771
ARIMA(0,1,1)(0,1,1)	1285,835
ARIMA(1,1,0)(1,1,0)	1310,554
ARIMA(1,2,2)(1,1,0)	1297,879

Fuente: Elaboración propia, 2020.

La mejor estimación de precios de maracuyá es el modelo ARIMA (1,1,2) para la parte del modelo regular, puesto que con este modelo se reduce el AIC a 1285,393. Para validar los supuestos del modelo se desarrolló el análisis de residuos, como se presenta en el Gráfico V.



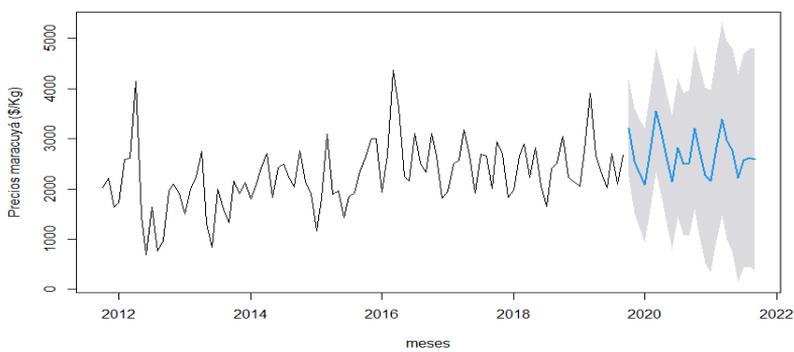
Fuente: Elaboración propia, 2020.

**Gráfico V: Análisis de residuos para el modelo ARIMA (1,1,2) para precios de maracuyá**

En el gráfico QQ plot, para el análisis de residuos se presenta un comportamiento normal. Dentro de los supuestos para mejorar la predicción de los modelos ARIMA es necesario probar la aleatoriedad de cada retardo, aquí la prueba se aplica a los residuos del modelo ARIMA seleccionado, para confirmar si estos no tienen correlación y comprobar está hipótesis se utiliza la prueba de *Box-Ljung* (Ljung y Box, 1978).

La hipótesis nula ( $H_0$ ), los datos se distribuyen de forma independiente es decir que las correlaciones son 0;  $H_a$ : Los datos no se distribuyen de forma independiente, el p-value para el modelo ARIMA (1,1,2) se obtuvo 0,7775 con un nivel de significancia de 0,05 se acepta la  $H_0$ . El modelo cumple con los supuestos propuestos para estimar el modelo ARIMA; en el Gráfico VI, se observa el pronóstico del precio de maracuyá ARIMA (1,1,2).

La hipótesis nula ( $H_0$ ), los datos se



Fuente: Elaboración propia, 2020.

**Gráfico VI: Pronóstico precio de maracuyá ARIMA (1, 1, 2)**

Los parámetros de la ecuación del modelo ARIMA (1,1,2) (2,1,1) para maracuyá, responde a la Tabla 4.

**Tabla 4**  
**Coefficientes del modelo ARIMA (1, 1,2) (2, 1,1) de precios de maracuyá**

Coefficientes	ar1	ma1	ma2	sar1	sma1
	0,8066	-1,5071	0,5071	-0,1355	-0,4123
e.e.	0,1195	0,1596	0,1513	0,1355	0,2424

**Nota:** e.e. (Error Estándar).

**Fuente:** Elaboración propia, 2020.

### 3.2. Resultados ARIMA precios de granadilla

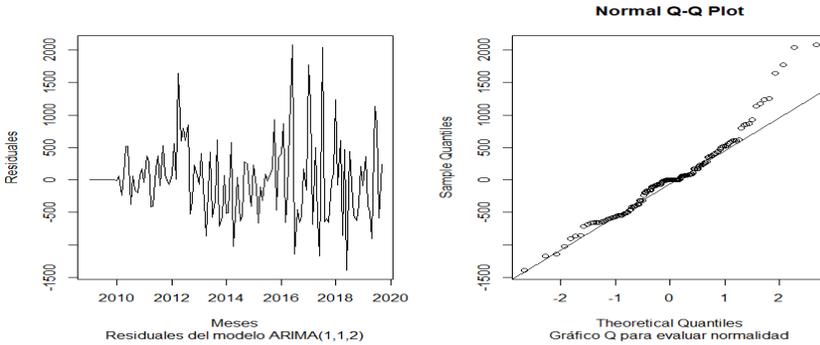
De acuerdo a los resultados de las pruebas obtenidas anteriormente, los precios de granadilla, al igual que los de maracuyá, cumplen con las características para utilizar los modelos ARIMA para pronosticar el precio. Para estimar el mejor desempeño a partir del criterio de información de Aikake (AIC) se utiliza la función AUTO.ARIMA, que permite la estimación de los diferentes valores de (p, d, q) para encontrar el modelo óptimo y eficiente. El modelo recomendado es ARIMA (2,1,3) con un AIC=2024,02, al iterar 8 modelos adicionales se presenta en la Tabla 5.

**Tabla 5**  
**Optimización de los parámetros ARIMA para la predicción de precios de granadilla**

Modelo ARIMA(p,d,q)(P,D,Q)	AIC
ARIMA(0,1,2) (1,0,0)	2034,354
ARIMA(1,1,0)(2,1,0)	1876,156
ARIMA(1,1,2)(2,1,1)	1847,456
ARIMA(1,1,1)(2,1,1)	1853,610
ARIMA(1,1,2)(1,1,1)	1845,803
ARIMA(0,1,1)(0,1,1)	1853,555
ARIMA(1,1,0)(1,1,0)	1881,495
ARIMA(12,2,2)(1,1,0)	1849,681
ARIMA(2,1,3)(1,0,1)	2024,018

**Fuente:** Elaboración propia, 2020.

El modelo que minimiza y mejora la eficiencia del modelo es ARIMA (1,1,2), con un AIC = 1845,803 que disminuye significativamente con el recomendado ARIMA (2,1,3). Se continúa con la validación de supuestos del modelo, como se muestra en el Gráfico VII.



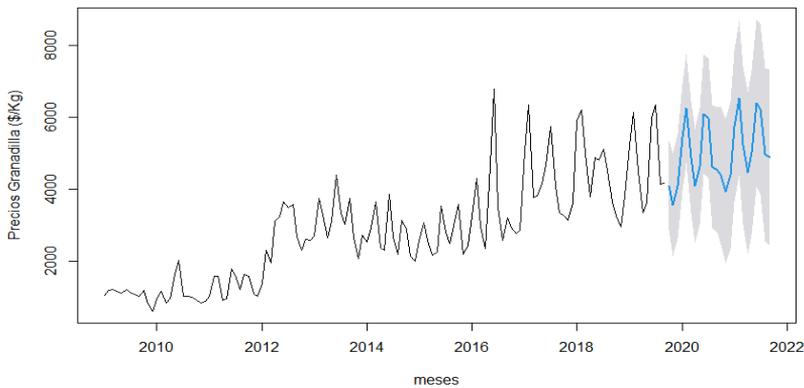
Fuente: Elaboración propia, 2020.

**Gráfico VII: Análisis de residuos para el modelo ARIMA (1,1,2) para precios de granadilla**

Los residuos muestran un comportamiento normal como se valida en la figura *QQ plot* de los residuos del modelo seleccionado. Para verificar los supuestos de autocorrelación de los residuos igual a cero para determinar su independencia se utiliza la prueba de *Box-Ljung* (Ljung y Box, 1978).

Los resultados obtenidos para el modelo es un p-value de 0,8224 con un nivel de significancia de 0,05, por lo que no

se puede rechazar la hipótesis nula ( $H_0$ ), en consecuencia, se acepta la  $H_0$ . Lo que concluye, que los residuos se distribuyen de forma independiente, que indica una correlación igual a 0. La validación muestra que los residuos obtenidos a partir del modelo ARIMA (1,1,2) (1,1,1), se recomienda, puesto que minimiza el AIC como se explicó anteriormente. El pronóstico se puede observar en el Gráfico VIII.



Fuente: Elaboración propia, 2020.

**Gráfico VIII: Pronóstico del modelo ARIMA (1,1,2) (1,1,1) de precios de granadilla**

Los parámetros de la ecuación del modelo ARIMA (1,1,2) (1,1,1) para granadilla, se indica a continuación en la Tabla 6.

**Tabla 6**  
**Coefficientes del modelo ARIMA (1,1,2) (1, 1,1) de precios de granadilla**

Coefficientes	ar1	ma1	ma2	sar1	sma1
	-0,25	-0,17	-0,50	0,1107	-0,70
e.e.	0,1778	0,1456	0,0972	0,1556	0,1406

**Nota:** e.e. (Error Estándar).

**Fuente:** Elaboración propia, 2020.

### 3.3. Resultados de componentes no observados y regresión markoviana

De acuerdo a los resultados obtenidos de AIC de los modelos propuestos para los precios de maracuyá y granadilla, se puede

observar en la Tabla 7, que los valores de AIC se minimizan para los modelos ARIMA. Comparando solo entre estas metodologías, en el caso de maracuyá el mejor es el modelo de componentes no observados, resultado similar para los precios de granadilla.

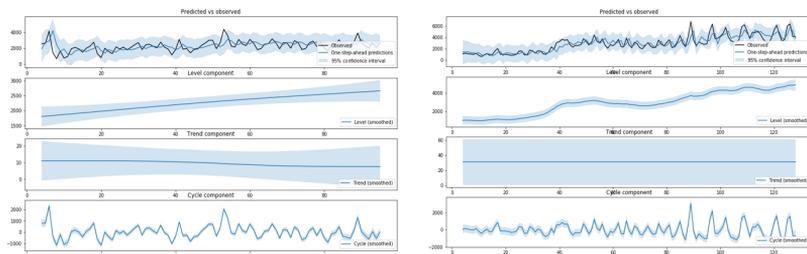
**Tabla 7**  
**Resultados obtenidos para los modelos componentes no observados y regresión markovianos para precios de maracuyá y granadilla**

Precios	Modelo	AIC
Maracuyá	Componentes no observados	1457,873
	Regresión markoviana	1511,286
Granadilla	Componentes no observados	2023,149
	Regresión markoviana	2160.659

**Fuente:** Elaboración propia, 2020.

Al comparar los datos observados con la estimación del modelo de componentes no observados para los precios de maracuyá y granadilla, como lo muestra el Gráfico IX, se puede observar que el componente de tendencia del maracuyá es negativo (figura de la izquierda), mientras para la granadilla

la tendencia de los precios estimados por el modelo es baja. Estos resultados difieren de los encontrados en el mercado de mango en Varanasi, que reporta un incremento en los precios que beneficia significativamente a los productores (Pardhi et al., 2018).



Fuente: Elaboración propia, 2020.

**Gráfico IX: Validación de supuestos del modelo de componentes no observados para precios de maracuyá y granadilla**

Por otro lado, puede confirmarse la conclusión que el filtro de *Hodrick-Prescott* puede llevar a que se extraigan conclusiones engañosas sobre la relación entre los movimientos a corto plazo en las series de tiempo macroeconómicas (Harvey y Jaeger, 2008).

Finalmente, con relación a los resultados, los precios de maracuyá y granadilla se ajustan mejor a los modelos de pronóstico ARIMA (1,1,2) (2,1,1) y ARIMA (1,1,2) (1,1,1), el cual es un modelo ventajoso porque permite predecir la magnitud de cualquier variable.

## Conclusiones

La dinámica de la economía global y, particularmente, el cambio climático, hacen de la planificación de cultivos una tarea titánica puesto que maximizan los riesgos de pérdida de ingresos debido a la incertidumbre que originan en el comportamiento de los precios. El rendimiento de los cultivos tiene también un efecto sobre la planificación debido a su fluctuación, la cual no es tan determinante y aleatoria como lo observado con el precio.

La estimación de modelos estadísticos para precios, con relación particular a las materias primas, considerados en este trabajo, representan aportes al conocimiento del ajuste de la colección de datos de precios de dos *commodities*, a través de la estimación de

parámetros de modelos estadísticos univariados para series de tiempo de naturaleza estocástica, permitiendo entender su comportamiento e inferir acerca de sus características.

El modelo ARIMA es adecuado para analizar las series temporales, los modelos económicos se utilizan para describir y predecir este tipo de series. Su implementación es relativamente sencilla, siempre y cuando se cuente con la información y la capacidad computacional para procesar la misma. Además, estas herramientas facilitan la generación de información para la toma de decisiones de los agricultores, disminuyendo el riesgo de las inversiones.

A través de este análisis, también se demuestra que la fluctuación de los precios depende del cultivo, mientras el maracuyá tiene una tendencia suavizada, la granadilla tiene este patrón mucho más marcado. Lo que podría sugerir que, dependiendo de la elección del cultivo, el ingreso del agricultor pueda variar. Este comportamiento confirma la denominada política de portafolio, en donde la multiplicidad de cultivos infiere un aumento en los ingresos, minimizando los riesgos y por ende las pérdidas económicas.

## Referencias bibliográficas

Alonso, J. C., y Arcila, A. M. (2013). Empleo del comportamiento estacional

- para mejorar el pronóstico de un commodity: El caso del mercado internacional del azúcar. *Estudios Gerenciales*, 29(129), 406-415. <https://doi.org/10.1016/j.estger.2013.11.006>
- Boateng, F. O., Amoah-Mensah, J., Anokye, M., Osei, L., y Dzebre, P. (2017). Modeling of Tomato prices in Ashanti Region, Ghana, using seasonal autoregressive integrated moving average model. *British Journal of Mathematics & Computer Science*, 20(2), 1-13. <https://doi.org/10.9734/bjmcs/2017/30535>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., y Ljung, G. M. (2016). *Time series analysis: Forecasting and control*. John Wiley & Sons, Inc
- Cleves, A., Jarma, A. D. J., y Fonseca, J. (2009). Manejo integrado del cultivo de maracuyá (*Passiflora edulis f. flavicarpa*). En D. Miranda, G. Fischer, C. Carranza, S. Magnitskiy, F. Casierra, W. Piedrahita y L. E. Flórez (Eds.), *Cultivo, poscosecha y comercialización de las pasifloráceas en Colombia: Maracuyá, Granadilla, Gulupa y Curuba* (pp. 97-120). Sociedad Colombiana de Ciencias Hortícolas.
- Cleves, J. A., Jarma, A. D. J., y Acened, G. (2012). Cultivo del maracuyá (*Passiflora edulis Sims f. flavicarpa* y *f. purpurea L.*). En G. Fischer (Ed.), *Manual para el cultivo de frutales en el trópico* (pp. 682-700). Editorial Produmedios.
- Corporación de Abastos de Bogotá S.A. – Corabastos (2020). Histórico de precios. Corabastos. <https://precios.precioscorabastos.com.co/#/>
- Costa, J. M., y Ruffo, A. (2019). Regímenes de inflación y dinámica de precios minoristas. Un estudio empírico para la Argentina. *Revista de Economía Política de Buenos Aires*, (18), 949.
- Cryer, J. D., y Chan, K-S. (2008). *Time series analysis with applications in R*. Springer. <http://dx.doi.org/10.1007/978-0-387-75959-3>
- Dalinina, R. (2017). Introduction to forecasting with ARIMA in R. <https://www.kdnuggets.com/2017/01/datascience-introduction-forecasting-arima-r.html>
- Dharavath, R., y Khosla, E. (2019). Seasonal ARIMA to forecast fruits and vegetable agricultural prices. *Proceedings - 2019 IEEE International Symposium on Smart Electronic Systems, ISES 2019*, 47-52. <https://doi.org/10.1109/ISES47678.2019.00023>
- Github (2020). *Series temporales en castellano*. Github. [https://github.com/FrancisArgnR/SeriesTemporaleEnCastellano#arima-\(autoregressive-integrated-moving-average\)](https://github.com/FrancisArgnR/SeriesTemporaleEnCastellano#arima-(autoregressive-integrated-moving-average))
- Harvey, A. C., y Jaeger, A. (2008). Detrending, stylized facts and the business cycle. *Journal of Applied Econometrics*, 8(3), 231-247.
- Hodrick, R. J., y Prescott, E. C. (1997). Post-War U.S. business cycles: An empirical investigation. *Journal of Money, Credit and Banking*, 29(1), 1-16.
- Jadhav, V., Chinnappa, B. V., y Gaddi, G. M. (2017). Application of ARIMA model for forecasting agricultural prices. *Journal Agricultural Science and Technology (JAST)*, 19(4), 981-992.
- Kantanatha, N. (2007). *Crop decision planning under yield and price uncertainties* [doctoral thesis, Georgia Institute of Technology]. [https://smartech.gatech.edu/bitstream/handle/1853/24676/kantanatha\\_nantachai\\_200708\\_phd.pdf](https://smartech.gatech.edu/bitstream/handle/1853/24676/kantanatha_nantachai_200708_phd.pdf)
- Kazaz, B. (2004). Production Planning Under Yield and Demand Uncertainty with Yield-Dependent Cost and Price. *Manufacturing & Service Operations*

- Management*, 6(3), 209-224. <https://doi.org/10.1287/msom.1030.0024>
- Lee, H., Bogner, C., Lee, S., y Koellner, T. (2016). Crop selection under price and yield fluctuation: Analysis of agro-economic time series from South Korea. *Agricultural Systems*, 148, 1-11. <https://doi.org/10.1016/j.agsy.2016.06.003>
- Ljung, G. M., y Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303. <https://doi.org/10.1093/biomet/65.2.297>
- Montecé, M. K., Peláez, F. R., Godoy, V. H., y Vásconez, F. del C. (2021). Sistema de producción y calidad del forraje de Moringa en Ecuador. *Revista de Ciencias Sociales (Ve)*, XXVII(E-3), 459-470.
- Pardhi, R., Singh, R., y Kumar, R. (2018). Price forecasting of Mango in Varanasi Market of Uttar Pradesh. *Current Agriculture Research Journal*, 6(2), 218-224. <https://doi.org/10.12944/carj.6.2.12>
- Paredes-García, W. J., Ocampo-Velázquez, R. V., Torres-Pacheco, I., y Cedillo-Jiménez, C. A. (2019). Price forecasting and span commercialization opportunities for Mexican agricultural products. *Agronomy*, 9(12), 826. <https://doi.org/10.3390/agronomy9120826>
- Ramírez, L. N., González, G. P., y Cleves-Leguizamo, J.-A. (2021). Mathematical modeling of climatological data to estimate passion fruit crop yield (*Passiflora edulis Sims L. f. Flavicarpa* y *f. Purpurea*). *Revista Brasileira de Fruticultura*, 43(3), e-182. <https://dx.doi.org/10.1590/0100-29452021182>
- Ramírez, L. N., y Potes, S. (2019). Estimación del rendimiento del cultivo de *Passiflora edulis* (Maracuyá) a partir de modelos estadísticos. *Inventum*, 14(26), 33-42. <https://doi.org/10.26620/uniminuto.inventum.14.26.2019.33-42>
- Reddy, A. A. (2019). Price forecasting of Tomatoes. *International Journal of Vegetable Science*, 25(2), 176-184. <https://doi.org/10.1080/19315260.2018.1495674>
- Sabu, K. M., y Kumar, T. K. M. (2020). Predictive analytics in agriculture: Forecasting prices of Arecanuts in Kerala. *Procedia Computer Science*, 171, 699-708. <https://doi.org/10.1016/j.procs.2020.04.076>
- Schermelleh-Engel, K., Moosbrugger, H., y Müller, H. (2003). Evaluating the fit of structural equation models: Tests of significance and descriptive goodness-of-fit measures. *Methods of Psychological Research*, 8(2), 23-74.
- Stasmodels (2020). *Stasmodels v0.11.0: Statistical models, hypothesis tests, and data exploration*. <https://www.stasmodels.org/v0.11.0/>
- Urdaneta, A., y Borgucci, E. (2018). Shocks petroleros y demanda de dinero en Venezuela 1988-2017. *Revista de Ciencias Sociales (Ve)*, XXIV(3), 108-126.
- Weng, Y., Wang, X., Hua, J., Wang, H., Kang, M., y Wang, F.-Y. (2019). Forecasting horticultural products price using ARIMA model and neural network based on a large-scale data set collected by web crawler. *IEEE Transactions on Computational Social Systems*, 6(3), 547-553. <https://doi.org/10.1109/TCSS.2019.2914499>
- Zhang, G., Shang, J., y Li, W. (2011). Collaborative production planning of supply chain under price and demand uncertainty. *European Journal of Operational Research*, 215(3), 590-603. <https://doi.org/10.1016/j.ejor.2011.07.007>