

Pronóstico para la producción de cebolla de rama a partir de un modelo VAR

Forecast scallion production based on a VAR model

Carlos Andrés Chaparro Arias ^{1,2}, Juan Carlos Ruiz Torres ^{1,3}, Gina Paola Fonseca Cifuentes ^{1,4}.

¹Universidad Pedagógica y Tecnológica de Colombia. Tunja, Colombia. ²  chaparroarias@uptc.edu.co; ³  juan.ruiz@uptc.edu.co;

⁴  gina.fonseca01@uptc.edu.co



<https://doi.org/10.15446/acag.v73n1.115618>

2024 | 73-1 p 82-91 | ISSN 0120-2812 | e-ISSN 2323-0118 | Rec.: 2024-07-07 Acep.: 2025-01-08

Resumen

Este trabajo tiene como objetivo desarrollar un modelo de pronóstico VAR (modelo vectorial autorregresivo) para la producción de cebolla de rama con datos del municipio de Aquitania, Boyacá (Colombia), a partir de métodos de series temporales multivariadas. La metodología ha incluido la materialización de fases de estudio de acuerdo con el método de Box-Jenkins y la aplicación de una serie de pruebas estadísticas de estacionariedad Phillips-Perron, raíz unitaria Dickey-Fuller aumentada (ADF), pruebas de normalidad de Jarque-Bera, test de Phillips-Ouliaris y prueba de causalidad de Granger, entre otras. Los resultados de este estudio confirman que el modelo VAR es una herramienta efectiva para la planificación de la producción y el área cosechada de cebolla de rama. Su capacidad predictiva facilita la toma de decisiones estratégicas, lo cual optimiza la gestión agrícola.

Palabras clave: área de campo, cebolla, modelización de los cultivos, producción, producto básico.

Abstract

This work aims to develop a VAR - forecast model for scallion production with data from the municipality of Aquitania, Boyacá (Colombia), using multivariate time series methods. The methodology included the implementation of study phases in accordance with the Box-Jenkins method, as well as the application of a series of statistical tests, including the Phillips-Perron stationarity test, the augmented Dickey-Fuller (ADF) unit root test, the Jarque-Bera normality test, the Phillips-Ouliaris test, the Granger causality test, among others. The results of this study confirm that the VAR model is an effective tool for planning the production and harvested area of scallion. Its predictive capacity facilitates strategic decision-making, optimizing agricultural management.

Keywords: Commodities, crop modelling, farm area, scallion, production.

Introducción

Eventos como la globalización de los mercados, las cadenas de valor, la celeridad en las innovaciones tecnológicas e institucionales, las limitaciones ambientales y el incremento de los precios de bienes agrícolas han ocasionado que la agricultura regrese a la agenda mundial y, por ende, al desarrollo económico de los países; estos hechos reconocen la multiplicidad de funciones que ejerce el sector, entre las que se encuentran, además del crecimiento económico, la disminución de la pobreza y el hambre, la sostenibilidad ambiental y la equidad y seguridad alimentaria (Naciones Unidas, 2021; Perfetti *et al.*, 2013).

Los productores agrícolas se enfrentan a diversas amenazas, entre las que se destacan la volatilidad del sector, las fluctuaciones de precios y los efectos del cambio climático, que generan incertidumbre en la producción y el suministro de alimentos. Estas condiciones adversas impactan tanto la actividad económica real como los mercados financieros, lo cual provoca inestabilidad en los precios (Chen *et al.*, 2023). En este contexto, la reducción en la producción, derivada de los cambios en la temperatura y la variabilidad climática, representa un riesgo significativo, especialmente en regiones de bajos ingresos. Para mitigar estas pérdidas, es fundamental implementar estrategias que fortalezcan la resiliencia del sector, promoviendo políticas e inversiones orientadas a reducir la vulnerabilidad y garantizar la estabilidad en la oferta. De lo contrario, el incremento en los costos de producción se trasladará al precio final para el consumidor, lo que afecta el acceso a los alimentos y la seguridad alimentaria en general (Antunes de Araujo *et al.*, 2020; Baffes y Kabundi, 2023; Ding y Xu, 2023).

En tal sentido, los *commodities* se identifican como mercados en crecimiento que incluyen productos agrícolas fundamentales para la alimentación de las personas y, por lo tanto, materias primas necesarias en los procesos industriales (Antunes de Araujo *et al.*, 2020; Ouyang y Zhang, 2020). Es así que los *commodities* agrícolas provienen principalmente de actividades primarias (Michail y Melas, 2020) y de economías con un menor nivel de desarrollo, cuyo consumo se lleva a cabo casi inmediatamente luego de un limitado proceso de transformación (Del Giorgio *et al.*, 2022). En el caso colombiano la participación agrícola tiene relevancia en la economía, ya que es un sector generador de empleo e ingresos para la población económicamente activa. Sin embargo, es afectado, entre otros, por factores económicos, políticos, sociales y ambientales (Fonseca-Cifuentes *et al.*, 2021).

En el caso del modelo vectorial autorregresivo (VAR), se explica como una técnica utilizada para realizar pronósticos en sistemas con múltiples series temporales interrelacionadas (Li y Umair, 2023). Este

enfoque es especialmente útil cuando, al menos, 2 series temporales influyen entre sí, lo que implica una relación bidireccional entre las variables analizadas (Sujath *et al.*, 2020).

El modelo VAR ha sido utilizado con éxito en diversos estudios sobre la determinación de precios de alimentos básicos. Firmansyah *et al.* (2023) compararon el modelo VAR con el modelo de corrección de errores vectoriales (VECM) para modelar los precios de la carne de vacuno en varias provincias de las islas de Sumatra, Java, Bali y Nusa Tenggara. Por su parte Sumertajaya *et al.* (2024) desarrollaron un modelo de pronóstico de precios de productos alimenticios en Indonesia, aplicando el agrupamiento de series temporales multivariadas y el método de imputación autorregresiva de vectores promedio móvil (VAR-IMMA).

En la apicultura, un estudio en Sicilia (sur de Italia) monitoreó colmenas en 3 lugares distantes para analizar las interrelaciones entre factores internos (peso, temperatura, humedad y nivel de presión sonora) y parámetros ambientales internos y externos (temperatura, humedad, lluvia, viento e índice UV). Utilizando un modelo VAR se identificó una relación significativa entre el peso de la colmena, su temperatura interna y su humedad relativa, lo cual permitió construir un modelo predictivo para comprender la posibilidad de intervención en las colmenas (Bono *et al.*, 2024).

De tal manera que este artículo tiene como objetivo desarrollar un modelo de pronóstico VAR para la producción y el área cosechada de cebolla de rama, mediante la aplicación de métodos de series temporales multivariadas. Para ello, se analizó la información histórica registrada en la Red de Información del Sector Agropecuario desde el segundo semestre de 2006 hasta el segundo semestre de 2022, enfocándose en el municipio de Aquitania, Boyacá. Este municipio es el principal productor de cebolla de rama en Colombia, involucra a la mayor parte de su población y aporta aproximadamente el 70 % de los ingresos de la economía local. Con una siembra anual promedio de 3800 hectáreas y una producción de 100 750 toneladas, Aquitania ocupa el primer lugar en producción dentro del departamento de Boyacá, junto con la producción de papa (Alcaldía Municipal Aquitania, 2020).

Materiales y métodos

Datos

La información del cultivo de cebolla de rama del municipio de Aquitania, Boyacá, proviene de las evaluaciones agropecuarias (EVA) y del Anuario Estadístico del Sector Agropecuario (Ministerio de Agricultura y Desarrollo Rural, 2024), los cuales consideran las variables de área cosechada y

producción. Los datos fueron procesados mediante el *software* R Studio versión 4.3.1., en el cual fueron consideradas 6 variables categorizadas, como se muestra la Tabla 1.

Métodos y pruebas estadísticas

El modelo fue desarrollado de acuerdo con la metodología Box-Jenkins (Figura 1) y materializado a partir de 4 etapas: a) identificación del modelo, b) estimación de los parámetros, c) diagnóstico del modelo basado en residuos y, d) generación de las predicciones.

Para el análisis se han considerado inicialmente las siguientes hipótesis como base para la determinación de los supuestos del modelo con un nivel de significancia del 5 %:

H_0 : la serie temporal se considera no estacionaria porque mantiene raíz unitaria mayor al nivel de significancia.

H_1 : la serie temporal se considera estacionaria menor al nivel de significancia.

A partir de estas, posteriormente se realizan las pruebas de estacionariedad Phillips-Perron y la raíz unitaria Dickey-Fuller aumentada (ADF). La prueba de estacionariedad de Phillips y Perron (1988) se utiliza en el análisis de series de tiempo para evaluar la hipótesis nula de que una serie está integrada, es decir, que posee una raíz unitaria y sigue una caminata aleatoria (raíz unitaria). De tal manera, asume que el proceso de generación de Y_i sigue un orden superior de autocorrelación admitido por la ecuación de prueba, ocasionando que Y_{t-1} sea de carácter endógeno, realizando correcciones no paramétricas

Tabla 1. Variables de estudio según evaluación agropecuaria por consenso

Tipo de variable	Nombre de la variable	Descripción
Cualitativa	Periodo	A (primer semestre) y B (segundo semestre).
Cuantitativa	Área sembrada (Ha)	Superficie en hectáreas (Ha) donde se ha realizado la siembra de un cultivo, sin importar si ha germinado o alcanzado su etapa de producción.
Cuantitativa	Área cosechada (Ha)	Extensión de la cual se obtiene la producción en hectáreas (Ha).
Cuantitativa	Producción (t)	Volumen obtenido, en toneladas (t), del área cosechada.
Cuantitativa	Rendimiento (t/Ha)	Toneladas (t) obtenidas por hectárea de cultivo (Ha).

Fuente: Ministerio de Agricultura y Desarrollo Rural, 2024




Figura 1. Metodología Box-Jenkins. Fuente: Uribe et al. (2017).

en el estadístico de prueba e invalidando la prueba de Dickey-Fuller (Meneses-Cerón y Pérez-Pacheco, 2020). Por tanto, la raíz unitaria es un caso de no estacionariedad, en el que la serie temporal tiene una tendencia estocástica persistente en el tiempo.

Una vez con los resultados, se ha establecido la prueba de causalidad a partir de las siguientes hipótesis:

H_0 : el tipo de producción no es causal en el sentido Granger (sirve para predecir); el área cosechada (Ha) de la cebolla de rama de forma semestral es mayor al nivel de significancia.

H_1 : el tipo de producción sí es causal en el sentido Granger (sirve para predecir); el área cosechada (ha) de la cebolla de rama de forma semestrales menor al nivel de significancia.

La prueba de causalidad de Granger es una prueba de hipótesis estadística con el fin de establecer si la serie de tiempo es útil para el pronóstico de otra y permite responder preguntas como ¿los cambios en Y_1 causan cambios en Y_2 ? ¿puede el pasado de Y_1 mejorar la predicción futura de Y_2 ? (causalidad bidireccional); ¿el conocimiento del futuro de Y_1 ayuda en el mejoramiento de la predicción de Y_2 ? (causalidad instantánea). Luego, para la selección del modelo y a partir del test de Phillips-Ouliaris, se han incluido las siguientes hipótesis, con el propósito de identificar si la serie temporal permite cointegraciones.

H_0 : la serie temporal no permite cointegración de las variables.

H_1 : la serie temporal sí permite cointegración de las variables.

Supuestos del modelo

A partir de la prueba de estacionariedad presentada en la Tabla 2 se validan las hipótesis. De acuerdo con los criterios de las pruebas estadísticas de estacionariedad (Phillips-Perron) y raíz unitaria (Dickey-Fuller), para la variable *área cosechada* los resultados son menores a 0.05, por lo cual se acepta la hipótesis alterna con un 95 % de confianza, ya que los datos siguen un comportamiento estacionario. Igualmente para el caso de la producción las pruebas estadísticas, son mayores a 0.05, por lo cual se acepta la hipótesis nula con un 95 % de confianza, ya que los datos no siguen un comportamiento estacionario.

Tabla 2. Resultados de prueba de estacionariedad y raíz unitaria

Test	Phillips-Perron	Dickey-Fuller
Función	ur.pp	ur.df
Criterio estadístico	p-value	p-value
Producción	0.758	9.029e-06
Área cosechada	0.01711	0.006218

Fuente: elaboración propia.

Resultados

Selección del modelo

Luego, a partir de la teoría de la cointegración se establece que, aunque las series originales sean no estacionarias, puede que existan combinaciones lineales de equilibrio entre estas que mantengan el carácter estacionario (a estas relaciones de largo plazo se les denomina relaciones de cointegración). En los modelos VEC (vector de correlación de errores) se intenta establecer un marco único con la integración de las relaciones de largo plazo estacionarias (reunidas a través de relaciones de cointegración) junto con las dependencias dinámicas de corto plazo conseguidas a través de modelos VAR (Novales, 2017).

De esta manera la generación del modelo ha considerado: a) identificación del número de rezagos, b) test de Phillips-Ouliaris, c) identificación del número de relaciones de cointegración.

Identificación del número de rezagos

El número de rezagos sugeridos y su criterio de selección se encuentran en la Tabla 3.

El modelo ha considerado el criterio de información Hannan-Quinn (HQ), que es una medida de bondad de ajuste del modelo estadístico, utilizada en la selección de un modelo frente a un conjunto finito de estos. De este modo, la medida introduce un término de penalización para el número de parámetros, de tal forma que, dados dos modelos estimados, el modelo con menor valor en HQ es preferido, lo que implica un número menor de variables explicativas, mejor ajuste o ambos elementos. Puede ser utilizado en la comparación de los modelos estimados cuando los valores numéricos de la variable dependiente son idénticos para que todas las estimaciones sean comparadas (Kamila, 2022). De esta manera el orden del VEC corresponde siempre a uno menos que el VAR (Novales, 2017), por tanto, y de acuerdo con los resultados para el desarrollo del modelo, se inicia con 1.

Test de Phillips-Ouliaris

Posteriormente se establece el cálculo del estadístico $Z(\alpha)$ de Phillips-Perron para una raíz unitaria en los residuos de la regresión de cointegración. La raíz unitaria se estima a partir de una regresión de la

Tabla 3. Rezagos sugeridos identificados

Indicador	Rezagos	Criterio
Akaike (AIC)	1	2.753201e+01
Hannan-Quinn (HQ)	1	2.761928e+01
Schwartz (SC)	1	2.781748e+01
Error de predicción final (FPE)	1	9.072289e+11

Fuente: elaboración propia.

primera variable (columna) de X sobre las restantes variables de x sin constante y con tendencia lineal. Para estimar la varianza se utiliza el estimador de Newey-West. Si la estadística calculada está fuera de la tabla de valores críticos, se genera un mensaje de advertencia. Una vez con los resultados $p\text{-value}=0.07275$ se acepta la hipótesis nula, es decir, la serie temporal no permite cointegración de las variables.

Identificación del número de relaciones de cointegración

En esta etapa se establece el número de relaciones de cointegración independientes, o de largo plazo, existente entre las variables. A este número se le denomina *rango de cointegración*. En general, si se tiene n series no estacionarias el rango de cointegración puede oscilar entre los valores 0, 1, ..., $n - 1$ (Novales, 2017). Se ha estimado un VECM mediante el cual se ha incluido una tendencia determinística en la relación de cointegración. Es así como en la primera y segunda hipótesis nula $r = 0$ y $r \geq 1$, dado que el estadístico de prueba 4.78 y 3.84 no excede todos los valores críticos, la primera y segunda hipótesis no se pueden rechazar. Por lo tanto, la cointegración se encuentra $r = 0$ y $r \leq 1$ bajo estadísticas de valores propios máximos (Tabla 4).

Validación del modelo

Para el proceso de discusión y validación del modelo se han realizado las pruebas de normalidad, pruebas de autocorrelación serial, prueba de impulso respuesta, descomposición de la varianza de error de pronóstico (FEVD), prueba de cointegración Phillips-Ouliaris, prueba de homocedasticidad y prueba de causalidad de Granger.

Prueba de normalidad

Esta prueba ha considerado los criterios de la prueba Jarque-Bera, utilizada para contrastar la hipótesis de normalidad en una muestra de datos con media y varianza desconocida (Glinskiy et al., 2024). Dicha prueba se basa en el análisis de la asimetría (medición de la menor o mayor simetría de la distribución existente entre 2 medidas) y la curtosis (medición de la mayor o menor concentración de datos alrededor de la media), lo que permite determinar la irregularidad de la distribución (Malá et al., 2021). Para ello han sido consideradas las siguientes hipótesis:

H_0 : los residuales del modelo se distribuyen normalmente $P - \text{valor} > 0.05$. No se rechaza.

H_1 : los residuales del modelo no se distribuyen normalmente $P - \text{valor} < 0.05$. No se acepta la hipótesis nula y se acepta la hipótesis alternativa.

De acuerdo con los resultados de la prueba de normalidad en la Tabla 5, se acepta la hipótesis alterna: los residuales del modelo no se distribuyen normalmente.

Adicional a las pruebas cuantitativas se realizaron figuras para visualizar la distribución. En la Figura 2 se identifica la independencia de los residuos. Si el $p\text{-value}$ obtenido es pequeño esto indica que no existe aleatoriedad, en cambio, cuanto mayor es su $p\text{-valor}$ más evidencia hay de que los residuos son ruido blanco. Para que un modelo sea válido, los diferentes análisis sobre los residuos obtenidos en la estimación deben ser ruido.

Pruebas de autocorrelación serial

La media y la varianza desempeñan un papel importante en el estudio de distribuciones estadísticas, ya que incluyen 2 propiedades distributivas clave: la ubicación central y la dispersión.

Por tanto, el criterio de decisión se especifica, en el sentido de rechazar la hipótesis nula, si el valor de la probabilidad es menor al nivel de significancia (Morán-Chiquito, 2014), de este modo se establece:

H_0 : los residuales del modelo no están correlacionados. No se rechaza.

H_1 : los residuales del modelo sí están correlacionados. No se acepta la hipótesis nula y se acepta la hipótesis alternativa.

Es así como los resultados $p\text{-value}$ son menores a 0.05, lo que indica que los residuales del modelo, están correlacionados, por tanto, se acepta la hipótesis alternativa, los residuales, no están correlacionados, como se aprecia en la Figura 2.

Prueba de impulso-respuesta

Esta prueba es un instrumento útil para evaluar la congruencia y la sensibilidad dinámica de las variables especificadas en el modelo, por tal razón, es eficiente para evaluar y proponer políticas económicas. Las funciones generalizadas de impulso-respuesta (FGIR) permiten establecer la respuesta dinámica de una

Tabla 4. Test de Phillips-Ouliaris

r	Test 1	1 %	5 %	10 %
≤ 1	3.84	12.97	9.24	7.52
$= 0$	4.78	20.20	15.67	13.75

Fuente: elaboración propia.

Tabla 5. Resultados de la prueba de normalidad

Test	Normalidad
Criterio estadístico	$p\text{-value}$
JB-Test (multivariate)	0.01775
Skewness only (multivariate)	0.01054
Kurtosis only (multivariate)	0.2415

Fuente: elaboración propia.




Figura 2. Residuales del modelo EDF (función de distribución empírica), ACF (función de autocorrelación), PACF (función de autocorrelación parcial).
Fuente: elaboración propia.

determinada variable del sistema ante choques (o cambios no anticipados) en alguna otra variable (Morán-Chiquito, 2014). De esta manera el análisis de respuesta al impulso se basa en la representación de la media móvil mundial del proceso VAR(p). Por tanto, la prueba fue aplicada entre todas las variables, evidenciando que responden a los estímulos generados por las demás variables, situación que se puede apreciar en la Figura 3.

Descomposición de la varianza FEVD

La descomposición de la varianza indica la cantidad de información que cada variable aporta a las otras variables en la autorregresión. Además, determina cuánto de la varianza del error de pronóstico de cada una de las variables puede explicarse por choques exógenos a las otras variables. De igual forma, las descomposiciones de varianzas establecen en qué medida (o en qué porcentaje) una variable es influida por innovaciones en otra variable (Cuevas-Ahumada, 2008).

En la Figura 4 se descompone la varianza, lo que en términos generales redunda en el grado de incidencia de esta en las diferentes variables. En el

caso de la producción total acumulada a lo largo de los distintos periodos, su variabilidad es inherente a la propia variable. Asimismo, a lo largo del tiempo se observa cuantitativamente la influencia de la variable *área cosechada*, lo cual evidencia su incidencia en la dinámica productiva.

Prueba de cointegración Phillips-Ouliaris

En la hipótesis nula de la no cointegración se encuentra una lenta tasa de convergencia de las estadísticas de prueba (Reimers, 1992). De esta manera:

H_0 : las series no son cointegradas. No se rechaza.

H_1 : las series sí son cointegradas; existe evidencia para sostener que las series son cointegradas, es decir, que hay una tendencia a largo plazo. No se acepta la hipótesis nula y se acepta la hipótesis alternativa.

Los resultados permiten establecer un valor de $p\text{-value} = 0.07275$, por lo que no hay evidencia para el rechazo de la hipótesis nula de las series cointegradas, es decir, mantienen una tendencia de largo plazo.




Figura 3. Test impulso-respuesta de la producción y área cosechada. Fuente: elaboración propia.




Figura 4. Descomposición de la varianza (FEVD). Fuente: elaboración propia.

Prueba de homocedasticidad

El supuesto de homogeneidad de varianzas, también conocido como homocedasticidad, considera que la varianza es constante (no varía) en los diferentes niveles de un factor. Los resultados arrojaron valores de $p\text{-value} = 0.00558$.

Prueba de causalidad de Granger

El concepto de causalidad de Granger se ha utilizado ampliamente para estudiar las relaciones dinámicas entre series temporales económicas. Este concepto probabilístico se define en términos de previsibilidad y explora la dirección del flujo del tiempo para lograr un ordenamiento causal de las variables dependientes en series temporales multivariadas (Eichler, 2012). Entonces, se establece que:

H_0 : la serie de tiempo x no Granger-causa la serie de tiempo y y no se rechaza.

H_1 : la serie de tiempo x Granger-causa la serie de tiempo.

Los resultados permiten establecer un valor de $p\text{-value} = 0.0006032$. En consecuencia, se rechaza la hipótesis nula, lo que indica que el crecimiento semestral de la producción causa en el sentido de Granger al crecimiento del área cosechada durante

el periodo de estimación del estudio. Como aparece en la Figura 5, no parece existir ruptura en los respectivos intervalos de confianza.

Finalmente, en la Tabla 6 se realiza el pronóstico del modelo VAR para los 3 años siguientes, con un nivel de confianza del 95 %; la estimación incluye el área cosechada y la producción para ambos semestres del año. De esta manera se obtiene una herramienta que facilita la modelización del comportamiento de la producción y se proporciona información relevante para la toma de decisiones en el sector agropecuario (Naciones Unidas, 2021).

Discusión

En esta investigación inicialmente se analizaron aspectos conceptuales relacionados con la producción del commodity cebolla de rama, a partir de autores como Chen *et al.* (2023), Antunes de Araujo *et al.* (2020), Ding y Xu (2023), y Ouyang y Zhang (2020). Posteriormente, para la construcción del modelo, se utilizó información sobre el cultivo de cebolla de rama en el municipio en estudio, la cual fue obtenida de las evaluaciones agropecuarias (EVA) y del anuario estadístico del sector. Asimismo, se aplicó la metodología Box-Jenkins (Uribe *et al.*, 2017) mediante un conjunto de pruebas estadísticas, incluidas las




Figura 5. Ruptura estructural de los residuos (prueba de estabilidad OLS-CUSUM). Fuente: elaboración propia.

Tabla 6. Pronóstico área cosechada y producción

Período de proyección (año/semestre)	Área cosechada (ha)	Producción (t)
1A	1283	59 707
1B	1297	61 309
2A	1202	59 050
2B	1193	59 149
3A	1274	62 754
3B	1272	60 756

pruebas de estacionariedad de Phillips-Perron, la prueba de raíz unitaria Dickey-Fuller aumentada (ADF), la prueba de normalidad de Jarque-Bera, el test de Phillips-Ouliaris y la prueba de causalidad de Granger.

Esto permitió desarrollar un modelo de pronóstico para series de tiempo orientado a estimar la producción de cebolla de rama en toneladas e identificar las variables que inciden en la mejora del área cosechada. El modelo desarrollado permitirá proyectar, tanto el área de cosecha, como la producción de la cebolla de rama o junca en periodos semestrales, además de establecer mecanismos para el aseguramiento de las cosechas y su adecuada recolección. Asimismo, es fundamental considerar la variable climática, debido a los cambios que impactan de manera sistemática los aspectos socioeconómicos y productivos a nivel global.

Los pronósticos de rendimiento de los cultivos son fundamentales para evaluar las pérdidas potenciales y reales de alimentos, lo que permite a Gobiernos y productores diseñar estrategias efectivas en materia de exportación e importación, seguridad alimentaria y gestión sostenible de la tierra (White *et al.*, 2020). La capacidad de pronosticar los rendimientos finales de los cultivos, tanto en etapas previas, como durante el periodo de crecimiento, se constituyen en una herramienta clave para los agricultores, ya que les brinda la oportunidad de planificar anticipadamente para la toma de decisiones (Filippi *et al.*, 2019).

De igual manera, en el sector agropecuario, los Objetivos de Desarrollo Sostenible (ODS), han cobrado relevancia en la investigación académica, pues se han convertido en un eje central para el análisis de los desafíos globales. Entre estos se destacan el cambio climático, la inseguridad política, la inestabilidad de los mercados y la seguridad alimentaria (Brunori *et al.*, 2016; Camara *et al.*, 2025; Galli *et al.*, 2020). En particular, en el sector agrícola, los ODS 2 (Hambre cero) y 12 (Producción y consumo sostenibles), abordan desafíos clave relacionados con la sostenibilidad ambiental, la seguridad alimentaria y el cambio climático, a la vez que promueven la mejora de los sistemas acuáticos y terrestres (FAO, 2020).

El análisis de modelos de pronósticos en la producción agropecuaria cuenta con antecedentes en estudios como el de Luis-Rojas *et al.* (2020), quienes desarrollaron un modelo basado en la metodología Box-Jenkins y fundamentada en procesos autorregresivos integrados de medias móviles (ARIMA), para estimar la producción anual de vainilla en México. Los resultados de su investigación permitieron proyectar la producción del año siguiente y generar información clave para la planificación y toma de decisiones en un horizonte de 6 años.

La investigación de Mohale y Obagbuwa. (2024) utilizó el método estadístico (VAR) para analizar cómo las variables climáticas interactúan entre sí e influyen en el rendimiento del trigo en Bloemfontein, Sudáfrica. Este modelo extiende el concepto de autorregresión univariante a un enfoque multivariable, lo que permite modelar el comportamiento conjunto del sistema en lugar de examinar cada variable de manera aislada. Este enfoque resulta particularmente valioso para examinar cómo la temperatura, la precipitación y otros factores climáticos interactúan y contribuyen a las fluctuaciones del rendimiento. Su principio fundamental radica en que cada variable está influenciada por los valores pasados en las demás variables del sistema, de este modo, se pueden capturar relaciones dinámicas y efectos de retroalimentación entre el clima y la producción de trigo. Al considerar estas interdependencias, el modelo VAR proporciona una visión integral del comportamiento del sistema. El orden de rezago

determina cuántos periodos anteriores se consideran para predecir valores actuales de las variables. Para seleccionar el orden del rezago óptimo se emplean criterios como la información de Akaike (AIC) y el criterio de información bayesiano (BIC), los cuales ayudan a equilibrar la complejidad del modelo y su precisión predictiva; además, el análisis de los gráficos de funciones de respuesta al impulso (IRF) y de la descomposición de la varianza (FEVD) proporciona información clave sobre las interacciones dinámicas y la importancia relativa de las variables climáticas en la incidencia del rendimiento del trigo.

Por otra parte, en Malasia, Bilal *et al.* (2024) integraron modelos (VAR) con modelos difusos basados en números trapezoidales, estableciendo nuevos enfoques multivariados de series temporales difusas (MFTS), específicamente modelos autorregresivos vectoriales difusos (FVAR). La integración de estos enfoques mejora el desempeño predictivo y permite una evaluación más precisa de los precios y la producción de arroz. Los resultados del estudio indican que la mayor precisión en los pronósticos obtenidos con los modelos FVAR y números difusos trapezoidales (TrFN) pueden generar beneficios significativos para los agricultores locales y otras partes interesadas, al facilitar la toma de decisiones informadas sobre producción y precios. Además, se destaca la importancia de incorporar variables como las condiciones climáticas, la calidad del suelo, los ataques de plagas y las innovaciones tecnológicas en la agricultura, lo que contribuiría a una comprensión más integral de los factores que influyen en el mercado del arroz.

De manera similar, Hou *et al.* (2023) analizaron el pronóstico de la evapotranspiración de referencia en el estado de Penang, Malasia, empleando el modelo VAR. En su estudio examinaron la relación causal de las variables meteorológicas y determinaron que el modelo VAR ofrece un mejor desempeño en comparación con otras técnicas, como el error potencial absoluto medio (MAPE), el margen de error (ME), el error absoluto medio (MAE), el error porcentual medio (MPE), el error cuadrático medio (RMSE), el coeficiente de correlación (CORR) y el método mínimo-máximo, para evaluar la precisión de los datos de pronóstico. Asimismo, los autores sugieren que futuras investigaciones podrían mejorar la precisión de los pronósticos mediante un enfoque híbrido que combine redes neuronales artificiales con el modelo VAR para pronosticar la evapotranspiración de referencia, utilizando diferentes combinaciones de variables meteorológicas como entrada, para aumentar la precisión de los resultados del pronóstico.

Conclusiones

Los resultados de este estudio evidencian que un modelo VAR es una herramienta útil para la planificación de la producción y el área cosechada

del commodity cebolla de rama en el municipio de Aquitania. A partir del análisis de datos históricos provenientes de las EVA, el anuario estadístico del sector y con la aplicación de la metodología Box-Jenkins se llevaron a cabo diversas pruebas estadísticas, como las de estacionariedad (Phillips-Perron, ADF), normalidad (Jarque-Bera), cointegración (Phillips-Ouliaris) y la causalidad de Granger. Estos resultados respaldan la viabilidad del modelo VAR para prever las necesidades futuras de producción, lo cual contribuye a una mejor toma de decisiones en la gestión agrícola. Asimismo, el estudio refuerza la importancia del uso de herramientas econométricas en la planificación del sector agrícola y facilita la implementación de estrategias más eficientes.

El modelo considera un histórico del área sembrada (ha), área cosechada (ha), producción (t) y rendimiento (t/ha) para el pronóstico, sin embargo, este puede verse afectado por factores externos relacionados con el clima o problemas fitosanitarios. Así mismo, el modelo puede ser de utilidad, entre otras instituciones técnicas, para la Unidad de Planificación Rural Agropecuaria (UPRA) y para las evaluaciones agropecuarias municipales en articulación con el Sistema Nacional Unificado de Información Rural Agropecuaria (SNUIRA).

Referencias

- Alcaldía Municipal de Aquitania. (2020). *Plan de Desarrollo para el Municipio de Aquitania Boyacá "Unidos Construimos el Progreso 2020-2023."* <https://www.aquitania-boyaca.gov.co/planes/plan-de-desarrollo-20202023-unidos-construimos-el-progreso-103456>
- Antunes de Araujo, F. H.; Bejan, L.; Stosic, B. y Stosic, T. (2020). An analysis of Brazilian agricultural commodities using permutation-information theory quantifiers: The influence of food crisis. *Chaos, Solitons and Fractals*, 139, 110081. <https://doi.org/10.1016/j.chaos.2020.110081>
- Baffes, J. y Kabundi, A. (2023). Commodity price shocks: Order within chaos? *Resources Policy*, 83. <https://doi.org/10.1016/j.resourpol.2023.103640>
- Bilal, M.; Alrasheedi, M. A.; Aamir, M.; Abdullah, S.; Norrulashikin, S. M. y Rezaizy, R. (2024). Enhanced forecasting of rice price and production in Malaysia using novel multivariate fuzzy time series models. *Scientific Reports*, 14, 29903. <https://doi.org/10.1038/s41598-024-77907-4>
- Bono, F.; Vallone, M.; Alleri, M.; Lo Verde, G.; Orlando, S.; Ragusa, E. y Catania, P. (2024). Hive behaviour assessment through vector autoregressive model by a smart apiculture system in the Mediterranean area. *Smart Agricultural Technology*, 9. <https://doi.org/10.1016/j.atech.2024.100676>
- Brunori, G.; Galli, F.; Barjolle, D.; Van Broekhuizen, R.; Colombo, L.; Giampietro, M.; Kirwan, J.; Lang, T.; Mathijs, E.; Maye, D.; De Roest, K.; Rougoor, C.; Schwarz, J.; Schmitt, E.; Smith, J.; Stojanovic, Z.; Tisenkopfs, T. y Touzard, J. M. (2016). Are local food chains more sustainable than global food chains? Considerations for assessment. *Sustainability*, 8(5). <https://doi.org/10.3390/su8050449>
- Camara, S. B.; Zucatto, L. C.; Brandão, J. B. y Boscardin, M. (2025). Mapping of scientific production around the sustainable

- development goals-SDGS and food production. *Ciencia Rural*, 55(3). <https://doi.org/10.1590/0103-8478cr20230134>
- Chen, L.; Verousis, T.; Wang, K. y Zhou, Z. (2023). Financial stress and commodity price volatility. *Energy Economics*, 125, 106874. <https://doi.org/10.1016/j.eneco.2023.106874>
- Cuevas-Ahumada, V. M. (2008). Inflation, output and economic policy in Mexico. *Investigación Económica*, 67(265), 85-120.
- Del Giorgio, O.; Robinson, B. E. y Le Polain de Waroux, Y. (2022). Impacts of agricultural commodity frontier expansion on smallholder livelihoods: An assessment through the lens of access to land and resources in the Argentine Chaco. *Journal of Rural Studies*, 93, 67-80. <https://doi.org/10.1016/j.jrurstud.2022.05.014>
- Ding, Y. y Xu, J. (2023). Global vulnerability of agricultural commodities to climate risk: Evidence from satellite data. *Economic Analysis and Policy*, 80, 669-687. <https://doi.org/10.1016/j.eap.2023.09.013>
- Eichler, M. (2012). Graphical modelling of multivariate time series. *Probability Theory and Related Fields*, 153, 233-268. <https://doi.org/10.1007/s00440-011-0345-8>
- FAO. (2020). FAO framework for the Urban Food Agenda. En FAO framework for the Urban Food Agenda. <https://doi.org/10.4060/ca3151en>
- Filippi, P.; Jones, E. J.; Wimalathunge, N. S.; Somarathna, P. D. S. N.; Pozza, L. E.; Ugbaje, S. U.; Jephcott, T. G.; Paterson, S. E.; Whelan, B. M. y Bishop, T. F. A. (2019). An approach to forecast grain crop yield using multi-layered, multi-farm data sets and machine learning. *Precision Agriculture*, 20, 1015-1029. <https://doi.org/10.1007/s11119-018-09628-4>
- Firmansyah, F.; Maruli, P. y Harahap, A. (2023). Analysis of beef market integration between consumer and producer regions in Indonesia. *Open Agriculture*, 8(1). <https://doi.org/10.1515/opag-2022-0221>
- Fonseca-Cifuentes, G.; León-Castro, E. y Blanco-Mesa, F. (2021). Predicting the future price of a commodity using the OWMa operator: An approximation of the interest rate and inflation in the brown pastusa potato price. *Journal of Intelligent & Fuzzy Systems*, 40(2), 1971-1981. <https://doi.org/10.3233/jifs-189200>
- Galli, F.; Prosperi, P.; Favilli, E.; D'amico, S.; Bartolini, F. y Brunori, G. (2020). How can policy processes remove barriers to sustainable food systems in Europe? Contributing to a policy framework for agri-food transitions. *Food Policy*, 96, 101871. <https://doi.org/https://doi.org/10.1016/j.foodpol.2020.101871>
- Glinksiy, V.; Ismayilova, Y.; Khrushchev, S.; Logachov, A.; Logachova, O.; Serga, L.; Yambartsev, A. y Zaykov, K. (2024). Modifications to the Jarque-Bera test. *Mathematics*, 12(16). <https://doi.org/10.3390/math12162523>
- Hou, P. S.; Fadzil, L. M.; Manickam, S. y Al-Shareeda, M. A. (2023). Vector autoregression model-based forecasting of reference evapotranspiration in Malaysia. *Sustainability*, 15(4). <https://doi.org/10.3390/su15043675>
- Kamila, K. (2022). General Hannan and Quinn criterion for common time series. *Statistics*, 56(1), 222-241. <https://doi.org/10.1080/02331888.2022.2041017>
- Li, Y. y Umair, M. (2023). The protective nature of gold during times of oil price volatility: An analysis of the Covid-19 pandemic. *Extractive Industries and Society*, 15. <https://doi.org/10.1016/j.exis.2023.101284>
- Luis-Rojas, S.; Ramírez-Valverde, B.; Díaz-Bautista, M.; Pizano-Calderón, J. y Rodríguez-López, C. (2020). Vanilla (*Vanilla planifolia*) production in Mexico: Analysis and forecast. *Revista Mexicana Ciencias Agrícolas*, 11(1), 175-187. <https://doi.org/https://doi.org/10.29312/remexca.v11i1.2065>
- Malá, I.; Sládek, V. y Bílková, D. (2021). Power comparisons of normality tests based on l-moments and classical tests. *Mathematics and Statistics*, 9(6), 994-1003. <https://doi.org/10.13189/ms.2021.090615>
- Meneses-Cerón, L. Á. y Pérez-Pacheco, C. A. (2020). Análisis comparativo de eficiencia en mercados emergentes. El caso de Colombia, Chile y Perú. *Apuntes Contables*, 26, 9-24. <https://doi.org/10.18601/16577175.N26.02>
- Michail, N. A. y Melas, K. D. (2020). Market interactions between agricultural commodities and the dry bulk shipping market. *The Asian Journal of Shipping and Logistics*, 37, 20212073. <https://doi.org/10.1016/j.ajsl.2020.07.003>
- Ministerio de Agricultura y Desarrollo Rural. (2024). Reporte: Área, Producción, Rendimiento y Participación Municipal en el Departamento por Cultivo. <https://www.Agronet.Gov.Co/Estadistica/Paginas/Home.aspx?Cod=59>
- Mohale, V. Z. y Obagbuwa, I. C. (2024). Assessing the impact of climate variability on wheat yield in Bloemfontein wheat farms through time series analysis. *Edelweiss Applied Science and Technology*, 8(5), 1213-1234. <https://doi.org/10.55214/25768484.v8i5.1826>
- Morán-Chiquito, D. M. (2014). Determinantes de la inflación en Ecuador. Un análisis econométrico utilizando modelos VAR. *Economía y Sociedad*, 18(31), 53-70.
- Naciones Unidas. (2021). Innovación para el desarrollo: la clave para una recuperación transformadora en América Latina y el Caribe. www.cepal.org/apps
- Novales, A. (2017). Modelos vectoriales autorregresivos (VAR). *Universidad Complutense de Madrid*, 58.
- Ouyang, R. y Zhang, X. (2020). Financialization of agricultural commodities: Evidence from China. *Economic Modelling*, 85, 381-389. <https://doi.org/10.1016/j.econmod.2019.11.009>
- Perfetti, J. J.; Balcázar, Á.; Hernández, A. y Leibovich, J. (2013). Políticas para el desarrollo de la agricultura en Colombia. SAC; Fedesarrollo. <http://hdl.handle.net/11445/61>
- Phillips, P. C. B. y Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335-346. <https://doi.org/10.1093/BIOMET/75.2.335>
- Reimers, H. E. (1992). Comparisons of tests for multivariate cointegration. *Statistical Papers*, 33, 335-359. <https://doi.org/10.1007/BF02925336>
- Sujath, R.; Chatterjee, J. M. y Hassanien, A. E. (2020). A machine learning forecasting model for Covid-19 pandemic in India. *Stochastic Environmental Research and Risk Assessment*, 34, 959-972. <https://doi.org/10.1007/s00477-020-01827-8>
- Sumertajaya, I. M.; Rohaeti, E.; Fitrianto, A. y Adi, W. P. P. (2024). Development of food commodity price forecasting model as an early warning system with a multivariate time series clustering. *Sains Malaysiana*, 53(11), 3779-3789. <https://doi.org/10.17576/jsm-2024-5311-20>
- Uribe, J. F.; Fajardo, E. O. y Romero, H. L. (2017). Incidencia de las políticas públicas de empleo sobre la desocupación en Colombia: un análisis de intervención para el periodo 2002-2014. *Revista Espacios*, 38(36), 22.
- White, J.; Berg, A. A.; Champagne, C.; Zhang, Y.; Chipanshi, A. y Daneshfar, B. (2020). Improving crop yield forecasts with satellite-based soil moisture estimates: An example for township level canola yield forecasts over the Canadian Prairies. *International Journal of Applied Earth Observation and Geoinformation*, 89. <https://doi.org/10.1016/j.jag.2020.102092>