

PRONÓSTICO DE LA TASA DE CAMBIO EN COLOMBIA (TRM) UTILIZANDO LOS MODELOS ARIMA-GARCH DURANTE EL PERIODO 1992-2025

FORECASTING THE EXCHANGE RATE IN COLOMBIA (TRM) USING ARIMA-GARCH MODELS DURING THE PERIOD 1992–2025

Edgar Ricardo Jiménez-Méndez (Universidad de Bogotá Jorge Tadeo Lozano, Colombia)*¹

Nicolas Aguilera-Peña (Aval Casa de Bolsa - Corficolombiana)²

Raúl Alberto Cortés-Villafradez (Universidad de Bogotá Jorge Tadeo Lozano, Colombia)³

Resumen

Los pronósticos de variables económicas como la tasa de cambio o inflación son un instrumento esencial para las autoridades económicas, ya que basados en las expectativas de los analistas del mercado se toman decisiones que tienen efecto sobre la sociedad. Esta investigación presenta como objetivo determinar un modelo econométrico que sea útil para pronosticar la tasa de cambio del peso colombiano frente al dólar estadounidense USD/COP (TRM). Por esta razón se realizó un estudio cuantitativo mediante la aplicación de los principios ARIMA-GARCH usando como serie de tiempo datos diarios de la Tasa Representativa del Mercado (TRM) entre 1992 y 2022. Los resultados sugieren que el modelo calculado logró filtrar adecuadamente la información contenida en los rezagos mediante la prueba del Q-Stat sin problemas de autocorrelación simples al 5% de significancia estadística, lo que permitió establecer que los parámetros estimados para pronosticar la TRM son significativos. Por lo anterior, se concluye que el modelo tiene buena capacidad predictiva para el peso colombiano frente al dólar estadounidense en el corto plazo.

Palabras clave: ARIMA, GARCH, dólar, pronóstico, econometría, macroeconomía.

Códigos JEL: C58, B23

Abstract

The economic figures forecast as exchange rate or the consumer price index are an essential tool for economic authorities, based on economic research analysts' expectations make decisions with effect in all society. This research has as objective to determinate a useful econometric model to forecast the Colombian exchange rate USD/COP (TRM). For this reason, it developed quantitative research applying ARIMA-GARCH models using time series data for TRM between 1992 and 2022. The results suggest that the model presented in this work achieves adequately filtered the information contained in lags using Q-Stat test, without simple

* Autor de correspondencia: edgarr.jimenezm@utadeo.edu.co

¹ ORCID: <https://orcid.org/0000-0003-4652-5649>

² ORCID: <https://orcid.org/0000-0001-6131-0828>

³ ORCID: <https://orcid.org/0000-0002-1385-9186>

autocorrelation problems at 5% in statistical significance. This permits us to establish that the estimated parameters for forecasting the TRM are significant. Consequently, it is concluded that the model has predictive capacity to forecast the exchange rate between the Colombian peso and the US dollar in the short term.

Keywords: ARIMA, GARCH, dollar, forecast, econometrics, macroeconomics.

JEL Codes: C58, B23

1. INTRODUCCIÓN

Contar con modelos que permitan pronosticar el comportamiento del tipo de cambio es de gran interés tanto para empresarios como para inversionistas y especuladores del mercado financiero. Particularmente en Colombia, un modelo que se enfoque en la tasa de cambio (USDCOP) o Tasa Representativa del Mercado (TRM) es altamente valorado, ya que Estados Unidos al ser el principal socio comercial del país, tiene una incidencia relevante en el comportamiento macroeconómico local (Clavijo, 2001).

Las variaciones del tipo de cambio tienen implicaciones importantes en el comercio internacional, el endeudamiento externo, la inflación, la inversión extranjera y la política económica del país (Ayala & Bucio, 2020). Sin embargo, la tasa de cambio en Colombia es conocida por su alta volatilidad en el corto plazo, un hecho que genera incertidumbre en los mercados y en la toma de decisiones económicas. Esta se ha visto acentuada por diversas transformaciones económicas, políticas y sociales que ha experimentado el país desde 1992, incluyendo crisis financieras como la del año 1998 (UPAC), fluctuaciones en los precios del petróleo, reformas económicas y cambiarias, así como los efectos de eventos globales como el COVID-19 (Thomakos & Bhattacharya, 2005).

En este contexto, el desarrollo de modelos econométricos aplicados que permitan predecir con razonable precisión el comportamiento futuro del tipo de cambio es de gran importancia. Este estudio tiene como objetivo principal identificar un modelo combinado ARIMA-GARCH para el pronóstico del tipo de cambio entre el peso colombiano y el dólar estadounidense durante el periodo 1992-2025, dentro de un rango de confianza estadísticamente significativo.

Un modelo combinado ARIMA-GARCH se justifica por el uso integrado de ambos modelos. Mientras el modelo ARIMA, popularizado por (Box & Jenkins, 1989), captura las dependencias temporales y la estructura lineal de la serie de tiempo (Lewis-Beck, *et al.*, 2012), el modelo GARCH permite modelar la volatilidad condicional, la cual es una característica esencial en el análisis de series financieras (Cao & Zhao, 2022; Wang *et al.*, 2020). En consecuencia, la combinación de ambos enfoques se traduce en un pronóstico más preciso y robusto del comportamiento de la serie, constituyéndose en una valiosa herramienta para la toma de decisiones económicas (Li, *et al.*, 2020).

En este contexto, la presente investigación tiene como objetivo principal determinar la efectividad del modelo ARIMA-GARCH en la predicción de la Tasa Representativa del Mercado (TRM) de Colombia. A través de un análisis de la serie de tiempo diaria, este estudio busca identificar el modelo ARIMA-GARCH más adecuado para capturar la dinámica de la TRM (tasa de cambio). La pregunta de investigación de este trabajo es: ¿Cuál es el modelo ARIMA más adecuado para pronosticar la Tasa Representativa del Mercado (TRM) en Colombia y cuál es su capacidad predictiva en el corto plazo?

El presente estudio se estructura de la siguiente manera: en primer lugar, se presenta la discusión del marco teórico de los modelos ARIMA-GARCH. En segundo lugar, se describe el

análisis de los datos utilizados. Luego, se especifica el procedimiento de estimación del modelo y finalmente, se presentan los resultados y conclusiones.

1.1. Fundamentación teórica

Existen diversas metodologías para pronosticar el tipo de cambio o precio de la divisa basados en diversos tipos de modelos econométricos. Existe pronósticos a partir de información cuantitativa de series temporales cuyas observaciones pasadas y actuales del comportamiento del tipo de cambio son registradas secuencialmente en el tiempo.

Dentro de estos últimos, existen los modelos de cointegración, los cuales se han convertido en una herramienta muy utilizada para pronosticar el tipo de cambio basado de que ciertas variables que no presentan divergencia significativa en el largo plazo (Arce, *et al.*, 2019). Adicionalmente, se han utilizado modelos de corrección de error VAR, (Pinčák & Bartoš, 2015) basados en las desviaciones del tipo de cambio que emplean la metodología cadena o patrón para su predicción. Dentro de estos últimos modelos, (Wang & Guo, 2020) empleó un método de pronóstico de volatilidad del mercado basado en series temporales aplicando un modelo combinado ARIMA y XGBoost.

Dentro de los modelos híbridos autorregresivos de promedios móviles (ARIMA), se cuenta con hallazgos importantes para la predicción del comportamiento futuro de los tipos de cambio presentados por (Li, *et al.*, 2020), (Peng, *et al.*, 2020), (Kumari & Gupta, 2022), (Ayala & Bucio, 2020) y por (Guo, *et al.*, 2022). Estos últimos autores, combinaron en su trabajo el modelo (ARIMA) con la metodología de pronóstico de Estabilidad de Taylor (TEF) que permitió pronosticar series de tiempo financieras con mayor precisión y estabilidad. Por su parte (Sirisha, *et al.*, 2022) y (Dyhrberg, 2015) emplearon en su estudios de pronóstico del tipo de cambio, utilizando la combinación de los Modelos de series de tiempo estacionales (ARIMA), junto con el modelo de red neuronal de memoria de largo y corto plazo (LSTM).

(Kučera, *et al.*, 2022) utilizaron la técnica de pronóstico del promedio móvil simple (SMA) junto con el modelo (ARIMA), concluyendo que este último modelo ofreció mejores resultados para predecir el comportamiento del índice S&P 500.

En general, para la mayoría de los autores citados anteriormente, el modelo ARIMA (Autoregressive Integrated Moving Average) es ampliamente utilizado para modelar series temporales, debido a que captura tanto las dependencias temporales de los datos del tipo de cambio, como las tendencias y ciclos que puedan existir en la serie. Para dichos autore, ARIMA se integra a partir de tres componentes claves: la parte autorregresiva (AR), el componente de la diferencia (I) para la serie estacionaria y, finalmente, la parte de la media móvil (MA). Lo anterior implica que el modelo es útil para identificar patrones tanto de largo plazo como de corto plazo en el comportamiento de las series del tipo de cambio.

Por otro lado, se encuentran autores que han empleado en sus ejercicios de pronóstico, modelos híbridos que combinan varias metodologías cuantitativas para predicciones puntuales aplicadas a las finanzas que incorporan la incertidumbre mediante predicción fundamentada en momentos condicionados y de máxima entropía como los presentados por (Lee, *et al.*, 2023) y (Torres, 2014) los cuales proponen metodología de uso de redes neuronales artificiales (GLM) combinadas con el modelo (GARCH) Modelo Generalizado Autorregresivo heterocedástico, el cual simula la volatilidad condicional de las series temporales de variables financieras como son el tipo de cambio.

Para dichos autores, la heterocedasticidad condicional implica que la varianza de los errores de la serie temporal, no es constante sino que depende del tiempo. En este sentido GARCH se adapta bien a las series temporales que muestras periodos de alta volatilidad

seguidos de periodos de calma, lo cual es un fenómeno recurrente en el comportamiento del tipo de cambio del peso Colombiano frente al dólar Estadounidense.

Finalmente, (Cao & Zhao, 2022) combinan en sus estudios métodos de predicciones tradicionales con modelos de aprendizaje moderno de máquina soporte de Vectores (SVM) con el modelos (ARIMA) – (GARCH) Modelo Generalizado Autorregresivo Heterocedástico para predecir valores de mercado y del tipo de cambio en contextos de países emergentes. En el estudio desarrollado por (Najamudin & Fátima, 2022) propuso un modelo híbrido para pronosticar los tipos de cambio basado en la integración del modelo de red neuronal regularizada bayesiana (BRNN) vinculado con el modelo (ARIMA) de promedio móvil integrado autorregresivo.

Otros modelos no convencionales utilizados: (Staffini, 2022) utilizaron un modelo de arquitectura de red adversa generativa convulcional profunda (DCGAN) para abordar el problema de pronóstico de cierre de precio de mercado accionario. (Shen, *et al.*, 2011) trabajaron con un modelo de red neuronal de función de base radial (RBFNN) para pronosticar el comportamiento de algunos activos financieros, haciendo uso de algoritmos y modelos (ARIMA) y (SVM), entre otros. Mientras tanto, (Wang *et al.*, 2020) utilizaron en sus ejercicios de pronóstico minería de datos de serie analítica de Big Data en activos financieros utilizando para ello varios modelo autoregresivos de series de tiempo (MA) y modelo (ARIMA) para predicción de series temporales en escenarios generales.

Se puede destacar que los anteriores estudios logran capturar la volatilidad de las series y el impacto de eventos económicos importantes para los ejercicios del pronóstico del tipo de cambio. De igual manera se resalta que los estudios previos sobre el tipo de cambio no solo se han centrado en los valores esperados (media) sino también en la modelación de la volatilidad, lo que configura la importancia del modelo GARCH en este tipo de análisis.

1.2. Antecedentes y referencia histórica

La evolución de la tasa de cambio en Colombia no ha sido muy diferente a lo que ha sucedido en Latinoamérica, salvo que este país no ha vivido épocas de hiperinflación o hiperdevaluación como las observadas en Argentina, Brasil o Ecuador durante décadas pasadas.

Para el desarrollo del presente trabajo, se segmentó temporalmente la serie histórica de precios USD/COP en seis períodos con el fin de evaluar el intervalo de tiempo que se tomaría para realizar los experimentos asociados al modelo y llegar a uno que cumpliera todos los requerimientos propios de los desarrollos científicos vigentes alrededor de modelos ARIMA-GARCH. Para los efectos del documento se trabajó con la serie histórica (TRM) o tasa representativa del mercado, que no es más que un promedio ponderado de las cotizaciones diarias de la tasa de cambio nominal.

A continuación se presenta un resumen con los datos de cada período donde se observa que el periodo “I”, claramente alcista, fue el reflejo de *la crisis de finales de los 90*, (Urrutia & Llano, 2011), que provocó la salida de capitales en Colombia y obligó al *Banco de la República o Banco Central de Colombia* a implementar un régimen cambiario flexible a partir de septiembre de 1999 (Clavijo, 2001).

En el periodo “II”, la TRM entró en fase de apreciación. Este hecho fue explicado por la confianza inversionista en el gobierno de *Álvaro Uribe Vélez*, el alza en los precios del petróleo, causados por el conflicto en Irak, y la expansión de la producción petrolera colombiana, sumada a una buena dinámica económica internacional.

En el periodo “III”, la (TRM) mostró un breve periodo alcista provocado por el aumento en el riesgo financiero a nivel planetario, en respuesta a la crisis financiera estadounidense del 2008 y a la alta volatilidad de los mercados de capitales a nivel mundial.

Para el periodo “IV” la (TRM) cae a causa de las medidas tomadas para inyectar liquidez en las economías, aunado a las expectativas alrededor del proceso de paz frente al primer gobierno de *Juan Manuel Santos* y su plan económico.

Entrado el periodo “V”, la (TRM) volvió a estar en fase alcista luego de que Estados Unidos eliminara el veto a las exportaciones del petróleo iraní, lo cual hizo descender los precios del crudo y moderar el flujo de divisas por este rubro a Colombia.

En el periodo “VI” el petróleo tuvo una leve recuperación y un periodo de estabilización, mientras que la economía colombiana logró contener la aceleración de la inflación y el riesgo energético derivado del fenómeno del niño y sus consecuencias en el sistema hidroeléctrico.

Por último, está el periodo “VII”, donde el mundo entró en un escenario de alta incertidumbre que se ha caracterizado principalmente por la guerra comercial entre China y Estados Unidos, la caída de la cotización internacional del petróleo a causa de la contracción en el (PIB) mundial y las sanciones del gobierno Trump a Irán por su programa nuclear. Adicionalmente, las olas de la pandemia por COVID-19 y sus respectivos confinamientos acompañados de medidas atadas a la política monetaria global, la guerra en Ucrania, el fenómeno de la inflación mundial, el default de la deuda rusa y la reciente Crisis Bursátil en los Estados Unidos.

Teniendo en cuenta lo anterior, al comparar cada uno de estos periodos, se observa que la situación económica actual presenta similitudes con los periodos ‘I’ y ‘V’, ya que ambos se caracterizaron por una alta inflación, un crecimiento económico débil, choques económicos severos y la devaluación del peso. Especialmente el periodo “I”, que tiene información del default de Rusia en 98, la crisis de *Long Term Capital Management* y la burbuja *punto com*. Sin embargo, este periodo no puede ser usado para el pronóstico de la tasa de cambio, ya que tiene información de los dos regímenes cambiarios que operaron en Colombia por esas épocas.

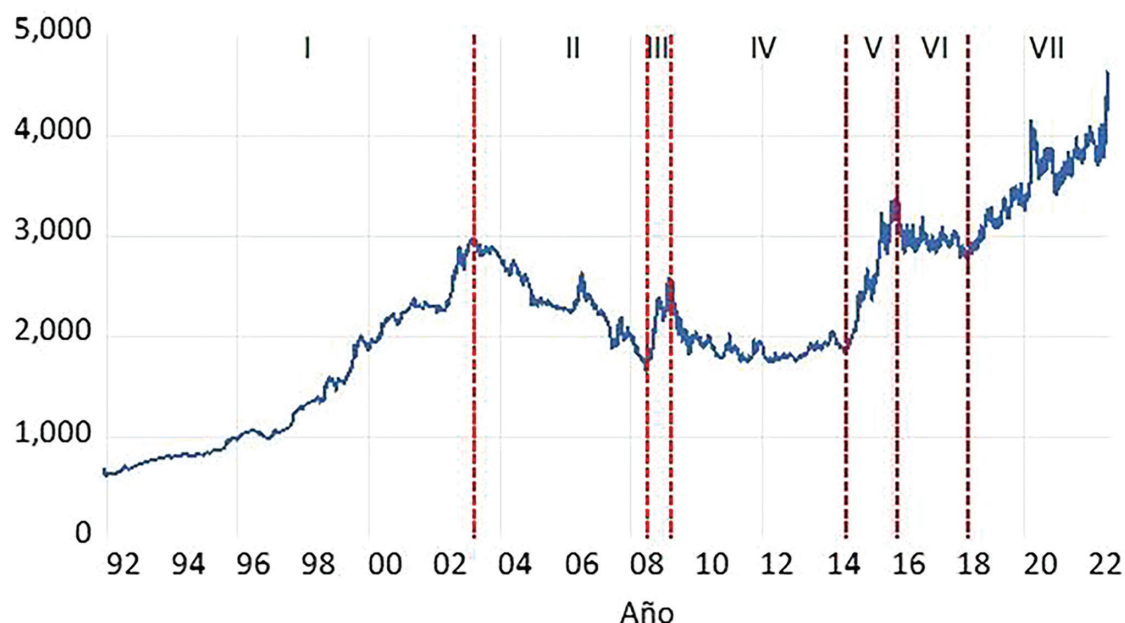
Por otra parte, la información de finales de los 90 y principios del 2000, presentaba un comportamiento de la tasa de cambio ante expectativas de las políticas monetaria y cambiaria, muy distintas a las que se enfrentan hoy en día los mercados en Colombia. En esa época Colombia estaba inmersa en gobiernos de tipo neoliberal, mientras en la actualidad las expectativas de los mercados giran en torno a un gobierno de izquierda.

Por su parte el periodo “V”, aunque presenta cierta similitud con el periodo VII, no puede ser comparado en tanto de manera clara con los demás ya que el contexto mundial seguía siendo de liquidez laxa y bajo riesgo, a lo que se agrega el optimismo por los precios bajos del combustible que afrontaban las mayores economías, escenario completamente opuesto al actual. De forma que, para poder proceder con el análisis se tomó como base el periodo “VII”, pues contiene la información del precio de la divisa con la mayor cantidad de eventos aleatorios que han confluído para crear la tendencia que se ve durante este lapso en la Gráfica 1.

1.3. Análisis de frecuencia del periodo “VII”


Como puede observarse en la Gráfica 2, durante el periodo seleccionado, se encontraron 4 rangos, donde los datos fueron agrupados, siendo el rango “4” el que más frecuencia evidenció. Continuando con el análisis, se puede observar que el primer rango, cuya frecuencia es la más baja, muestra oscilaciones de la (TRM) de entre COP 2600 y COP 3000, siendo el dato más frecuente el nivel de los COP 2850 aproximadamente. Por su parte el segundo rango se movió entre los COP 3000 y los COP 3300, con el dato más frecuente en un nivel cercano a los COP 3175. El siguiente rango (rango “3”), tuvo variaciones entre los COP 3300 y COP 3550, con el dato más frecuente en el nivel de los COP 3425. Por último, estuvo el cuarto rango, que mostró niveles para la (TRM) de entre los COP 3550 a COP 4628, con el dato más frecuente en el nivel de COP 3775 aproximadamente.

GRÁFICA 1. EVOLUCIÓN DE LA TRM (USD/COP) EN NIVELES



Fuente: Elaboración propia con datos del año 2022 usando LSEG (antes Refinitiv) y cifras del Banco de la República.

GRÁFICA 2. HISTOGRAMA DE LA TASA DE CAMBIO (USD/COP) PARA EL “VII” PERIODO



Fuente: Elaboración propia usando LSEG (antes Refinitiv) y cifras del Banco de la República.

Dado lo anterior, para llegar a definir un modelo óptimo de pronóstico de la (TRM) de conformidad con (Box & Jenkins, 1989) se debe elaborar análisis que tenga en cuenta cálculos alrededor de estacionalidad, medias móviles y diferenciación, modelados a través del ARIMA.

Adicionalmente, se modela la volatilidad a través de GARCH como lo indica (Dyhrberg, 2015), es decir modelar los residuos cuadráticos ya que el valor esperado de la ecuación de indica hacia donde converge la volatilidad del modelo.

2. METODOLOGÍA

El presente trabajo de investigación de ha desarrollado mediante método cuantitativo, teniendo en cuenta series históricas del tipo de cambio del peso colombiano COP frente a la divisa estadounidense USD usando modelos de regresión ARIMA-GARCH. para el periodo de 1992 a 2022. Los datos fueron obtenidos desde la aplicación LSEG (Refinitiv), con el apoyo se series de precios del Banco de la República y la Superintendencia Financiera de Colombia. Igualmente, se usó el software econométrico Eviews y se trabajó con lenguaje de programación en Python.

Siguiendo los parámetros de cálculo de manera ordenada de conformidad con trabajos similares realizados por (Clauon, 1997; Dagum & Morry, 1984; Thomakos & Bhattacharya, 2005), se procedió a calcular el test de raíz unitaria aplicando para la serie de datos seleccionada utilizando la prueba de *Dickey-Fuller*.

Posteriormente, se determinó el modelo ARIMA-GARCH, atendiendo los desarrollos teóricos de (Box & Jenkins, 1989) y a los resultados de trabajos de series de tiempo financieras elaborados por (Dritsaki, 2018), (Gao, 2021), (Ghani & Rahim, 2019) y (Pahlavani; & Reza, 2015). Los hallazgos de estos autores sugieren que el primer paso a desarrollar en el modelo propuesto es determinar si la serie de datos históricos utilizada presenta un patrón de estacionalidad o de diferenciación tal y como lo mencionan (Vizek & Broz, 2009).

Se procedió entonces a aplicar la prueba de patrón de estacionalidad en el modelo, la cual fue validada por la prueba de raíz unitaria.

Se procedió a determinar los parámetros del modelo ARIMA que fueran significativos y que estadísticamente mostraron un nivel de confianza que permitió de manera razonable considerar que las estimaciones derivadas eran consistentes y atendían los desarrollos econométricos vigentes de conformidad con los estudios presentados por (Baghestani, 1992), (Granger & Jenkins, 1974), (Jain, 1989) y (Kang, 1986).

Parte de la validez del modelo se evaluó a través de pruebas de significancia estadística para asegurar un poder adecuado en la detección de relaciones, siguiendo los principios establecidos por (Cohen, 1988).

Finamente, se efectuó el abordaje del contenido GARCH del modelo, el cual fue compatible con el desarrollado con la prueba de raíz unitaria y el modelo ARIMA. Se destaca en esta investigación, que la serie de experimentos que fueron utilizados para llegar a un nivel óptimo en la significancia de las variables fue apoyada y contrastada por ejercicios previos citados anteriormente, obteniendo como resultado niveles de confiabilidad aceptables para cada una de las variables.

2.1. Análisis de Raíz Unitaria en el Nivel de la (TRM)

De acuerdo con lo mencionado anteriormente, como primer paso se realizó fue el cálculo de la prueba de raíz unitaria en tendencia e intercepto.

Al observar el resultado de la prueba de *Dickey-Fuller Aumentado (DFA)*, para la serie de datos de la (TRM), se encontró que este no fue significativo al 5%, esto indicó que no se rechazaría la hipótesis nula de raíz unitaria, es decir que la serie no era estacionaria. Sin embargo, los parámetros de la regresión auxiliar mostraron que la tendencia y el intercepto si

fueron significativos al nivel mencionado, lo cual indica que a pesar de que la serie tiene raíz unitaria, esta podría contener también un componente de tendencia e intercepto en su estructura (ver Tabla 1).

TABLA 1. RESULTADOS DEL TEST DE DFA EN TENDENCIA E INTERCEPTO PARA EL NIVEL DE LA TRM

Null Hypothesis: TRM has a unit root Exogenous: Constant, Linear Trend				
Lag Length: 1 (Automatic - based on SIC, maxlag=21)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-3.404270	0.0513
Test critical values:	1% level		-3.966211	
	5% level		-3.413805	
	10% level		-3.128976	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation. Dependent Variable: D(TRM). Method: Least Squares. Date: 08/06/22 Time: 15:42. Sample: 4/13/2018 8/08/2022.				
Included observations: 1127				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
TRM(-1)	-0.017874	0.005251	-3.404270	0.0007
D(TRM(-1))	0.135443	0.029614	4.573589	0.0000
C	54.17848	15.64431	3.463144	0.0006
@TREND("4/13/2018")	0.018191	0.005957	3.053898	0.0023
R-squared	0.026027	Mean dependent var		1.423283
Adjusted R-squared	0.023425	S.D. dependent var		29.21774
S.E. of regression	28.87351	Akaike info criterion		9.567269
Sum squared resid	936221.9	Schwarz criterion		9.585112
Log likelihood	-5387.156	Hannan-Quinn criter.		9.574011
F-statistic	10.00294	Durbin-Watson stat		2.010265
Prob(F-statistic)	0.000002			

Fuente: Elaboración propia.

2.2. Análisis de Raíz Unitaria en el logaritmo de la TRM

Debido a que el nivel de la (TRM), para un nivel de significancia deseado (5%), mostró evidencia de tener raíz unitaria, se decidió transformar la serie de nivel a logaritmo natural de acuerdo con (Pahlavani & Reza, 2015). Este cambio se hizo con el propósito de suavizar la serie y de esta manera aumentar la probabilidad de rechazo de la hipótesis nula de raíz unitaria mediante la prueba de DFA. Como se observa en la Tabla 2, los resultados fueron exitosos mediante la aplicación del DFA en tendencia e intercepto a la serie en logaritmos, debido a que fueron significativos al 5.

Dado lo anterior se puede afirmar que la serie transformada es estacionaria, por lo tanto, resulta válido proceder con el desarrollo de un modelo ARIMA, para esto y siguiendo el método se procedió a evaluar el correlograma, usando la serie de datos obtenida en este ejercicio.

TABLA 2. TEST DE DFA EN TENDENCIA E INTERCEPTO EN EL LOGARITMO DEL NIVEL DE LA TRM

Null Hypothesis: LTRM has a unit root. Exogenous: Constant, Linear Trend				
Lag Length: 1 (Automatic - based on SIC, maxlag=21)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-3.507687	0.0390
Test critical values:	1% level		-3.966225	
	5% level		-3.413812	
	10% level		-3.128980	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation. Dependent Variable: D(LTRM). Method: Least Squares. Date: 08/06/22 Time: 16:52. Sample (adjusted): 4/17/2018 8/08/2022				
Included observations: 1125 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LTRM(-1)	-0.017522	0.004995	-3.507687	0.0005
D(LTRM(-1))	0.133954	0.029601	4.525240	0.0000
C	0.140669	0.039967	3.519647	0.0004
@TREND("4/13/2018")	4.91E-06	1.63E-06	3.021979	0.0026
R-squared	0.026669	Mean dependent var		0.000420
Adjusted R-squared	0.024065	S.D. dependent var		0.007871
S.E. of regression	0.007775	Akaike info criterion		-6.872178
Sum squared resid	0.067771	Schwarz criterion		-6.854309
Log likelihood	3869.600	Hannan-Quinn criter.		-6.865426
F-statistic	10.23849	Durbin-Watson stat		2.010052
Prob(F-statistic)	0.000001			

Fuente: Elaboración propia.

2.3. Correlograma de residuos de la regresión del logaritmo de la TRM respecto a su tendencia e intercepto


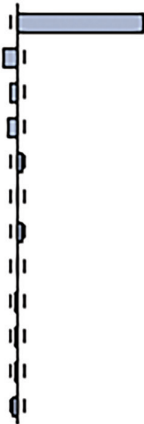
Como se pudo observar en la prueba del *DFA* en tendencia e intercepto para el logaritmo natural del nivel de la TRM, la serie mostró tener un componente de tendencia e intercepto que resultó ser significativo al 5%, razón por la que se consideró más apropiado usar el correlograma de la serie después de filtrar la misma por tendencia e intercepto.

En la Tabla 3, se observó un patrón de caída, tanto en la *Función de Autocorrelación Parcial (PAC)* o en el gráfico "*Partial Correlation*", como en la *Función de Autocorrelación Simple (AC)* "*Autocorrelation*", corresponde al de un proceso *AR(1)* (*autorregresivo de orden 1*). Este proceso fue caracterizado por la caída del *PAC* lentamente convergiendo hacia cero, mientras la *AC* cayó estrepitosamente.

2.4. Primer modelo: Modelo *AR(1)* con tendencia e intercepto

La Tabla 4 muestra en sus resultados que el agregado del componente autorregresivo de primer orden, cuyo filtro de tendencia e intercepto se calculó como el logaritmo de la TRM, mostró tener raíz cercana a la unidad, a pesar de haber mostrado un *P*-valor significativo al 5%.

TABLA 3. CORRELOGRAMA DEL LOGARITMO NATURAL DE LA TRM, DESPUÉS DE FILTRAR POR TENDENCIA E INTERCEPTO

Date: 08/06/22 Time: 17:22 Sample: 4/13/2018 8/08/2022 Included observations: 1127						
Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	0.983	0.983	1093.0	0.000
		2	0.964	-0.112	2143.2	0.000
		3	0.942	-0.057	3147.4	0.000
		4	0.918	0.074	4101.7	0.000
		5	0.895	0.034	5009.4	0.000
		6	0.872	0.006	5872.7	0.000
		7	0.851	0.028	6695.4	0.000
		8	0.831	-0.003	7479.9	0.000
		9	0.810	-0.015	8227.2	0.000
		10	0.790	-0.016	8938.2	0.000
		11	0.770	-0.009	9614.0	0.000
		12	0.748	-0.048	10253.	0.000

Fuente: Elaboración propia con desarrollo del software Eviews.

TABLA 4. PRIMER MODELO



Dependent Variable: LOG(TRM). Method: ARMA Maximum Likelihood (OPG - BHHH). Date: 08/06/22 Time: 17:38.				
Sample: 4/13/2018 8/08/2022.				
Included observations: 1127.				
Convergence achieved after 19 iterations. C				
Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5.689600	0.284927	19.96865	0.0000
@TREND	0.000332	3.83E-05	8.677409	0.0000
AR(1)	0.986962	0.003751	263.1294	0.0000
SIGMASQ	6.14E-05	1.36E-06	45.08897	0.0000
R-squared	0.994542	Mean dependent var		8.165157
Adjusted R-squared	0.994527	S.D. dependent var		0.106152
S.E. of regression	0.007853	Akaike info criterion		-6.849078
Sum squared resid	0.069254	Schwarz criterion		-6.831234
Log likelihood	3863.455	Hannan-Quinn criter.		-6.842335
F-statistic	68208.29	Durbin-Watson stat		1.732499
Prob(F-statistic)	0.000000			
Inverted AR Roots	.99			

Fuente: Elaboración propia. Elaboración propia con desarrollo del software Eviews.

2.5. Función de Autocorrelación Simple FAS y Función de autocorrelación Parcial FAP para el primer modelo

Al observar la FAS y FAP para los residuos del primer modelo, se pudo observar que los tres primeros niveles de ambas funciones estuvieron por fuera de las bandas al 95% de confianza estadística. Es decir, se pudo sospechar que hay un MA de 3. Aunque se presentaron rezagos más lejanos que también estuvieron por fuera de las bandas. Se procedió a analizar los resultados tres primeras. por tratarse de las más cercanas de conformidad con (Lewis-Beck *et al.*, 2012). Por otra parte, deriva en la modificación más parsimoniosa al modelo para continuar manteniéndolo simple mientras se trató de mejorarlo (Tabla 5).

TABLA 5. FAS Y FAP DE LOS RESIDUOS DEL PRIMER MODELO

Date: 08/06/22 Time: 17:50 Sample: 4/13/2018 8/08/2022 Included observations: 1127 Q-statistic probabilities adjusted for 1 ARMA term						
Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	0.131	0.131	19.343	
		2	0.070	0.054	24.862	0.000
		3	0.089	0.075	33.898	0.000
		4	-0.029	-0.054	34.864	0.000
		5	-0.017	-0.017	35.187	0.000
		6	-0.049	-0.049	37.955	0.000
		7	-0.006	-0.015	37.999	0.000
		8	-0.001	0.005	37.999	0.000
		9	0.018	0.026	38.384	0.000
		10	0.000	-0.011	38.384	0.000
		11	0.047	0.046	40.937	0.000
		12	0.057	0.041	44.589	0.000

*Probabilities may not be valid for this equation specification
Fuente: Elaboración propia con desarrollo del software Eviews.

El siguiente modelo fue un $ARMA(3,3)$ con tendencia e intercepto, este se propuso con la intención de poder extraer al máximo la información presente en las autocorrelaciones que surgieron en ambas funciones, *FAS* y *FAP*, en los tres primeros rezagos.

2.6. Modelo 2: $ARMA(3,3)$ con tendencia e intercepto

Se estimó un modelo $ARMA(3,3)$ con tendencia e intercepto. Los resultados presentados indicaron, que dos de los parámetros no fueron estadísticamente significativos al nivel del 5% tal y como se evidencia en la Tabla 6. En orden de menor a mayor significancia, estos fueron: el parámetro $MA(2)$, con un valor p del 69%, y el parámetro $AR(3)$, con un valor p del 25%. En función de estos resultados, se decidió eliminar del modelo el término menos significativo y proceder con una nueva estimación. Los resultados posteriores evidenciaron que el modelo logró capturar adecuadamente la información contenida en las tres primeras autocorrelaciones.

TABLA 6. MODELO 2

Dependent Variable: LOG(TRM). Included observations: 1127				
Date: 08/06/22 Time: 18:28. Sample: 4/13/2018 8/08/2022.				
Convergence achieved after 45 iterations				
Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5.788700	0.232165	24.93354	0.0000
@TREND	0.000319	3.12E-05	10.22935	0.0000
AR(1)	0.691051	0.158554	4.358464	0.0000
AR(2)	0.447900	0.194973	2.297241	0.0218
AR(3)	-0.163828	0.143375	-1.142653	0.2534
MA(1)	0.419020	0.163892	2.556679	0.0107
MA(2)	-0.057329	0.148645	-0.385680	0.6998
MA(3)	0.110853	0.029778	3.722704	0.0002
SIGMASQ	5.95E-05	1.56E-06	38.12451	0.0000
R-squared	0.994714	Mean dependent var		8.165157
Adjusted R-squared	0.994676	S.D. dependent var		0.106152
S.E. of regression	0.007745	Akaike info criterion		-6.872211
Sum squared resid	0.067068	Schwarz criterion		-6.832064
Log likelihood	3881.491	Hannan-Quinn criter.		-6.857041
F-statistic	26298.56	Durbin-Watson stat		1.994380
Prob(F-statistic)	0.000000			
Inverted AR Roots	.98	.29	-.58	
Inverted MA Roots	.15-.36i	.15+.36i	-.72	

Fuente: Elaboración propia. Elaboración propia con desarrollo del software Eviews.

2.7. Modelo 3: $ARMA(3,3)$ en tendencia e intercepto sin el parámetro $MA(2)$

Para este modelo se volvió a estimar el modelo 2, pero esta vez sin el parámetro $MA(2)$ que resultó no ser significativo en la ecuación anterior. De esta manera se probó que si quitando este parámetro mejoraría la significancia de los demás.

En la Tabla 7, los parámetros del modelo 3, fueron todos significativos al 5% de significancia estadística. Por otra parte, se observó que, las raíces características de los parámetros fueron todas menores a la unidad, razón por la cual se puede deducir que el modelo es convergente en varianza. Habiendo solucionado el problema de la significancia en los parámetros, se procedió a observar si el modelo lograba filtrar la información en los tres primeros rezagos lo suficiente como para desaparecer la autocorrelación que estuvo presente en el primer modelo.

Para verificar esto se analizó la autocorrelación de los errores, es decir se toman los errores y se corrió una función de autocorrelación.

2.8. FAS y FAP del modelo 3

Los resultados de las funciones de correlación en la Tabla 8 correspondientes al modelo 3, además fueron significativos como se observó en la tabla anterior. Pues se logró filtrar muy bien

TABLA 7. RESULTADO DE LA ESTIMACIÓN DEL MODELO 3

Sample: 4/13/2018 8/08/2022. Included observations: 1127. Convergence achieved after 52 iterations. Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	5.786836	0.233041	24.83188	0.0000
@TREND	0.000319	3.13E-05	10.19808	0.0000
AR(1)	0.694463	0.161508	4.299874	0.0000
AR(2)	0.386867	0.175866	2.199780	0.0280
AR(3)	-0.107083	0.027204	-3.936223	0.0001
MA(1)	0.415538	0.166930	2.489300	0.0129
MA(3)	0.118595	0.020795	5.702983	0.0000
SIGMASQ	5.95E-05	1.56E-06	38.13990	0.0000
R-squared	0.994714	Mean dependent var		8.165157
Adjusted R-squared	0.994681	S.D. dependent var		0.106152
S.E. of regression	0.007742	Akaike info criterion		-6.873915
Sum squared resid	0.067073	Schwarz criterion		-6.838228
Log likelihood	3881.451	Hannan-Quinn criter.		-6.860430
F-statistic	30080.24	Durbin-Watson stat		1.994865
Prob(F-statistic)	0.000000			
Inverted AR Roots	.98	.22	-.50	
Inverted MA Roots	.13+.40i	.13-.40i	-.68	

Fuente: Elaboración propia. Elaboración propia con desarrollo del software Eviews.

la información de los tres primeros rezagos, al punto que la autocorrelación de los residuos del modelo no fue significativa, es decir que estuvieron dentro de las bandas del 95% de confianza estadística. Por otra parte, en cuanto a los rezagos más alejados se observó con la prueba del *Q-Stat* no se encontró evidencia de que la suma de la autocorrelación de los rezagos.

Lo anterior confirma que el modelo planteado logro filtrar toda la información relevante de la serie a tal punto de dejar la información no relevante en forma de ruido blanco. Sin embargo, se procedió a probar si la serie presentaba efecto *ARCH* (*Heteroscedasticidad condicionada*) tal como lo menciona (Madrid *et al.*, 2007), en cuyo caso hubiere sido necesario modificar el modelo añadiendo un componente de la familia de los modelos *ARCH-GARCH* con el fin de filtrar la información contenida en las varianzas rezagadas e incorporarlas al modelo y sus pronósticos. No deberían presentarse autocorrelaciones entre los rezagos cuadráticos con el fin que las predicciones, esto es extraer información de que tan acertado puede ser el siguiente pronóstico.

2.9. Correlograma de los residuos cuadráticos

De acuerdo con la Tabla 9, se observó que el correlograma de los residuos cuadráticos resultó tener rezagos significativos. Lo cual implica que las varianzas rezagadas estuvieron influyendo en las varianzas actuales y futuras. Se procedió a filtrar esta información, en vista de que los 5 primeros rezagos en ambas funciones tanto la *FAS* como la *FAP*. Los resultados

TABLA 8. FAS Y FAP DEL MODELO 3

Date: 08/06/22 Time: 19:11 Sample: 4/13/2018 8/08/2022 Included observations: 1127 Q-statistic probabilities adjusted for 5 ARMA terms						
Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	-0.001	-0.001	0.0005	
		2	-0.004	-0.004	0.0222	
		3	-0.002	-0.002	0.0263	
		4	0.007	0.007	0.0786	
		5	-0.021	-0.021	0.5879	
		6	-0.034	-0.034	1.8708	0.171
		7	0.002	0.002	1.8757	0.391
		8	0.009	0.009	1.9671	0.579
		9	0.018	0.018	2.3169	0.678
		10	-0.004	-0.004	2.3323	0.802
		11	0.047	0.046	4.8711	0.560
		12	0.058	0.058	8.7630	0.270
		13	-0.021	-0.020	9.2449	0.322
		14	0.004	0.006	9.2594	0.414
		15	-0.008	-0.007	9.3251	0.502
		16	-0.035	-0.034	10.705	0.468
		17	-0.005	-0.000	10.737	0.552
		18	-0.067	-0.065	15.859	0.257
		19	0.004	0.002	15.878	0.321
		20	0.012	0.009	16.043	0.379
		21	0.001	-0.003	16.043	0.450
		22	0.043	0.041	18.124	0.381

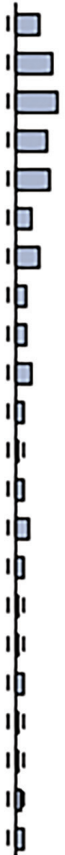

Fuente: Elaboración propia con desarrollo del software Eviews.

fueron significativos al 5% de confianza estadística, a partir de la cual se propuso incorporar a la ecuación un componente *EGARCH (5,5)* con quinto *Orden Asimétrico*.

2.10. Modelo 4: Modelo *ARMA(3,3)* sin parámetro *MA(2)* con componente *EGARCH(5,5)* y quinto *Orden Asimétrico*

En la Tabla 10 se puede observar el resultado del modelo. Una particularidad es que el único parámetro que no fue significativo al 5% de significancia estadística fue el parámetro *AR(3)*. Sin embargo, se considera permitirlo dentro de la estimación ya que, debido a la cantidad de parámetros que hay incluidos tanto en la parte *ARMA* como en la parte *EGARCH*, hacen que el modelo sea muy sensible a los cambios en su estructura. Por ejemplo, quitar o agregar otro parámetro, podría cambiar drásticamente la significancia de todos los estimadores,

TABLA 9. CORRELOGRAMA DE LOS RESIDUOS CUADRÁTICOS DEL MODELO 3

Date: 08/06/22 Time: 19:26 Sample: 4/13/2018 8/08/2022 Included observations: 1127						
Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	0.171	0.171	33.040	0.000
		2	0.254	0.232	106.07	0.000
		3	0.289	0.235	200.49	0.000
		4	0.214	0.116	252.50	0.000
		5	0.223	0.098	309.04	0.000
		6	0.110	-0.044	322.74	0.000
		7	0.166	0.032	354.15	0.000
		8	0.072	-0.053	360.12	0.000
		9	0.067	-0.028	365.23	0.000
		10	0.100	0.030	376.64	0.000
		11	0.059	0.019	380.60	0.000
		12	0.020	-0.036	381.07	0.000
		13	0.048	0.014	383.68	0.000
		14	0.085	0.062	392.01	0.000
		15	0.058	0.037	398.58	0.000
		16	0.021	-0.022	396.36	0.000
		17	0.011	-0.047	396.51	0.000
		18	0.047	0.007	398.99	0.000
		19	0.016	-0.005	399.30	0.000
		20	0.013	-0.005	399.50	0.000
		21	0.036	0.023	401.00	0.000
		22	0.046	0.049	403.47	0.000

Fuente: Elaboración propia con desarrollo del software Eviews.

e inclusive cambiar la forma en cómo se están filtrando los rezagos, además de las raíces características.

Omitiendo el *P-Valor* del parámetro $MA(3)$, por las razones ya expuestas, se observa que la ecuación empleada fue capaz de filtrar toda la información de los rezagos tanto simples como cuadráticos.

3. RESULTADOS

Finalmente, los resultados sugieren que el modelo 4 fue estadísticamente significativo y cumplió con los criterios econométricos necesarios para considerarlo válido, tal y como se explicará en este aparte. En tabla anterior, se presentó la ecuación que calcula el pronóstico de la tasa de cambio del peso colombiano contra el dólar estadounidense. A continuación, se detallan los criterios que validan el modelo o ecuación definitiva.

TABLA 10. ESTIMACIÓN DEL MODELO 4

Metadatos del Modelo	Variable Dependiente: LOG(TRM)	Fecha: 08/06/22 20:35	Método: ML ARCH (Normal)	Muestra: 4/13/18-8/08/22 (1127 obs.)	Convergencia: No mejora	Cov. Coef.: OPG	MA Backcast: 4/10/18-4/12/18	Varianza Presample: Backcast (0.7)
Ecuación GARCH	\multicolumn{9">{ 9 }							
Ajuste y Raíces	R²: 0.9947	R² Adj.: 0.9946	{ LOG(GARCH) = C(8) + C(9)* S.E.: 0.0078	RESID(-1) \sum Res²: 0.0677	$\sqrt{\text{GARCH}(-1) + \text{C}(10)^*}$ Log-L: 4011.07	RESID(-2) DW: 2.075	$\sqrt{\text{GARCH}(-2) + \text{C}(11)^*}$ AIC: -7.077	RESID(-3) SIC: -6.975

Fuente: Elaboración propia con desarrollo del software Eviews.

Se realizaron verificaciones de control, incluyendo el cálculo de las funciones FAS y FAP del modelo, con el objetivo de evaluar que la nueva especificación no hubiese deteriorado los parámetros previamente considerados óptimos o adecuados para la elaboración de pronósticos.

3.1. Funciones *FAS* y *FAP* del modelo 4

De acuerdo con los datos de la Tabla 11, el modelo logró filtrar adecuadamente la información contenida en los rezagos al punto que, por la prueba del *Q-Stat*. Los resultados sugieren que no existe evidencia de que haya autocorrelación en los rezagos simples al 5% de significancia estadística, es decir, que los parámetros estimados para pronosticar siguen siendo significativos.

TABLA 11. DATOS CORRELOGRAMA FAS Y FAP DEL MODELO 4

Descripción	Valor	Lag	AC	PAC	Q-Stat	Prob*
Análisis		1	0.008	0.008	0.067	—
Fecha	8/06/2022	5	−0.031	−0.032	26.161	—
Hora	20:51	10	0.022	0.021	45.478	0.474
Muestra	4/13/2018 al 8/08/2022	15	−0.004	−0.006	96.669	0.47
Observaciones incluidas	1127	20	−0.009	−0.01	15.424	0.421
Ajuste	5 términos ARMA	22	0.05	0.05	18.318	0.369

Fuente: Elaboración propia con desarrollo del software Eviews.

A continuación, se precedió a verificar si la ecuación de GARCH logró filtrar bien la autocorrelación en los errores cuadráticos, es decir que la varianza es predecible con un nivel de confianza o se logró extraer la señal de la varianza es decir determinar la trayectoria de la varianza. Para esto nuevamente fue necesario calcular el FAS y la FAP.

3.2. *FAS* y *FAP* de los errores cuadráticos del modelo 4

En la Tabla 12, los resultados muestran que el modelo también logró filtrar satisfactoriamente la información que estaba contenida en los rezagos de los errores cuadráticos, de manera que, como se puede comprobar, por el estadístico *Q-Stat*, los rezagos muestran que al 5% de significancia estadística, no hay evidencia de autocorrelación en los errores cuadráticos.

TABLA 12. FAS Y FAP DE LOS ERRORES CUADRÁTICOS DEL MODELO 4

Descripción	Valor	Lag	AC	PAC	Q-Stat	Prob*
Análisis		1	−0.005	−0.005	0.0238	0.877
Fecha	8/06/2022	5	0.047	0.047	56.347	0.343
Hora	20:55	10	0.02	0.019	10.491	0.399
Muestra	4/13/2018 al 8/08/2022	15	0.036	0.039	14.429	0.493
Observaciones incluidas	1127	20	−0.018	−0.019	16.647	0.676
Ajuste	5 términos ARMA	22	0.037	0.039	18.241	0.692

Fuente: Elaboración propia con desarrollo del software Eviews.

Esto implica que ya el modelo ha logrado retener la señal proveniente de la información pasada y aislarla del ruido con el que viene acompañada mediante el filtro que está contenido en la ecuación híbrida que se ha creado a lo largo de este trabajo.

Con esto en mente ahora queda, en base a esa ecuación, pronosticar cual es la senda esperada para lo que resta del mes de agosto del 2022. Con el fin de poder tener una perspectiva sobre la tendencia que puede tomar el dólar estadounidense en los próximos días, en medio del escenario de incertidumbre global que se está viviendo hoy en día ante la coyuntura política, económica y social.

A partir de la información del documento, se puede validar el modelo de pronóstico de la TRM, el cual combina los principios ARIMA-GARCH, para que aporte mayor solidez a su capacidad predictiva.

3.3. Validación del modelo usando los criterios de información de Akaike (AIC) el criterio de información bayesiano (BIC)

Con el fin de validar y comparar la solidez predictiva del modelo final seleccionado (Modelo 4) frente a los modelos alternativos que se diseñaron, se muestra en la Tabla 13 una síntesis de las cifras asociadas con los criterios AIC y BIC. Al comparar los valores, se puede concluir desde este punto de vista que el modelo 4 es el que cuenta con mejor ajuste de los cuatro, ya que presenta los datos más bajos de AIC (-7.077) y BIC (-6.975), lo cual deja ver una mayor robustez predictiva y un ajuste más parsimonioso.

TABLA 13. COMPARATIVO CRITERIOS AIC Y BIC

Modelo	AIC	BIC
AR(1) con tendencia e intercepto	-6.849078	-6.831234
ARMA(3,3) con tendencia e intercepto	-6.872211	-6.832064
ARMA(3,3) sin MA(2), con tendencia e intercepto	-6.873915	-6.838228
ARMA(3,3) sin MA(2) con componente EGARCH(5,5)	-7.077000	-6.975000

Fuente: Elaboración propia.

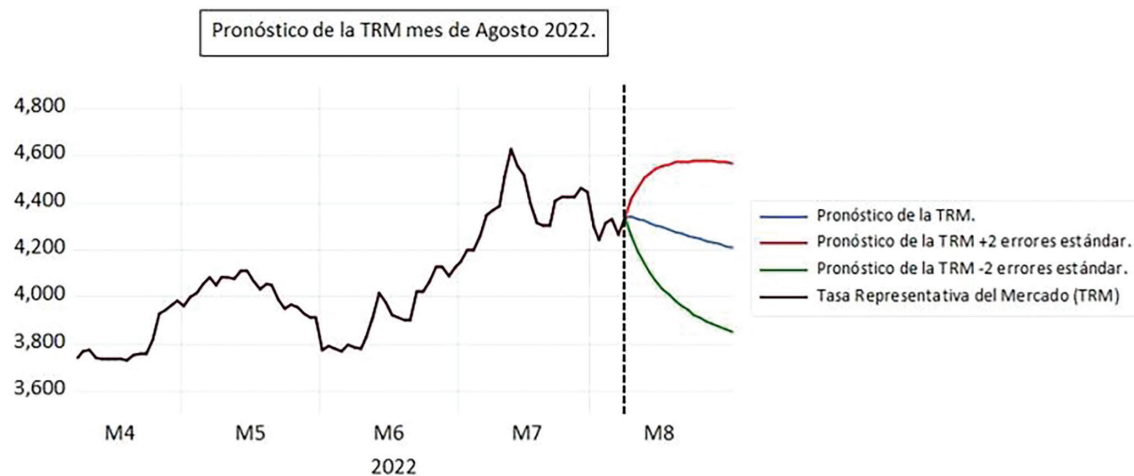
3.4. Pronóstico del modelo 4 para agosto del 2022

Conforme al modelo construido y a la información capturada en el presente ejercicio, se pronosticó, que la (TRM) podría continuar en tendencia bajista en lo que queda del mes agosto (año 2022) para bajar desde los COP 4341 actuales, hasta los COP 4212, lo que representaría aproximadamente una caída del 2.47% en el precio de la divisa (ver Gráfica 3).

Para el mediano y largo plazo se corrió el modelo para determinar la trayectoria de la TRM a partir de enero del año 2023. Con el fin de contar con una mejor perspectiva, se crearon diez escenarios (normal alcista y bajista) usando simulaciones atadas a los parámetros estadísticos generados (Gráfica 4) Estas fueron realizadas con datos a partir de enero de 2023 usando lenguaje de programación en Python.

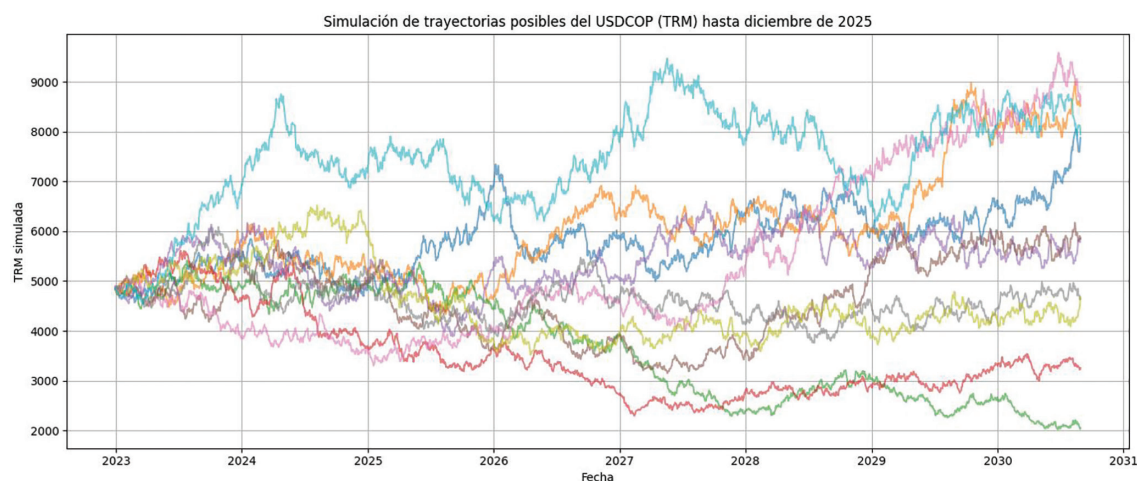
Posteriormente, se simplificó este comportamiento esperado en únicamente tres líneas que describieran el posible comportamiento del precio (Gráficas 4 y 5). Basados en una comparación de los datos reales contra los estimados a manera de backtesting para los años 2023, 2024 y 2025

GRÁFICA 3. PRONÓSTICO DE LA TRM (USD/COP)



Fuente: Utadeo Finance & Business Club Vicepresidencia de Research, con datos del año 2022 usando LSEG (antes Refinitiv) y cifras del Banco de la República.


GRÁFICA 4. ESCENARIOS PRONÓSTICOS DE LA TRM (USD/COP) HASTA EL AÑO 2030



Fuente: Elaboración propia con datos de LSEG (antes Refinitiv) y formulado en Python.

hasta julio, se encontró que la trayectoria bajista es la que mejor describió el comportamiento de la TRM para el mediano plazo y es la que se considera actualmente la que cuenta con mayor validez para pronosticar si se asocia este ejercicio econométrico con expectativas frente a las tasas de interés por parte de la Reserva Federal de los Estados Unidos y sus efectos económicos, tema que si bien aporta en la tare diaria de los analistas del mercado bursátil, es una limitación de este trabajo por lo que se sugiere sea objeto de investigaciones futuras que combinen análisis fundamental con el estadístico.

GRÁFICA 5. ESCENARIOS ALCISTA, BAJISTA Y PROMEDIO PARA EL PRONÓSTICO DE LA TRM



Fuente: Elaboración propia con datos de LSEG (antes Refinitiv) y formulado en Python.

4. CONCLUSIONES

Se cuenta con una gran cantidad de modelos de pronóstico que permiten, de manera científica, prever comportamientos de variables económicas. Desde los modelos clásicos de regresión lineal simple hasta combinaciones de *Big Data* con modelos de equilibrio general DSGE.

Se puede inferir con el resultado obtenido en el ejercicio de pronóstico del tipo de cambio, que no tiene que ser de elevada complejidad un modelo para que arrojar como resultado un pronóstico razonable. Por lo tanto, es bastante útil que, basados en las series históricas y aplicando técnicas desarrolladas y probadas por reconocidos autores, se cuente con proyecciones útiles para la sociedad.

En concordancia con los hallazgos presentados por (Kumari & Gupta, 2022), se demuestra que la combinación de diversas ecuaciones y principios asociados con el cálculo de pronósticos resulta ser válida y merece ser explorada. En este sentido los aportes de (Ayala & Bucio, 2020) fueron verificados, y para el caso colombiano se prueba que la realización de experimentos consecutivos, incluso de ensayo y error, pueden llevar a considerar modelos de pronóstico estadísticamente significativos.

De conformidad con (Urrutia & Llano, 2011) trabajos basados en la actual metodología deben ser desarrollados de manera continua ya que son herramientas e insumos necesarios para contar con mejor información para tomar decisiones en materia económica y en particular de política monetaria. En este sentido, se observó que la dinámica en el cambio de precios de los activos en los mercados exige actualización permanente de los modelos, parámetros y variables de cálculo.

Asimismo, los experimentos realizados coinciden con las apreciaciones mencionada de (Urrutia & Llano, 2011) y de (Arce, *et al.*, 2019) quienes consideran que, aunque los modelos ajusten bien, es necesario actualizarlos de manera permanente ya que es posible que cambios asociados a hechos sociales, fenómenos naturales o económicos lleven a que se den variaciones en los parámetros de las variables que permiten estimar o realizar los pronósticos.

Se demuestra que los modelos ARIMA pueden ser aplicados bien en series de tiempo de variables como la tasa de cambio que suelen tener ausencia de estacionalidad tal y como lo lograron afirmar (Li, *et al.*, 2020) y (Sirisha, *et al.*, 2022). Esto se logra mediante la incorporación de apoyos, en este caso se usó GARCH, siguiendo estudios previos ya señalados.

El resultado del ejercicio realizado en el presente trabajo sugiere que resulta útil emplear una metodología igual o similar para pronosticar otras variables como el índice de precios al consumidor, pues al contar con un análisis de estacionalidad, se pueden obtener parámetros y ecuaciones finales de estimación con ajustes muy aproximados a lo observado. Lo anterior, resulta en un aporte de calidad a los pronósticos que los analistas enviamos a los Bancos Centrales y que sirve de insumo para determinar cambios en el precio del dinero u otras variables que tienen efecto sobre la población.

FINANCIACIÓN

Esta investigación no ha recibido financiación externa.

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización: Edgar Ricardo Jiménez Méndez; **Metodología:** Nicolás Aguilera Peña y Edgar Ricardo Jiménez Méndez; **Obtención de datos:** Nicolás Aguilera Peña; **Análisis de datos:** Nicolás Aguilera Peña y Edgar Ricardo Jiménez Méndez; **Redacción:** Nicolás Aguilera Peña y Edgar Ricardo Jiménez Méndez; **Preparación del borrador original:** Raúl Alberto Cortés Villafradez y Edgar Ricardo Jiménez Méndez; **Redacción, revisión y edición:** Raúl Alberto Cortés Villafradez; **Supervisión:** Edgar Ricardo Jiménez Méndez.

REFERENCIAS

- Arce, P., Antognini, J., Poller, W. K., & Salinas, L. (2019). Modelo basado en cointegración rápido y adaptativo para pronosticar series temporales financieras de alta frecuencia. *Computación Económica*, 54, 99–112. <https://doi.org/10.1007/s10614-017-9691-7>
- Ayala, R. F., & Bucio, C. (2020). Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes. *Revista mexicana de economía y finanzas*, 15(3), 331–354. <https://doi.org/10.21919/remef.v15i3.466>
- Baghestani, H. (1992). On the formation of expected inflation under various conditions?: Some survey evidence. *The Journal of Business*, 65(2), 281–293. <https://www.jstor.org/stable/2353166>
- Box, G. E. P., & Jenkins, G. M. (1989). *Time series analysis: Forecasting and control* (1970). https://onlinelibrary.wiley.com/doi/10.1111/jtsa.12194?utm_source=researchgate
- Cao, X., & Zhao, Z. (2022). Research on stock index forecasting based on ARIMA-GARCH and SVM mixed model. *Highlights in Science, Engineering and Technology*, 1, 40–46. <https://doi.org/10.54097/hset.v4i.843>
- Clauson, A. L. (1997). Forecasting retail food prices under current conditions. *American Journal of Agricultural Economics*, 79(5), 1669–1672. <https://doi.org/10.2307/1244400>
- Clavijo, S. (2001). El régimen de flotación cambiaria en Colombia. (Vol. 7, Issue 2). <https://www.banrep.gov.co/es/el-regimen-flotacion-cambiaria-colombia>

- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2nd ed.). Hillsdale, NJ: Lawrence Erlbaum Associates, Publishers. ISBN 9780805802832.
- Dagum, E. B., & Morry, M. (1984). Basic issues on the seasonal adjustment of the canadian consumer price index. *Journal of Business & Economic Statistics*, 2(3), 250–259. <https://doi.org/10.1080/07350015.1984.10509392>
- Dritsaki, C. (2018). The performance of hybrid ARIMA-GARCH modeling and forecasting oil price. *International Journal of Energy Economics and Policy*, 8(3), 14–21. <https://www.econjournals.com/index.php/ijeep/article/view/6437>
- Dyhrberg, A. H. (2015). *Bitcoin, gold and the dollar - a GARCH volatility analysis*. University College Dublin. School of Economics. <http://hdl.handle.net/10197/7168>
- Gao, J. (2021). Research on stock price forecast based on ARIMA-GARCH model. *E3S Web of Conferences*, 292, 02030. <https://doi.org/10.1051/e3sconf/202129202030>
- Ghani, I. M., & Rahim, H. A. (2019). Modeling and forecasting of volatility using ARMA-GARCH: Case study on Malaysia natural rubber prices. *IOP Conference Series: Materials Science and Engineering*, 548(1). <https://doi.org/10.1088/1757-899X/548/1/012023>
- Granger, P. N., & Jenkins, C. W. (1974). Experience with forecasting univariate time series and the combination of forecasts. *Journal of the Royal Statistical Society*, 137(2), 131–165. <http://www.jstor.com/stable/2344546>
- Guo, W., Liu, Q., Luo, Z., & Tse, Y. (2022). Forecasts for international financial series with VMD algorithms. *Journal of Asian Economics*, 82. <https://doi.org/10.1016/j.asieco.2022.101458>
- Jain, R. K. (1989). The seasonal adjustment procedures for the consumer price indexes: Some empirical results. *Journal of Business & Economic Statistics*, 7(4), 461–469. <https://doi.org/10.1080/07350015.1989.10509758>
- Kang, H. (1986). Univariate ARIMA forecasts of defined variables. *Journal of Business & Economic Statistics*, 4(1), 81–86. <https://doi.org/10.2307/1391389>
- Kučera, J., Kalinová, E., & Divoká, L. (2022). Profitability of current investments in stock indexes. *Entrepreneurship and Sustainability Issues*, 10(1), 420–434. [https://doi.org/10.9770/jesi.2022.10.1\(23\)](https://doi.org/10.9770/jesi.2022.10.1(23))
- Kumari, S., & Gupta, J. (2022). Forecasting SGD-INR exchange return: An application of autoregressive integrated moving average. *ANUSANDHAN - NDIM's Journal of Business and Management Research*, 4(1), 16–22. <https://doi.org/10.56411/anusandhan.2022.v4i1.16-22>
- Lee, T., Wang, H., Xi, Z., & Zhang, R. (2023). Density forecast of financial returns using decomposition and maximum entropy. *Diario de Métodos Económicos*, 12(1), 57–83. <https://doi.org/10.1515/jem-2020-0014>
- Lewis-Beck, M., Bryman, A., & Futing Liao, T. (2012). Box-Jenkins modeling. *The SAGE Encyclopedia of Social Science Research Methods*, 1–2. <https://doi.org/10.4135/9781412950589.n80>
- Li, Z., Han, J., & Song, Y. (2020). On the forecasting of high-frequency financial time series based on ARIMA model improved by deep learning. *Journal of Forecasting*, 39(7), 1081–1097. <https://doi.org/10.1002/for.2677>

- Madrid, C., Pellegrini, S., Ruiz, E., & Espasa, A. (2007). The relationship between ARIMA-GARCH and unobserved component models with GARCH disturbances. (Working Paper). <https://ideas.repec.org/p/cte/wsrepe/ws072706.html>
- Najamudin, M., & Fátima, S. (2022). Hybrid BRNN-ARIMA model for financial time series forecasting. *Sukkur IBA Journal of Computing and Mathematical Sciences*, 6(1), 62–71. <https://doi.org/10.30537/sjcms.v6i1.1027>
- Pahlavani, M., & Reza, R. (2015). The comparison among ARIMA and hybrid ARIMA-GARCH models in forecasting the exchange rate of Iran. *International Journal of Business and Development Studies*, 7(1), 31–50. https://ijbds.usb.ac.ir/article_2198.html
- Peng, Z., Khan, F. U., Khan, F., Shaikh, P. A., Yonghong, D., Ullah, I., & Ullah, F. (2020). An application of hybrid models for weekly stock market index prediction: Empirical evidence from SAARC countries. *Complexity in Financial Markets*. <https://doi.org/10.1155/2021/5663302>
- Pinčák, R., & Bartoš, E. (2015). With string model to time series forecasting. *Physica A: Statistical Mechanics and its Applications*, 436, 135–146. <https://doi.org/10.1016/j.physa.2015.05.013>
- Shen, W., Guo, X., Wu, C., & Wu, D. (2011). Forecasting stock indices using radial basis function neural networks optimized by artificial fish swarm algorithm. *Knowledge-Based Systems*, 24(3), 378–385. <https://doi.org/10.1016/j.knosys.2010.11.001>
- Sirisha, U. M., Belavagi, M. C., & Attigeri, G. (2022). Profit prediction using ARIMA, SARIMA and LSTM models in time series forecasting: A comparison. *IEEE Access*, 10, 124715–124727. <https://doi.org/10.1109/ACCESS.2022.3224938>
- Staffini, A. (2022). Stock price forecasting by a deep convolutional generative adversarial network. *Frontiers in Artificial Intelligence*, 5, 1–16. <https://doi.org/10.3389/frai.2022.837596>
- Thomakos, D. D., & Bhattacharya, P. S. (2005). Forecasting Inflation, Industrial Output and Exchange Rates: A Template Study for India. *Indian Economic Review*, 40(2), 145–165. <http://www.jstor.org/stable/29793841>
- Torres, L. E. (2014). *Contraste entre modelos de Redes Neuronales Artificiales, GLM y GARCH en el pronóstico y análisis del tipo de cambio mexicano: 2000-2014*. [Tesis de maestría, Repositorio Institucional Universidad Autónoma del Estado de México]. <http://hdl.handle.net/20.500.11799/67002>
- Urrutia, M., & Llano, J. (2011). La crisis internacional y cambiaria de fin de siglo en Colombia. *Desarrollo y Sociedad*, 67, 11–48. <https://doi.org/10.13043/dys.67.1>
- Vizek, M., & Broz, T. (2009). Modeling inflation in Croatia. *Emerging Markets Finance and Trade*, 45(6), 87–98. <https://doi.org/10.2753/REE1540-496X450606>
- Wang, F., Li, M., Mei, Y., & Li, W. (2020). Time series data mining: A case study with big data analytics approach. *IEEE Access*, 8, 1–7. <https://doi.org/10.1109/ACCESS.2020.2966553>
- Wang, Y., & Guo, Y. (2020). Forecasting method of stock market volatility in time series data based on mixed model of ARIMA and XGBoost. *China Communications*, 17(3), 205–221. <https://doi.org/10.23919/JCC.2020.03.017>