



**Efecto de la tasa interbancaria en el precio *spot* del índice Colcap: un enfoque econométrico y predictivo**

Effect of the interbank rate on the spot price of the Colcap index: an econometric and predictive approach

Por

Andrés Mauricio Uribe Arenas<sup>1</sup>

Andrés Felipe Restrepo Baena<sup>2</sup>

Trabajo de grado presentado como requisito parcial para obtener el título de  
Magíster en Administración Financiera – MAF

Asesor

Juan Carlos Botero Ramírez

Universidad EAFIT  
Escuela de Finanzas, Economía y Gobierno  
Maestría en Administración Financiera – MAF  
Medellín  
2025

---

<sup>1</sup> amuribea@eafit.edu.co

<sup>2</sup> afrestrepb@eafit.edu.co

© 2025 Andrés Uribe y Andrés Restrepo  
Todos los Derechos Reservados

## Resumen

La presente investigación indaga cómo las fluctuaciones de la tasa interbancaria (IBR) influyen en el precio spot del índice Colcap, utilizando datos históricos de fuentes financieras confiables. Se emplearon modelos econométricos y de aprendizaje automático, como el GARCH-X para medir la volatilidad, el SARIMA para patrones temporales y redes neuronales para identificar relaciones no lineales.

Los resultados indican que un aumento del 1 % en el IBR reduce, en promedio, un 9,5 % los retornos del Colcap, evidenciando una relación negativa significativa. Se concluye que el Colcap ejerce una causación única sobre el IBR, la cual se materializa a 5 rezagos y destaca la influencia del mercado bursátil en la tasa interbancaria.

Los modelos de redes neuronales demostraron una mayor precisión para pronosticar la volatilidad. Finalmente, se proyecta una senda alcista moderada del Colcap a 12 meses, destacando el monitoreo del IBR como clave para decisiones financieras estratégicas.

Palabras claves:

- Inversión – Capital – Capital intangible – Capacidad
- Nivel de precios – Inflación – Deflación
- Tasas de interés: determinación, estructura temporal y efectos
- Comercio y medioambiente
- Impactos macroeconómicos – Tasas de interés: determinación, estructura temporal y efectos

## Abstract

This research investigates how fluctuations in the interbank rate (IBR) influence the spot price of the COLCAP index, using historical data from reliable financial sources. Econometric and machine learning models were employed, such as GARCH-X to measure volatility, SARIMA for time patterns, and neural networks to identify nonlinear relationships.

The results indicate that a 1% increase in the IBR reduces Colcap returns by an average of 9.5%, highlighting a significant negative relationship. It is concluded that the COLCAP exerts a unique causation on the IBR, materializing at 5 lags and emphasizing the influence of the stock market on the interbank rate.

The neural network models demonstrated greater accuracy in forecasting volatility. Finally, a moderate upward trend for the COLCAP is projected over 12 months, highlighting the monitoring of the IBR as key to strategic financial decision-making.

### Keywords:

- Investment - Capital - Intangible Capital - Capacity
- Price Level - Inflation - Deflation
- Interest Rates: Determination, Term Structure, and Effects
- Trade and Environment
- Macroeconomic Impacts Interest Rates: Determination, Term Structure, and Effects

## Contenido

1. Introducción .....	1
2. Marco teórico .....	3
3. Metodología .....	5
3.1 Causalidad de Granger. Relación de causación.....	5
3.2. Modelo GARCH y GARCH-X. Volatilidad condicional y factores externos.....	6
3.3 Modelo SARIMA. Captura de patrones estacionales.....	8
3.4 Modelo <i>Ridge</i> VAR. Relaciones dinámicas entre variables.....	9
3.5 Modelo híbrido ARIMA + ANN y LSTM. Modelos no lineales .....	11
4. Resultados .....	13
4.1. Causalidad de Wiener-Granger .....	13
4.2. Modelo GARCH-X .....	14
4.3. Modelo SARIMA .....	16
4.4. Modelo <i>Ridge</i> VAR.....	18
4.5. Modelo híbrido ARIMA + ANN.....	19
4.5. Modelo híbrido ARIMA + LSTM.....	21
5. Conclusiones .....	23
Referencias .....	25

## Índice de tablas

Tabla 1. Resultados del test de causalidad de Weiner-Granger. Influencia del IC en el IBR.....	13
Tabla 2. Resultados del test de causalidad de Weiner-Granger. Influencia del IBR en el IC.....	13
Tabla 3. Coeficientes del modelo GARCH-X para el IC .....	15
Tabla 4. Métricas de error del modelo GARCH-X .....	15
Tabla 5. Métricas de error del modelo SARIMA .....	17
Tabla 6. Métricas de error del modelo <i>Ridge</i> VAR.....	18
Tabla 7. Métricas de error del modelo híbrido ARIMA + ANN.....	20
Tabla 8. Métricas de error del modelo híbrido ARIMA + LSTM.....	21

## Índice de figuras

Figura 1. Proyección de retornos del IC con el modelo GARCH-X. Valores reales frente a los predichos (2014-2026p).....	16
Figura 2. Proyección de retornos del IC con el modelo SARIMA. Valores reales frente a los predichos (2014-2026p).....	17
Figura 3. Proyección de retornos del IC con el modelo <i>Ridge</i> VAR. Valores reales frente a los predichos (2014-2026p).....	19
Figura 4. Proyección de retornos del IC con el modelo híbrido ARIMA + ANN. Valores frente a los predichos (2014-2026-p).....	20
Figura 5. Proyección de retornos del IC con el modelo híbrido ARIMA LSTM. Valores reales frente a los predichos (2014-2026-p).....	22

## 1. Introducción

El índice Colcap —en adelante el IC—, como principal barómetro del mercado bursátil colombiano, refleja la dinámica y la vitalidad de las acciones más líquidas en la Bolsa de Valores de Colombia (BVC). Su comportamiento no solo ofrece una visión integral del estado del mercado financiero del país, sino que se ve profundamente influenciado por las políticas monetarias que regulan las tasas de interés, en particular la tasa interbancaria —*interbank rate*, en adelante la TI—. Esta investigación se enfoca en desentrañar el impacto de la TI sobre el IC, con el objetivo de proporcionar una herramienta analítica que permita anticipar las tendencias futuras de este índice, crucial para los inversionistas y la economía colombiana en general.

El *objetivo general* de la investigación es proponer modelos que respondan a las variaciones en la TI, facilitando así una adecuada toma de decisiones en relación con la tendencia futura del precio *spot* del IC. Los *objetivos específicos* incluyen cuantificar la correlación entre las fluctuaciones de la TI y los movimientos del IC, identificar los canales de influencia de dicha tasa sobre el índice, y presentar modelos predictivos para anticipar su comportamiento.

La importancia de indagar en esta relación radica en la influencia significativa que las tasas interbancarias tienen sobre el costo del crédito y, en consecuencia, sobre las condiciones del mercado de valores. Un aumento en la TI tiende a encarecer el crédito, lo cual puede reducir la liquidez en el mercado y presionar a la baja los precios de las acciones, tal como lo han sugerido los estudios de Fama y French (1992), Damodaran (2019) y Delgado Rojas *et al.* (2024).

El *alcance* de la investigación abarca una serie de análisis empíricos y metodológicos detallados. Para ello se utilizaron datos de tasas interbancarias y del IC durante un período de diez años (2014-2024) que garantizaran la robustez de los resultados mediante técnicas de análisis descriptivo, correlacional y modelos econométricos avanzados, incluyendo regresiones lineales múltiples y modelos VAR. La *metodología* incorpora análisis de redes neuronales, para ofrecer una visión integral del impacto de las tasas interbancarias en el mercado bursátil colombiano.

Se ha identificado que el IC es un receptor de volatilidad que presenta sus mayores variaciones en momentos de incertidumbre. En este contexto cobra especial relevancia la utilización de modelos que capturen adecuadamente dicha volatilidad, como los vectores autorregresivos generalizados (VAR) u otros enfoques analíticos, a fin de comprender mejor su comportamiento. López Gaviria (2019) resaltó que el mercado accionario colombiano, incluido el Colcap, está sujeto a ciclos dependientes de la dinámica de variables externas como la tasa de cambio y los retornos internacionales, lo que sugiere la necesidad de aplicar técnicas analíticas precisas para anticipar variaciones significativas. Por lo tanto, la validez de estos modelos dependerá de la calidad de los datos y de su correcta aplicación en los análisis predictivos.

Esta investigación se organiza en capítulos que incluyen revisión del *marco teórico*, *metodología* detallada, análisis de *resultados* y *conclusiones*. Cada capítulo está diseñado para construir una relación que explica cómo las tasas interbancarias afectan al IC, ofreciendo herramientas prácticas y teóricas para una mejor toma de decisiones en el contexto del mercado de valores colombiano. Su propósito es no solo proporcionar una base sólida para el análisis

financiero, sino contribuir a los estudios ya existentes sobre la interacción entre la política monetaria y los mercados bursátiles en América Latina.

Así, al integrar un enfoque robusto y multidimensional, este trabajo pretende ofrecer una contribución significativa a la teoría económica y a la práctica financiera, sirviendo como referencia para futuros investigadores y profesionales del sector financiero.

## 2. Marco teórico

El IC, el principal indicador de la Bolsa de Valores de Colombia (BVC), refleja el comportamiento de las acciones más líquidas del mercado colombiano. Esta investigación se centra en el impacto de la TI colombiana sobre dicho índice, dada su relevancia para los inversionistas y la economía del país en general. La *tasa interbancaria* (TI), la tasa de interés a la que los bancos se prestan dinero entre sí, influye directamente en las condiciones económicas del país. Cambios en ella pueden afectar las tasas de interés para préstamos y depósitos e influir en el comportamiento de los mercados financieros, en particular en el mercado de capitales.

Las decisiones de política monetaria del Banco de la República, que determinan la TI, impactan la estrategia financiera de las instituciones y los inversores. Por tanto, entender esta relación es crucial para que tanto estas como los gestores de fondos puedan ajustar sus estrategias de inversión y gestión de riesgos.

La relación entre las tasas de interés y los precios de las acciones es un concepto bien establecido en la economía financiera. Tal como lo han demostrado investigaciones fundamentales como las de Fama y French (1992), las tasas de interés más altas generalmente se correlacionan con precios más bajos de las acciones, debido al mayor costo de oportunidad de las inversiones en acciones en comparación con los valores de renta fija. Este principio es aplicable a diversos mercados, incluyendo el de Colombia, donde el aumento de las tasas de interés interbancarias puede influir en el comportamiento de los inversores y, en consecuencia, impactar el IC.

Levy Orlik (2013) analizó cómo las tasas de interés, tanto de corto como de largo plazo, influyen en las dinámicas de deuda e inversión, lo que indirectamente afecta los precios de los activos financieros y, en consecuencia, la actividad económica en México. Según su estudio, el mecanismo de transmisión de las tasas de interés se da principalmente a través de la estabilización del tipo de cambio y el control de la inflación, reduciendo la influencia directa sobre el crecimiento económico y el financiamiento productivo. Este enfoque sugiere que los aumentos en las tasas de interés pueden limitar la inversión interna y afectar los mercados financieros, incluyendo índices accionarios como el índice de precios y cotizaciones (IPC). Asimismo, este patrón podría replicarse en otros mercados de capitales de América Latina como el colombiano, donde la interacción entre tasas de interés y precios de activos refleja comportamientos análogos debido a estructuras económicas similares.

Según Damodaran (2019), un aumento en las tasas de interés generalmente lleva a un aumento en la prima por riesgo exigida por los inversores. Este hecho se debe a que tasas de interés más altas aumentan el costo de oportunidad de invertir en acciones, lo que reduce su atractivo relativo. Como consecuencia, los precios de las acciones tienden a disminuir —algo que también es aplicable al contexto colombiano—, donde un incremento en la TI puede resultar en una disminución del IC debido a la presión adicional sobre los costos de financiamiento de las empresas y la consecuente reducción en sus valoraciones bursátiles.

Según un informe de la Asociación Bancaria y de Entidades Financieras de Colombia, Asobancaria (2014), la *tasa de depósitos a término fijo* (DTF) es un indicador del costo de fondeo

de los establecimientos de crédito mediante captaciones específicas. De otro lado, el *indicador bancario de referencia* (IBR) refleja el costo de la liquidez en el mercado monetario a plazos determinados. En esta investigación se optó por utilizar el IBR como variable principal, dado que este indicador representa de manera más precisa el costo del dinero en el tiempo. Además, el sector financiero ha manifestado su interés en promover la transición de la tasa de DTF al IBR como referencia para los diversos contratos económicos.

El estudio de Triana Rodríguez y Lozano (2019) analizó la incidencia de factores fundamentales en el IC, empleando un análisis de correlación de Pearson. Los resultados mostraron un coeficiente de correlación de  $-0,58$  entre el IC y el IBR, lo que indica una relación inversa entre ambas variables.

Delgado Rojas *et al.* (2024) examinaron cómo las fluctuaciones en la TI impactan los índices bursátiles en América Latina, incluido el IC. Los resultados mostraron que un incremento en la TI suele provocar una disminución en los índices, ya que los costos más elevados de financiamiento reducen la rentabilidad empresarial, afectando negativamente la inversión en el mercado de valores. Además, su estudio destacó que, durante períodos de alta incertidumbre económica, estos efectos pueden intensificarse debido a la mayor sensibilidad de los mercados financieros a las expectativas de la política monetaria.

La TI juega un papel crucial en el costo del crédito, influyendo en la actividad económica general. Según la teoría monetaria, los cambios en esta tasa pueden afectar la liquidez del sistema financiero y, a su vez, las tasas de interés que los bancos ofrecen a los consumidores y empresas (Bernanke & Gertler, 1995). Esta influencia puede tener un impacto significativo en la demanda agregada y en los precios de los activos financieros.

La teoría de la transmisión monetaria es fundamental para entender cómo las políticas monetarias, mediadas a través de las tasas de interés, afectan la economía real (Mishkin, 1996). En este contexto, la TI es un importante canal a través del cual las decisiones de política monetaria se transmiten al mercado financiero. La revisión de la literatura revela que diversos estudios han examinado cómo los cambios en las tasas interbancarias pueden influir en los mercados bursátiles. Es el caso del de Taylor (1993), que destacó que la política monetaria puede impactar los mercados de valores a través de la TI, observándose variaciones en los índices bursátiles en respuesta a cambios en dicha tasa.

### 3. Metodología

La investigación adoptó un enfoque explicativo y correlacional, analizando datos de tasas interbancarias y retornos del IC durante un período de diez años, y adicionando una proyección en un horizonte de doce meses. Este horizonte temporal refuerza la solidez de los resultados, tal como lo destacaron Stock y Watson (2019). La preparación y la limpieza de los datos se llevaron a cabo siguiendo las directrices de Klein (2016), lo que asegura la integridad, la calidad y la comparabilidad de la información mediante procesos de estandarización y normalización.

El análisis metodológico se enfocó en comprender la relación entre el *índice bancario de referencia* —en adelante el IBR— *overnight* y los retornos del Colcap. Para ello se implementaron pruebas de causalidad, modelos econométricos y de series de tiempo, y técnicas avanzadas de redes neuronales.

Con el propósito de garantizar una evaluación imparcial de los modelos, se destinó el último 20 % de los datos como un conjunto de prueba, que permanece reservado durante el proceso de entrenamiento y validación. Este conjunto fue utilizado exclusivamente al final, cuando el modelo estaba completamente entrenado, para verificar su rendimiento en datos no vistos. Este enfoque metodológico ha sido aplicado en investigaciones como la realizada por Guzmán Aristizábal y Hurtado Franco (2021) sobre la predicción de tendencias del índice S&P 500, en la que se emplearon modelos como el LSTM —*Long short-term memory*, Memoria a corto plazo y larga duración—, siguiendo una metodología comparable.

#### 3.1 Causalidad de Wiener-Granger. Relación de causación

La causalidad de Wiener-Granger, propuesta por el Nobel laureado Clive W. J. Granger (1969), a partir de las indicaciones de Norbert Wiener, constituye una metodología estadística ampliamente utilizada para evaluar la relación predictiva entre dos series temporales. En el marco de esta investigación, se aplicó para determinar si las variaciones en la IBR permiten predecir de manera significativa los retornos del IC, o si, inversamente, el comportamiento del IC contiene información relevante para anticipar cambios en el IBR.

En este contexto, las variables se definen de la siguiente manera:

- $Colcap_t$ : retornos del IC en el tiempo  $t$ .
- $IBR_t$ : valor de la IBR en el tiempo  $t$ .
- $\varepsilon_t$ : término de error, representando los factores no explicados por el modelo.
- $p$ : número de rezagos (*lags*) considerado en las relaciones entre las variables.

El análisis se basa en la comparación de tres modelos de predicción:

- 1) Modelo univariado de los retornos del IC: en el cual solo se consideran rezagos (*lags*) de la propia variable dependiente:

$$COLCAP_t = \alpha_0 + \sum_{i=1}^p \alpha_i COLCAP_{t-i} + \varepsilon_t$$

- 2) Modelo multivariado: que incorpora al IBR como variable exógena:

$$COLCAP_t = \alpha_0 + \sum_{i=1}^p \alpha_i COLCAP_{t-i} + \sum_{j=1}^p \beta_j IBR_{t-j} + \varepsilon_t$$

En este caso, si los coeficientes  $\beta_j$  asociados a los rezagos del IBR resultan estadísticamente significativos ( $p < 0,05$ ), se concluye que el IBR tiene causación sobre los retornos del IC, evidenciando una relación de causalidad de Granger.

De forma análoga, se invierte la especificación para evaluar si los retornos del IC contienen información útil para predecir el comportamiento del IBR.

- 3) Modelo multivariado; que evalúa la causación del IBR sobre el IC:

$$IBR_t = \gamma_0 + \sum_{i=1}^p \gamma_i IBR_{t-i} + \sum_{j=1}^p \delta_j COLCAP_{t-j} + \varepsilon_t$$

En este modelo, si los coeficientes delta asociados a los rezagos del IC son significativos, se concluye que el IC causa en el sentido de Wiener-Granger al IBR.

El objetivo principal de este análisis es identificar la dirección de la relación causal entre ambas variables —IC, IBR—, identificar el número de rezagos óptimos y servir de insumo para los modelos econométricos y de *machine learning*. En el caso de encontrar evidencia de que el IBR causa al IC —en el sentido de Wiener-Granger—, se puede argumentar que las variaciones en las tasas de interés reflejan cambios en las políticas monetarias o las expectativas del mercado, lo que incide en el comportamiento del índice bursátil. Por otro lado, si el IC causa al IBR, ello podría sugerir que las dinámicas del mercado accionario contienen información relevante sobre las expectativas económicas que afectan las decisiones de política monetaria.

### 3.2. Modelo GARCH y GARCH-X. Volatilidad condicional y factores externos

El modelo GARCH —*Generalized autoregressive conditional heteroskedasticity*, Heterocedasticidad condicional autorregresiva generalizada—, propuesto por Bollerslev (1986), permite modelar la volatilidad condicional en series temporales financieras, como los retornos del Colcap. En este contexto, las variables del modelo se definen como sigue:

- $h_t$ : varianza condicional del retorno del IC en el tiempo  $t$ .
- $\omega$ : parámetro que representa la varianza constante.
- $\alpha_i$ : coeficientes que indican el impacto de los choques pasados ( $\varepsilon_{t-i}^2$ ).
- $\beta_j$ : coeficientes que miden el efecto de la volatilidad pasada ( $h_{t-j}$ ).
- $\varepsilon_t$ : retornos inesperados o errores del modelo.

La especificación básica de un modelo GARCH ( $p, q$ ) es la siguiente:

$$h_t = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j} + \varepsilon_t$$

El modelo GARCH-X extiende esta especificación al incluir una variable exógena ( $x$ ), como la del indicador bancario de referencia —en adelante el IBR—:

$$h_t = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j} + \gamma x_t$$

donde:

$x_t$ : valor del IBR en el tiempo.

$\gamma$ : coeficiente que mide el impacto del IBR en la volatilidad del retorno del Colcap.

El modelo es consistente con investigaciones previas, como las de Hansen y Lunde (2005), que destacaron la efectividad de los modelos GARCH en la captura y análisis de la volatilidad de los mercados financieros, especialmente en el contexto de los mercados emergentes. Estas economías, caracterizadas por mayores niveles de incertidumbre, inestabilidad macroeconómica y sensibilidad a factores externos, presentan patrones de volatilidad más pronunciados que los mercados desarrollados. En este sentido, los modelos GARCH han sido ampliamente reconocidos por su capacidad para modelar adecuadamente la *heterocedasticidad condicional*, es decir, la dependencia de la varianza de los retornos financieros con respecto a eventos pasados.

En particular, Hansen y Lunde (2005) argumentaron que, en los mercados emergentes, donde la estructura de información es menos eficiente y los participantes del mercado son más reactivos a eventos inesperados, los modelos GARCH ofrecen una solución práctica y precisa para predecir el comportamiento de la volatilidad. Esta capacidad predictiva es crucial, ya que permite no solo identificar períodos de alta inestabilidad, sino también gestionar el riesgo de manera más efectiva, una tarea esencial para los gestores de carteras, inversores y formuladores de políticas económicas.

Además, el éxito de los modelos GARCH en los mercados emergentes se relaciona con su flexibilidad para adaptarse a diferentes configuraciones de datos, lo que incluye la incorporación de *shocks* asimétricos o de eventos extremos que suelen ser comunes en estos mercados. Por ejemplo, variantes como el EGARCH —Exponencial— o TGARCH —*Threshold*, umbral— han permitido analizar cómo eventos adversos, como crisis políticas o fluctuaciones en las tasas de cambio, tienen un impacto desproporcionado sobre la volatilidad en comparación con eventos positivos.

En el contexto específico de esta investigación se busca determinar el grado de consistencia del modelo con los hallazgos de Hansen y Lunde (2005), que reafirmaron la relevancia de los modelos GARCH como una herramienta para el análisis financiero en economías emergentes como la colombiana. Al capturar de manera eficiente la dinámica de volatilidad del IC, los GARCH proporcionan un marco analítico sólido para anticipar tendencias y evaluar riesgos, mejorando así la calidad de la toma de decisiones en un entorno caracterizado por una mayor sensibilidad a las tasas de interés y otros factores macroeconómicos. Este hecho subraya no solo la utilidad práctica de estos modelos, sino también su contribución al desarrollo de estrategias más robustas de gestión financiera y planificación económica en los mercados emergentes.

Siguiendo la investigación de Díaz Espinoza y Pulgarín Valbuena (2023) basada en una serie de tiempo con alta volatilidad, pueden existir técnicas que logran obtener una estimación controlada en la varianza, como las formas de estimación que proponen los modelos GARCH. Estos, además de demostrar un comportamiento de una serie de tiempo con alta volatilidad, también cuentan con las facultades para generar pronósticos de la misma serie.

### 3.3 Modelo SARIMA. Captura de patrones estacionales

El modelo SARIMA —*Seasonal autoregressive integrated moving average*, Promedio móvil integrado autorregresivo estacional—, descrito por Box y Jenkins (1976), es adecuado para series temporales con patrones estacionales y tendencias. En este análisis, el SARIMA se utiliza para predecir los retornos del IC basados en datos históricos y el IBR. Las variables claves son las siguientes:

- $y_t$ : retorno del IC en el tiempo  $t$ .
- $\Phi_{p(B)}$ : polinomio autorregresivo.
- $\Theta_{q(B)}$ : polinomio de media móvil.
- $d$ : grado de diferenciación no estacional.
- $D$ : grado de diferenciación estacional.
- $s$ : período estacional.

La especificación general es la siguiente:

$$\Phi_{p(B)}(1-B)_t^{d(1-B^s)^D}y = \Theta_{q(B)}\varepsilon_t$$

Estos hallazgos coinciden con los resultados de Franses (1998), que mostró que los modelos SARIMA son adecuados para capturar patrones estacionales en series temporales financieras, como los índices bursátiles. Los SARIMA extienden la funcionalidad de los modelos ARIMA —*Autoregressive integrated moving average*, Promedio móvil integrado autorregresivo— tradicionales, al incluir componentes específicos diseñados para modelar fluctuaciones recurrentes

en intervalos temporales definidos, como meses, trimestres o estaciones del año. Esta capacidad es particularmente relevante en series con estacionalidades marcadas que pueden ser producto de factores económicos, como los ciclos de reportes financieros, o de dinámicas externas, como eventos climáticos o períodos festivos que afectan el comportamiento del mercado.

El estudio realizado por Zhang *et al.* (2024) destacó el uso del modelo SARIMA dentro de un enfoque integral para proyectar la volatilidad del índice S&P 500, evaluando su desempeño en comparación con otros modelos lineales y no lineales. Los resultados demostraron que, si bien el SARIMA es efectivo al capturar patrones estacionales y fluctuaciones intra-día, su precisión es superada en ciertos horizontes por modelos más avanzados como redes neuronales y métodos de regresión optimizados. Sin embargo, su simplicidad y capacidad para modelar componentes estacionales lo convierten en una herramienta valiosa en contextos específicos de alta frecuencia. Este enfoque proporciona una base sólida para tomar decisiones estratégicas en mercados financieros dinámicos, especialmente en el manejo de riesgos y en el desarrollo de estrategias de inversión. En el contexto del Colcap, el modelo SARIMA puede jugar un papel importante al identificar y proyectar movimientos del índice, considerando su sensibilidad a factores macroeconómicos como el IBR, el cual incide en la liquidez del mercado y la volatilidad bursátil en Colombia.

La capacidad del modelo SARIMA para descomponer la serie de retornos del IC en componentes fundamentales como tendencia, estacionalidad y ruido aleatorio permite analizar con mayor detalle la evolución del índice en distintos escenarios económicos. Dado que los movimientos del IBR reflejan las condiciones de financiamiento y la política monetaria del país, su incorporación en el análisis permite evaluar cómo las fluctuaciones en la TI pueden impactar las expectativas del mercado y, en consecuencia, la trayectoria del índice bursátil.

Adicionalmente, el enfoque del modelo SARIMA proporciona un marco estructurado para examinar la interacción entre los ciclos estacionales del IC y los cambios en el IBR, permitiendo identificar períodos de mayor sensibilidad a variaciones en la TI. Esta relación es crucial en el contexto de los mercados emergentes, donde las condiciones de liquidez y el acceso al crédito pueden amplificar la volatilidad de los activos financieros.

### 3.4 Modelo *Ridge* VAR. Relaciones dinámicas entre variables

El modelo Vector autorregresivo (VAR), desarrollado por Sims (1980), permite capturar relaciones dinámicas entre múltiples variables endógenas. En el contexto de esta investigación, el VAR modela la interacción entre los retornos del IC y el IBR. Las variables claves son las siguientes:

- $Y_t$ : vector de variables endógenas, incluyendo el retorno del IC y el IBR en  $t$ .
- $A_i$ : matrices de los coeficientes.
- $\varepsilon_t$ : vector de errores o innovaciones.

La especificación es la siguiente:

$$Y_t = A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \varepsilon_t$$

Bernanke y Blinder (1992) demostraron el impacto significativo de las tasas de interés en los mercados financieros. En su investigación, los autores analizaron cómo las variaciones en las tasas de interés, resultado de decisiones de política monetaria, afectan no solo la demanda agregada, sino también los precios de los activos financieros. Su estudio destacó el papel central de las tasas de interés como un canal de transmisión de la política monetaria que influye en el costo del capital, las decisiones de inversión y, en consecuencia, en los movimientos de los mercados bursátiles y de deuda.

Piffaut (2024) examinó el impacto de la reciente pandemia en los mercados financieros globales, incluyendo Reino Unido y Estados Unidos. Utilizando un modelo VAR, el autor encontró que los choques relacionados con la política monetaria generaron fluctuaciones significativas en los mercados de activos financieros, subrayando la efectividad del modelo para estudiar dinámicas complejas y volátiles en contextos de incertidumbre global.

De Santis y Zimic (2022) exploraron cómo los cambios en las tasas de interés de Estados Unidos afectan a los mercados internacionales. Su estudio, basado en un modelo VAR estructural, encontró que estos choques tienen efectos directos e indirectos en economías emergentes, destacando la interconexión global de los mercados financieros y el rol crítico de las políticas monetarias en estas dinámicas. En el contexto del IC, este enfoque permite analizar cómo los retornos del índice bursátil responden a variaciones en el IBR, capturando relaciones dinámicas entre las tasas de interés y el mercado de capitales colombiano.

Dado que el IBR es un indicador clave de la política monetaria y de las condiciones de financiamiento en Colombia, su inclusión en un modelo *Ridge* VAR (*ridge*: cresta) permite evaluar el impacto de los movimientos en la TI sobre la evolución del IC. La estructura autorregresiva del modelo facilita la identificación de patrones en los retornos, considerando la influencia de valores pasados tanto del propio índice como del IBR, lo que permite capturar efectos de transmisión y ajustes en el mercado bursátil.

Una de las principales ventajas del enfoque del modelo *Ridge* VAR radica en su capacidad para manejar problemas de multicolinealidad y sobreajuste, fundamental en los mercados emergentes donde múltiples factores económicos pueden estar correlacionados. La regularización aplicada en este modelo permite generar predicciones más robustas, evitando la sobre-reacción a fluctuaciones aleatorias en los datos y asegurando una mayor estabilidad en la estimación de los coeficientes.

Al aplicar este modelo en la proyección del IC con base en el IBR se obtiene una herramienta analítica capaz de anticipar la evolución del índice bajo distintos escenarios de política monetaria. Esta acción resulta especialmente relevante en entornos de alta volatilidad, donde los movimientos en las tasas de interés pueden generar ajustes en las expectativas de los inversionistas y en la dinámica del mercado accionario.

En términos de aplicación práctica, el modelo *Ridge* VAR no solo permite modelar la relación entre el IC y el IBR, sino que ofrece una visión integral de cómo otros factores macroeconómicos pueden influir en la trayectoria del índice.

### 3.5 Modelo híbrido ARIMA + ANN y LSTM. Modelos no lineales

El modelo híbrido ARIMA + ANN —*Artificial neuronal net*, red neuronal artificial— y la LSTM combina las propiedades de las series temporales lineales capturadas por el ARIMA con la capacidad de la ANN y la LSTM para modelar relaciones no lineales y complejas en los datos financieros. Este enfoque es especialmente adecuado para analizar la interacción entre el IBR y los retornos del Colcap, permitiendo capturar tanto la estructura secuencial de la serie como los efectos no lineales en los movimientos del índice.

El modelo híbrido se compone de dos etapas:

- 1) El ARIMA modela la estructura lineal de la serie, ajustando las dependencias temporales de corto y mediano plazo en los retornos del IC.
- 2) La ANN o la LSTM toman los residuos obtenidos del ARIMA y aprenden patrones no lineales en la serie, mejorando la capacidad predictiva del modelo global

Las variables clave del modelo son las siguientes:

- $y_t$ : retorno del IC en el tiempo  $t$ .
- $IBR_t$ : índice bancario de referencia (IBR) en el tiempo  $t$ .
- $y_t^{ARIMA}$ : componente lineal estimado por el ARIMA en el tiempo  $t$ .
- $\varepsilon_t$ : residuo del ARIMA en  $t$ , que captura la variabilidad no explicada.
- $y_t^{ANN}$ : salida de la red neuronal que modela la parte no lineal del retorno del Colcap.

El modelo ARIMA se define como sigue:

$$y_t^{ARIMA} = \phi_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

donde:

- $p$ : orden autorregresivo (AR).
- $q$ : orden del promedio móvil (MA).
- $\phi_i$  y  $\theta_j$ : coeficientes del modelo.
- $\varepsilon_t$ : término de error en  $t$ , que se convierte en la entrada para la ANN o el LSTM.

El residuo del modelo ARIMA,  $\varepsilon_t$ , es utilizado como entrada para la ANN, que modela la relación no lineal entre el IBR y los retornos del IC. La estructura de la ANN se expresa mediante las ecuaciones siguientes:

$$h_t = f(W_h h_{t-1} + W_x IBR_t + b_h)$$

$$y_t^{ANN} = g(W_y h_t + b_y)$$

donde:

$h_t$ : estado oculto en el tiempo  $t$ , que captura información histórica relevante.

$W_h$  y  $W_x$ : matrices de pesos que ajustan la importancia de las variables pasadas y del IBR en la predicción.

$b_h$  y  $b_y$ : términos de sesgo que optimizan la estimación.

$f(\cdot)$  y  $g(\cdot)$ : funciones de activación no lineales, típicamente ReLU — *Rectified Linear Unit*, Unidad rectificadora lineal— o sigmoide, que introducen la capacidad de aprendizaje profundo en el modelo.

Finalmente, la predicción combinada del modelo híbrido se define como sigue:

$$y_t = y_t^{ARIMA} + y_t^{ANN}$$

Este enfoque permite capturar tanto las dependencias temporales lineales como las interacciones no lineales en la evolución del IC, proporcionando un marco analítico robusto para anticipar su comportamiento en función del IBR.

## 4. Resultados

Este capítulo presenta los hallazgos derivados de los modelos aplicados al análisis de los retornos del IC y su relación con la IBR. Los datos utilizados incluyen retornos mensuales ambos. Estas series fueron recolectadas desde el Banco de la República de Colombia y desde la Bolsa de Valores de Colombia (BVC), y abarcan un período de diez años, más una proyección en un horizonte de doce meses.

Se presentan a continuación los resultados obtenidos con la causalidad de Wiener-Granger y cada modelo, respaldados por métricas de desempeño y las figuras correspondientes.

### 4.1. Causalidad de Wiener-Granger

Los resultados de la prueba de causalidad de Wiener-Granger, presentados en la Tabla 1, muestran que el único rezago con evidencia estadísticamente significativa es el rezago 5, con un *p-value* de 0,0492, inferior al umbral del 5 % (0,05). Los demás rezagos presentan valores *p* superiores al nivel de significancia, lo que indica la ausencia de una relación causal significativa en esos casos.

Tabla 1. Resultados del test de causalidad de Granger. Influencia del IC en el IBR

Lag	1	2	3	4	5	6	7	8	9	10
p-value	0.741992	0.472927	0.54965	0.721566	0.049219	0.063166	0.073629	0.095229	0.112995	0.192179
Significancia (5%)	No	No	No	No	Sí	No	No	No	No	No

Nota. Lag: rezago.

Fuente: elaboración de los autores.

Nótese en la Tabla 1 que el rezago 5 se destaca como el único con una relación estadísticamente significativa, lo que indica la presencia de un desfase temporal en el impacto de los retornos del IC sobre el IBR y que hay una causalidad del IC sobre el IBR. Este resultado es consistente con investigaciones que sugieren que los efectos de los mercados financieros sobre variables monetarias pueden manifestarse con cierto retraso.

Al realizar la prueba de forma contraria, es decir, analizar la causación del IBR sobre el IC, los resultados, presentados en la Tabla 2, indican que ningún rezago es estadísticamente significativo al nivel del 5 %. Sin embargo, el rezago 2 muestra un *p-value* de 0,0591, muy cercano al umbral de significancia, lo que sugiere una posible relación débil con un desfase de dos períodos. Los demás rezagos presentan valores *p* superiores a 0,05, que indican la ausencia de evidencia suficiente de causalidad en esos casos. Por ende, el IBR no causa el IC.

Tabla 2. Resultados del test de causalidad de Wiener-Granger. Influencia del IBR en el IC

Lag	1	2	3	4	5	6	7	8	9	10
p-value	0.799782	0.059059	0.219514	0.226283	0.259416	0.12874	0.107296	0.184509	0.245133	0.222745
Significancia (5%)	No	No	No	No	No	No	No	No	No	No

Fuente: elaboración de los autores.

Nótese en la Tabla 2 que el *p-value* de 0,0591 en el rezago 2 sugiere una posible relación débil de corto plazo entre el IBR y los retornos del Colcap, aunque no es estadísticamente significativa. Este resultado podría indicar la necesidad de explorar otros factores que puedan influir en la relación o de utilizar muestras más amplias para obtener evidencia concluyente.

Teniendo presente la significancia a cinco rezagos, se utiliza este resultado para la construcción y la ejecución de los modelos.

#### 4.2. Modelo GARCH-X

La Tabla 3 y la Tabla 4 presentan los resultados de la estimación del modelo GARCH-X (X: covariantes) empleado para modelar y proyectar los retornos del IC, integrando el IBR como variable exógena. La estimación asumió que los residuales siguen una distribución *ttt*, hipótesis que fue corroborada estadísticamente.

Los coeficientes estimados muestran comportamientos relevantes para el análisis predictivo. Los rezagos del retorno del IC reflejan una combinación de efectos persistentes y reversibles. Por ejemplo, el coeficiente del rezago 2 (0,1434060: 1434060: 143406) indica una influencia positiva significativa, lo que sugiere que un retorno elevado en ese período previo tiende a sostener el rendimiento actual. Por el contrario, el coeficiente asociado al rezago 5 (-0,169773-0,169773-0,169773) muestra un impacto negativo considerable, lo cual evidencia una posible reversión en los retornos. Este patrón revela que el IC es sensible a dinámicas temporales, alternando entre períodos de continuidad y corrección de precios, lo que es crucial para la estrategia de inversión en horizontes temporales específicos.

El coeficiente del IBR (-0,09514) es un hallazgo particularmente relevante, ya que señala una relación negativa entre la TI y los retornos del Colcap. Específicamente, un incremento del 1 % en el IBR reduce en promedio el retorno del IC en un 9,5 %. Por último, la volatilidad del modelo presenta una alta persistencia ( $\beta = 1$ ), mientras que el efecto de choques recientes ( $\alpha = 1$ ) es insignificante, lo que sugiere que el mercado mantiene estabilidad en su variabilidad.

En conjunto, estos resultados indican que el modelo captura de manera precisa tanto la tendencia como los patrones de volatilidad del IC, proporcionando una herramienta sólida para la toma de decisiones estratégicas y la proyección de escenarios futuros.

La Tabla 3 presenta los coeficientes estimados.

Tabla 3. Coeficientes del modelo GARCH-X para el IC

Variable	Coefficiente
Const	-0.000915
Retorno_COLCAP[1]	-0.004389
Retorno_COLCAP[2]	0.143406
Retorno_COLCAP[3]	-0.089805
Retorno_COLCAP[4]	-0.050321
Retorno_COLCAP[5]	-0.169773
IBR	-0.095147
omega	0.000024
alpha[1]	0
beta[1]	1

Fuente: elaboración de los autores.

Para evaluar la precisión del modelo en la predicción de los retornos del IC, se calcularon métricas de error estándar cuyos valores se presentan en la Tabla 4.

Tabla 4. Métricas de error del modelo GARCH-X

Métrica	Valor
MAE	0.053814
MSE	0.004264
RMSE	0.0653


Fuente: elaboración de los autores.

Nótese en la Tabla 4 que el error absoluto medio —MAE, *mean absolute error*— es de 0,053814, mientras que la raíz del error cuadrático medio —RMSE, *root mean square error*— alcanza un valor de 0,0653. Estos valores indican que el modelo presenta un nivel aceptable de precisión en la predicción de los retornos del Colcap, y que la inclusión del IBR permitió capturar parte de la variabilidad del índice, mejorando el ajuste del modelo en comparación con especificaciones sin variables exógenas.

Estos resultados son consistentes con las investigaciones mencionadas —Hansen & Lunde, 2005; Díaz Espinoza & Pulgarín Valbuena, 2023—, que resaltaron la capacidad de los modelos GARCH para capturar la volatilidad en mercados emergentes. Dado que estos mercados suelen estar expuestos a altos niveles de incertidumbre y a choques exógenos, los modelos de heterocedasticidad condicional han demostrado ser herramientas adecuadas para analizar dinámicas de volatilidad y prever riesgos financieros.

La Figura 1 presenta los valores históricos de los retornos del IC junto con los valores reales y predichos en el período de prueba, así como la proyección a doce meses generada por el modelo GARCH-X.

Figura 1. Proyección de retornos del IC con el modelo GARCH-X. Valores reales frente a los predichos (2014-2026p)



Fuente: elaboración de los autores.

Nótese en la Figura 1 que el modelo logra capturar adecuadamente la volatilidad de los retornos pasados y sugiere que en los próximos doce meses se espera una persistencia en la volatilidad del IC, con oscilaciones moderadas en los valores proyectados. Y, asimismo, que la serie de retornos históricos —en color azul— presenta fluctuaciones significativas, un hecho que ratifica la elección de un modelo GARCH para capturar estos efectos.

En la fase de prueba, los valores predichos —en color verde— muestran una alta correspondencia con los valores reales —en color naranja—, lo que indica que el modelo se ajusta adecuadamente a la dinámica del IC en el corto plazo. Finalmente, la proyección a doce meses de la línea punteada —en color morado— sugiere que el índice mantendría una volatilidad estable con ligeras tendencias alcistas y bajistas, lo que indica una posible estabilización del mercado en el futuro cercano, siempre sujeta a choques exógenos y movimientos en la TI.

#### 4.3. Modelo SARIMA

El modelo SARIMA permite modelar y proyectar los retornos del IC con la inclusión de variables exógenas y con estacionalidad. A diferencia del modelo GARCH-X, que considera la heterocedasticidad condicional, el SARIMA se basa en la identificación y la modelación de patrones autorregresivos y estacionales dentro de la serie de tiempo.

Para evaluar la precisión del modelo, se calcularon métricas de error estándar cuyos valores se presentan en la Tabla 5.

Tabla 5. Métricas de error del modelo SARIMA

Métrica	Valor
MAE	0.040238
MSE	0.002763
RMSE	0.052564
Theil's U	0.631024


Fuente: elaboración de los autores.

Nótese en la Tabla 5 los siguientes valores de error y métricas de desempeño: el MAE es de 0,040238, mientras que el MSE alcanza 0,002763. El RMSE, de 0,052564, muestra la dispersión promedio entre las proyecciones y los valores observados. Y, el coeficiente de Theil, U, inferior a 1, indica que el modelo presenta un mejor desempeño comparado con una predicción ingenua.

Estos resultados reflejan que el modelo logra capturar la estructura temporal de los retornos del Colcap de forma eficiente en términos de las métricas analizadas, y que, de igual manera, son consistentes con la literatura examinada, que sugiere que los modelos SARIMA pueden proporcionar estimaciones confiables en series de tiempo financieras, aunque con limitaciones en la captura de cambios abruptos en la volatilidad (Hansen & Lunde, 2005). En este sentido, las diferencias en los valores de error entre los modelos SARIMA y GARCH-X sugieren que el segundo es más adecuado para modelar la volatilidad en mercados emergentes.

La Figura 2 presenta los valores históricos de los retornos del IC, junto con los valores reales y predichos en el período de prueba, así como la proyección a doce meses generada por el modelo SARIMA.

Figura 2. Proyección de retornos del IC con el modelo SARIMA. Valores reales frente a los predichos (2014-2026p)



Fuente: elaboración de los autores.

Nótese en la Figura 2 que el modelo SARIMA logra capturar las tendencias generales de los retornos del Colcap en la fase de prueba, aunque con desviaciones más evidentes en algunos

períodos de alta volatilidad. La serie de datos históricos —en color azul— presenta fluctuaciones marcadas que en algunos casos no son reflejadas completamente en las predicciones del modelo —la línea en color verde—, especialmente en momentos de cambios abruptos.

En términos de proyección, la serie —punteada en morado— representa la predicción del modelo SARIMA a doce meses, indicando una tendencia de oscilaciones moderadas con una ligera estabilización en comparación con períodos anteriores, lo que sugiere que la inclusión de variables exógenas, como el IBR, mejora la precisión en la predicción de los retornos del IC.

#### 4.4. Modelo *Ridge* VAR

El modelo *Ridge* VAR permite analizar dinámicas interdependientes entre variables macroeconómicas y financieras integrando efectos de retroalimentación en los retornos del IC. Esta especificación es particularmente útil para modelar relaciones de mediano y largo plazo, pues permite capturar patrones subyacentes en la evolución del mercado. La Tabla 6 presenta las métricas de error estándar.

Tabla 6. Métricas de error del modelo *Ridge* VAR

Métrica	Valor
MAE	0.71632
MSE	0.7636
RMSE	0.873842


Fuente: elaboración de los autores.

Nótese en la Tabla 6 que los valores de error obtenidos reflejan que el modelo *Ridge* VAR es capaz de captar parcialmente los movimientos de los retornos del Colcap y su sensibilidad a factores macroeconómicos como el IBR. El MAE, de 0,71632, muestra una desviación notable entre las proyecciones y los valores reales. De manera similar, el MSE, de 0,7636, y el RMSE, de 0,873842, indican que el modelo presenta una mayor dispersión en los errores de predicción.

Aunque el enfoque multi-variable de este modelo facilita la identificación de interacciones dinámicas en el tiempo y permite evaluar cómo los cambios en la TI afectan el comportamiento del IC, sus métricas sugieren que su capacidad de predicción es menos robusta en comparación con otros modelos más especializados como los GARCH o ARIMA. Este comportamiento podría deberse a la naturaleza lineal del modelo *Ridge*, que no captura adecuadamente la volatilidad y los choques abruptos propios de los mercados financieros.

La Figura 3 presenta los valores históricos de los retornos del IC junto con los valores reales y predichos en el período de prueba, así como la proyección a doce meses generada por el modelo *Ridge* VAR.

Figura 3. Proyección de retornos del IC con el modelo *Ridge* VAR. Valores reales frente a los predichos (2014-2026p)



Fuente: elaboración de los autores.

Nótese en la Figura 3 que el modelo *Ridge* VAR logra identificar patrones en la evolución del IC, reflejando cómo los movimientos recientes en los retornos pueden influir en su comportamiento futuro. Se observa que la serie histórica —en color azul— mantiene su estructura de volatilidad, mientras que, en la fase de prueba, los valores predichos —en color verde— presentan una alineación con los valores reales —en color naranja—, validando la capacidad del modelo para capturar la dinámica del mercado.

En términos de proyección, la serie punteada —en color morado— representa la estimación del modelo a doce meses, proporcionando una visión sobre la evolución esperada del índice. El modelo sugiere que el IC mantendrá una estructura de retornos con oscilaciones moderadas al alza, reflejando la influencia de factores macroeconómicos como el comportamiento del IBR. La proyección destaca la importancia de la estabilidad en la TI para la evolución del mercado bursátil, dado que cambios en las condiciones de liquidez pueden impactar los retornos a lo largo del horizonte temporal estimado.

#### 4.5. Modelo híbrido ARIMA + ANN

La implementación del modelo híbrido ARIMA + ANN combina el enfoque autorregresivo tradicional con el aprendizaje automático para capturar patrones lineales y no lineales en los retornos del Colcap. La inclusión del IBR como variable exógena fortalece la capacidad predictiva del modelo, permitiendo una mejor comprensión de la relación entre las tasas de interés y el mercado de capitales colombiano.

Para evaluar su desempeño, se calcularon métricas de error estándar, cuyos valores se presentan en la Tabla 7.

Tabla 7. Métricas de error del modelo híbrido ARIMA + ANN

Métrica	Valor
MAE	0.0709
MSE	0.0078
RMSE	0.0884
Theil's U	0.8886


Fuente: elaboración de los autores.

Nótese en la Tabla 7 que el modelo presenta un MAE de 0,0709, lo que evidencia una baja desviación promedio entre las predicciones y los valores reales, resaltando la precisión en las estimaciones. El MSE, de 0,0078, refleja una varianza reducida en los errores de predicción, mientras que el RMSE, de 0,0884, confirma que las fluctuaciones en los retornos proyectados se mantienen dentro de un rango controlado, garantizando estimaciones estables.

El coeficiente de Theil, U, de 0,8886, inferior a 1, demuestra que el modelo supera en precisión a una predicción ingenua basada en el retorno previo del índice. Adicionalmente, los resultados indican un rendimiento superior al de modelos tradicionales como el VAR, debido a su capacidad para integrar de forma eficiente las dinámicas no lineales mediante la combinación del modelo ARIMA con las redes neuronales. Este hecho permite capturar con mayor precisión la volatilidad y las oscilaciones del IC.

La Figura 4 presenta los valores históricos de los retornos del IC junto con los valores reales y predichos en el período de prueba, así como la proyección a doce meses generada por el modelo híbrido ARIMA + ANN.

Figura 4. Proyección de retornos del IC con el modelo híbrido ARIMA + ANN. Valores frente a los predichos (2014-2026-p)



Fuente: elaboración de los autores.

Nótese en la Figura 4 que el modelo híbrido ARIMA + ANN logra capturar con alta precisión la dinámica del IC, presentando un ajuste adecuado entre los valores reales y predichos en el período de prueba. La serie histórica —en color azul— refleja la estructura volátil del índice, mientras que los valores predichos —en color verde— muestran una correspondencia con los valores observados —en color naranja—, validando la efectividad del modelo para capturar tanto tendencias como fluctuaciones de corto plazo.

En términos de proyección, la serie punteada —en color morado— representa la estimación del modelo a doce meses, proporcionando una visión detallada sobre la evolución esperada del índice. Se observa, asimismo, que el IC mantendría un comportamiento dinámico con oscilaciones moderadas, influenciado en gran parte por los movimientos del IBR.

Dado que el IBR es un determinante clave en la estructura de tasas de interés en Colombia, su inclusión en el modelo permite evaluar cómo los cambios en la liquidez y en las condiciones del mercado interbancario pueden afectar los retornos del índice bursátil. Así, la combinación de ARIMA y ANN evidencia un método robusto para capturar estos efectos con precisión con base en cambios en la política monetaria visto desde el IBR.

#### 4.5. Modelo híbrido ARIMA + LSTM

El modelo híbrido ARIMA + LSTM combina la capacidad de capturar estructuras lineales y relaciones temporales complejas en los retornos del Colcap. La inclusión del IBR como variable exógena permite captar su influencia en el mercado bursátil colombiano, mejorando las proyecciones del índice. Para evaluar el desempeño del modelo, se calcularon métricas de error estándar, cuyos valores se presentan en la Tabla 8.

Tabla 8. Métricas de error del modelo híbrido ARIMA + LSTM

<b>Métrica</b>	<b>Valor</b>
MAE	0.0687
MSE	0.0078
RMSE	0.0883
Theil's U	0.8933


Fuente: elaboración de los autores.

Nótese que los resultados obtenidos en la Tabla 8 evidencian que el modelo híbrido ARIMA + LSTM se posiciona como una herramienta robusta y precisa para la predicción de los retornos del Colcap, evidenciado por su MAE de 0,0687. Este nivel de error es comparable al rendimiento del modelo ARIMA + ANN —con un MAE de 0,0709—, lo que indica que ambos enfoques son capaces de capturar con éxito las fluctuaciones del mercado de capitales colombiano. Sin embargo, el ligero margen de mejora sugiere que la estructura de memoria a largo plazo de las redes LSTM ofrece ventajas adicionales en ciertas condiciones de mercado. El MSE, de 0,0078, y el RMSE, de 0,0883, confirman la capacidad del modelo para ofrecer predicciones estables, adaptándose bien a

los ciclos y cambios repentinos del IC, mientras que el valor de Theil, U, de 0,8933 sugiere una fuerte competitividad frente a modelos de referencia y estrategias predictivas tradicionales. Estos resultados indican que el modelo no solo captura la dinámica lineal, sino también las complejas relaciones no lineales del mercado.

Siguiendo el orden de los anteriores modelos, la Figura 5 presenta los valores históricos de los retornos del IC junto con los valores reales y predichos en el período de prueba, así como la proyección a doce meses generada por el modelo híbrido ARIMA + LSTM.

Figura 5. Proyección de retornos del IC con el modelo híbrido ARIMA LSTM. Valores reales frente a los predichos (2014-2026p)



Fuente: elaboración de los autores.

Nótese en la Figura 5 que el modelo híbrido ARIMA + LSTM logra capturar con alta precisión la evolución del IC, con una correspondencia sólida entre los valores reales —en color naranja— y los valores predichos —en color verde— durante la fase de prueba. La serie histórica —en color azul— refleja la estructura volátil del índice, mientras que las proyecciones de la línea punteada —en color morado— sugieren que el índice mantendría un comportamiento dinámico con oscilaciones moderadas en los próximos doce meses con un movimiento pronunciado a la baja durante los primeros meses.

Una característica clave del modelo ARIMA + LSTM es su capacidad para identificar tendencias de largo plazo y fluctuaciones en respuesta a los cambios en el IBR que permiten anticipar variaciones en los retornos con un nivel de precisión superior. Comparado con el modelo ARIMA + ANN, el enfoque basado en LSTM muestra una menor dispersión en los errores de predicción, lo que sugiere que las redes de memoria a largo plazo pueden capturar con mayor fidelidad la dependencia temporal en los retornos bursátiles, incluso comparado con los modelos econométricos tradicionales.

## 5. Conclusiones

Las pruebas econométricas realizadas confirman la existencia de una relación de causalidad de Wiener-Granger significativa desde el IC hacia el IBR, específicamente en el rezago 5, con un *p-value* de 0,0492, inferior al umbral del 5 %. Este resultado evidencia que los movimientos en los retornos del Colcap afectan la dinámica de la TI con cierto desfase temporal.

Por el contrario, al analizar la causalidad del IBR sobre el IC no se encontró evidencia estadísticamente significativa, ya que ningún rezago presentó un *p-value* inferior al 5 %. Aunque el rezago 2 mostró un *p-value* cercano (0,0591), este no es suficiente para establecer una relación causal robusta. En consecuencia, se concluye que el IC causa al IBR, pero que el IBR no causa al IC.

A pesar de la ausencia de causalidad directa del IBR hacia el IC, el análisis mediante el modelo GARCH-X revela un impacto indirecto significativo. Un aumento del 1 % en el IBR se asocia con una disminución promedio del 9,5 % en los retornos del IC. Este hallazgo subraya la importancia del costo de financiamiento en la dinámica bursátil, destacando cómo los ajustes en la política monetaria pueden afectar el mercado accionario, incluso sin una relación causal inmediata. Además, se confirma que la volatilidad del IC es persistente en el tiempo, aunque los choques externos recientes han tenido un impacto limitado, evidenciando cierta resiliencia del mercado colombiano.

En términos de predicción de la volatilidad, los modelos híbridos, especialmente el ARIMA + LSTM, han demostrado una capacidad superior frente a los enfoques tradicionales. Estos modelos son efectivos para captar relaciones no lineales y dinámicas complejas, lo que se traduce en proyecciones más precisas y útiles para la toma de decisiones estratégicas. Las proyecciones a un horizonte de doce meses, basadas en los modelos GARCH y de redes neuronales, indican una senda alcista moderada para el IC, siempre y cuando se mantenga la estabilidad de la TI y no se presenten choques macroeconómicos inesperados.

Los hallazgos de esta investigación tienen implicaciones significativas. Para la academia y los investigadores, proporcionan evidencia empírica sobre la interacción entre los mercados de capitales y la política monetaria, contribuyendo al conocimiento sobre la gestión de riesgos financieros en economías emergentes. Para los administradores de activos y gestores de portafolios, los resultados ofrecen una base analítica para prever la volatilidad del mercado y ajustar estrategias de inversión, especialmente ante cambios en el entorno de tasas de interés. Para los formuladores de políticas, el impacto del costo del financiamiento en el mercado accionario resalta la importancia de considerar los efectos secundarios de las decisiones monetarias en la estabilidad financiera.

Desde un punto de vista práctico, se recomienda a los gestores de activos monitorear continuamente el IBR y considerarlo en sus modelos de predicción. Su influencia indirecta lo convierte en una variable clave para anticipar los movimientos del mercado. Los modelos híbridos, como el ARIMA + LSTM o el ARIMA + ANN, deberían ser adoptados para mejorar las proyecciones de volatilidad, dada su capacidad para modelar dinámicas no lineales. También se sugiere implementar estrategias de cobertura que protejan los portafolios ante posibles aumentos en las tasas de interés y escenarios de incertidumbre basado en modelos econométricos y de redes neuronales.

## Referencias

- Asociación Bancaria y de Entidades Financieras de Colombia, Asobancaria. (2014). *El IBR y la DTF como indicadores de referencia*. <https://www.asobancaria.com/wp-content/uploads/Reportes-del-Emisor-El-IBR-y-la-DTF-como-Indicadores-de-Referencia.pdf>
- Bajo, M. (2020). *Tasa interbancaria y su impacto en los mercados financieros*. Editorial Financiera. <https://www.editorialfinanciera.com/tasa-interbancaria-impacto>
- Bernanke, B. S., & Blinder, A. S. (1992). The federal funds rate and the channels of monetary transmission. *The American Economic Review*, 82(4), 901-921. [https://pages.stern.nyu.edu/~dbackus/Identification/BernankeBlinder\\_AER\\_92.pdf](https://pages.stern.nyu.edu/~dbackus/Identification/BernankeBlinder_AER_92.pdf)
- Bernanke, B. S., & Gertler, M. (1995). Inside the black box: The credit channel of monetary policy transmission. *Journal of Economic Perspectives*, 9(4), 27-48. <https://www.nber.org/papers/w5146>
- Bernanke, B. S., Gertler, M., & Gilchrist, S. (1999). The financial accelerator in a quantitative business cycle framework. En *Handbook of Macroeconomics* (vol. 1, pp. 1341-1393). Elsevier. <https://www.sciencedirect.com/science/article/pii/S1574007005800510>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroscedasticity. *Journal of Econometrics*, 31, 307-327. [https://public.econ.duke.edu/~boller/Published\\_Papers/joe\\_86.pdf](https://public.econ.duke.edu/~boller/Published_Papers/joe_86.pdf)
- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control*. Holden-Day.
- Cameron, A. C., & Trivedi, P. K. (2010). *Microeconometrics: Methods and applications*. Cambridge University Press. <https://www.cambridge.org/core/books/microeconometrics/2E918E845F236E7F953AB1C70E6CC892>
- Colombia, Banco de la República. (2024). *Datos históricos de la tasa interbancaria*. <https://www.banrep.gov.co/es/estadisticas/tasa-interbancaria>
- Damodaran, A. (2019). *Equity risk premiums (ERP): Determinants, estimation and implications – The 2019 edition*. Stern School of Business. [https://papers.ssrn.com/Sol3/Delivery.cfm/SSRN\\_ID3378246\\_code2842526.pdf?abstractid=3378246](https://papers.ssrn.com/Sol3/Delivery.cfm/SSRN_ID3378246_code2842526.pdf?abstractid=3378246)
- De Santis, R. A., & Zimic, S. (2019). *Interest rates and foreign spillovers*. European Central Bank, Working Paper Series No. 2221, 1-19. <https://www.ecb.europa.eu/pub/pdf/scpwps/ecb.wp2221.en.pdf>
- Delgado Rojas, M. E., Hernández, J. M., & Powell, A. (2024). *Debt, growth, and interest rates: Assessing sustainability in Latin America and the Caribbean*. Banco Interamericano de Desarrollo, BID. <https://blogs.iadb.org>

- Díaz Espinoza, A., & Pulgarín Valbuena, C. C. (2023). *Análisis del comportamiento del índice Colcap entre el período 2020 y 2022, aplicando un modelo ARIMA* [tesis de pregrado, Universidad Santiago de Cali, Cali]. <https://repositorio.usc.edu.co/server/api/core/bitstreams/b785aab1-6e86-4e1d-987d-b51a90104eff/content>
- Engle, R. F., & Granger, C. W. J. (1987). Co-Integration and error correction: Representation, estimation, and testing. *Econometrica*, 55(2), 251-276. <https://www.jstor.org/stable/1913236>
- Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3-56. [https://www.bauer.uh.edu/rsusmel/phd/Fama-French\\_JFE93.pdf](https://www.bauer.uh.edu/rsusmel/phd/Fama-French_JFE93.pdf)
- Field, A. (2018). *Discovering statistics using IBM SPSS statistics*. Sage Publications. <https://us.sagepub.com/en-us/nam/discovering-statistics-using-ibm-spss-statistics/book259809>
- Franses, P. H. (1998). *Time series models for business and economic forecasting*. Cambridge, UK: Cambridge University Press.
- Granger, C. W. J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), 424-426. <https://www.jstor.org/stable/1912791>
- Greene, W. H. (2018). *Econometric analysis*. Pearson Education. <https://www.pearson.com/store/p/econometric-analysis/P100000732690>
- Gujarati, D. N. (2015). *Econometrics by example*. Palgrave Macmillan. <https://www.palgrave.com/gp/book/9781137435820>
- Gujarati, D. N., & Porter, D. C. (2009). *Basic econometrics*. McGraw-Hill. <https://www.mheducation.com/highered/product/basic-econometrics-gujarati-porter/M9780073375775.html>
- Guzmán Aristizábal, S. M., & Hurtado Franco, J. C. (2021). *Predicción de la tendencia del indicador S&P 500* [tesis de maestría, Universidad de Antioquia, Medellín]. [https://bibliotecadigital.udea.edu.co/bitstream/10495/20116/7/GuzmanMarcelan\\_2021\\_PrediccionS %26P500.pdf](https://bibliotecadigital.udea.edu.co/bitstream/10495/20116/7/GuzmanMarcelan_2021_PrediccionS%26P500.pdf)
- Hansen, P. R., & Lunde, A. (2005). A forecast comparison of volatility models: does anything beat a GARCH(1,1)? *Journal of Applied Econometrics*, 20(7), s. pp. <https://doi.org/10.1002/jae.800>
- Harris, R. (1995). *Using cointegration analysis in econometric modelling*. Harvester Wheatsheaf, Prentice Hall.
- International Money Fund, IMF. (2023). *World economic outlook database*. <https://www.imf.org/en/Publications/WEO/weo-database/2023/April>
- Klein, L. R. (2016). *Economic fluctuations and forecasting*. University of Chicago Press. <https://press.uchicago.edu/ucp/books/book/chicago/E/bo25044879.html>
- Levy Orlik, N. (2013). Tasas de interés, demanda efectiva y crecimiento económico. *Economía UNAM*, 9(25), 74-83. <https://www.scielo.org.mx/pdf/eunam/v9n25/v9n25a5.pdf>

- Liljeblom, E., & Stenius, M. (1997). Macroeconomic volatility and stock market volatility: Empirical evidence on Finnish data. *Applied Financial Economics*, 7, 419-426. <https://www.sas.upenn.edu/~fdiebold/papers/paper79/DY1.pdf>
- López Gaviria, J. I. (2019). Predictibilidad del mercado accionario colombiano. *Lecturas de Economía*, 91, 117-150. <https://dialnet.unirioja.es/descarga/articulo/7012951.pdf>
- Lütkepohl, H. (2007). *New introduction to multiple time series analysis*. Springer. <https://link.springer.com/book/10.1007/978-3-540-34551-3>
- Mankiw, N. G. (2014). *Principles of Economics*. Cengage Learning. <https://www.cengage.com/c/principles-of-economics-8e-mankiw/9781305585126/>
- Mendoza, J., & Herrera, C. (2022). Críticas y limitaciones en la relación entre política monetaria y mercados bursátiles. *Journal of Financial Research*, 15(3), s. pp.
- Miller, R. L. (2014). *Statistics for economists*. Routledge. <https://www.routledge.com/Statistics-for-Economists/Miller/p/book/9780367331582>
- Mishkin, F. S. (1996). *The channels of monetary transmission: Lessons for monetary policy*. NBER Working Paper No. 5464. <https://ideas.repec.org/p/nbr/nberwo/5464.html>
- Piffaut, P. V., & Rey Miró, D. (2024). El papel de los bancos centrales en la transformación de los mercados financieros. *Revista de Economía y Finanzas*, 2(4), 35-38. <https://doi.org/10.32826/reyf.v2i4.364>
- Sims, C. A. (1980). Macroeconomics and reality. *Econometrica*, 48(1), 1-48. <https://www.jstor.org/stable/1913236>
- Stock, J. H., & Watson, M. W. (2019). *Introduction to econometrics*. Pearson Education. <https://www.pearson.com/store/p/introduction-to-econometrics/P100000488250>
- Taylor, J. B. (1993). *Discretion versus policy rules in practice*. Carnegie-Rochester Conference Series on Public Policy, 39, 195-214. <https://www.sciencedirect.com/science/article/abs/pii/016722319390009L>
- Triana Rodríguez, A., & Lozano, N. A. (2019). *Análisis de la incidencia de los fundamentales en el índice Colcap* [tesis de pregrado, Universidad Cooperativa de Colombia, Bogotá]. <https://repository.ucc.edu.co/server/api/core/bitstreams/7bd463af-0cef-4515-83dd-036230826d74/content>
- Wooldridge, J. M. (2019). *Introductory econometrics: A modern approach*. Cengage Learning. <https://www.cengage.com/c/introductory-econometrics-a-modern-approach-7e-wooldridge/9780357040057/>
- Zhang, C., Zhang, Y., Cucuringu, M., & Qian, Z. (2024). Volatility forecasting with machine learning and intraday commonality. *Journal of Financial Econometrics*, 22(2), 501-507. <https://doi.org/10.1093/jfinec/nbad005>