



Universidad de las Américas

Maestría en Big Data

Tema:

“Aplicación del modelo ARIMA para la predicción de precios bancarios de la Bolsa de Valores Ecuatoriana y su visualización para optimizar la toma de decisiones en inversiones.”

Tutor:

Manuel Eugenio Morocho Cayamcela

Autor:

Carlos Antonio León Mosquera

2024

Resumen

Este proyecto busca desarrollar y aplicar un modelo autoregresivo integrado de promedio móvil (ARIMA) para predecir los precios bancarios en la Bolsa de Valores de Ecuador, proporcionando una herramienta poderosa para inversores y analistas. Además, se desarrollará una visualización de estas predicciones en la herramienta "Power BI", lo que facilitará la interpretación de los datos y apoyará la toma de decisiones estratégicas en inversiones, contribuyendo a una mayor eficiencia y rentabilidad en los portafolios de los inversionistas bancarios.

Los modelos evaluados en el presente estudio concluyen que el modelo ARIMA es una herramienta capaz de predecir el precio de las acciones con un margen de error bajo, lo cual es útil para que el lector e inversor pueda utilizar los modelos validados y comenzar a invertir en sus portafolios.

Se recomienda que, además del análisis técnico expuesto, el inversor siempre complemente este análisis con un análisis fundamental, incluyendo noticias, estados financieros y otros factores, para tomar decisiones más informadas.

Palabras clave: ARIMA, Portafolios

Abstract

This project aims to develop and apply an AutoRegressive Integrated Moving Average (ARIMA) model to predict banking prices in the Ecuadorian Stock Exchange, providing a powerful tool for investors and analysts. Additionally, a visualization of these predictions will be developed using the "Power BI" tool, facilitating data interpretation and supporting strategic investment decisions, contributing to greater efficiency and profitability in banking investors' portfolios.

The models evaluated in this study conclude that the ARIMA model is a tool capable of predicting stock prices with a low margin of error, which is useful for readers and investors to utilize the validated models and start investing in their portfolios.

It is recommended that, in addition to the technical analysis presented, investors always complement this analysis with fundamental analysis, including news, financial statements, and other factors, to make more informed decisions.

Keywords: *ARIMA, Portfolios.*

Tabla de contenidos:

Introducción.....	7
Revisión Literaria.....	8
Objeto de Estudio.....	18
Planteamiento del Problema	19
Objetivo general	20
Objetivos específicos	21
Justificación.....	22
Metodología.....	23
Determinación de la estacionariedad.....	23
Identificación de los parámetros	24
Estimación del modelo.....	25
Dataset.....	26
Obtención del dataset y evaluación exploratoria de campos.....	26
Carga de Dataset e importación de librerías.....	29
Limpieza de datos.....	31
1. Filtrado por emisor	31
2. Campo fecha a "datetime"	31
3. Verificar datos nulos	31
4. Ordenar por fecha y resamplio de frecuencia	31
5. Foward fill.....	32
Modelo ARIMA	33
1. Análisis exploratorio de datos	33
2. Pruebas de estacionariedad.....	35
3. ACF y PACF para denfinir "p" y "q".....	36
4. División de datos de prueba y entrenamiento	37
5. Ajuste del modelo.....	37
6. Predicciones.....	37
7. Medir error cuadrático	37
8. Visualizamos las predicciones vs los datos reales.....	38
Resultados del modelo.....	39
Herramienta de visualización	40
Obtención de información	40
1. Obtención de datos históricos.....	40
2. Obtención de predictivos.....	40

Visualizaciones	42
Gráfico de velas	42
Gráfico de predicciones	42
Gráfico de volumen y precio	43
Gráfico de rendimientos.....	44
Gráfico de oportunidades.....	45
Discusión sobre resultados	46
Modelo ARIMA.....	46
Herramienta de visualización.....	47
El MSE como medida financiera.....	49
Implicaciones a los inversionistas y la sociedad en general.....	50
Conclusiones y recomendaciones.....	52
Conclusiones	52
Recomendaciones	53
Referencias	55
Anexo 1.	56
Script de phyton.....	56

Índice de tablas

Tabla 1. Tabla de referencias.....	11
Tabla 2. Base de datos BVQ.....	26
Tabla 3. Campos de base de datos.....	27
Tabla 4. Resultados modelo ARIMA.....	39
Tabla 5. Datos históricos en power query.....	40
Tabla 6. Datos predictivos en power query.....	41

Introducción

Las Bolsas de Valores, tanto de Guayaquil como de Quito, ambas de Ecuador, se fundan en el año de 1969. Actualmente, funcionan de manera conjunta y paralela, registran una transaccionalidad solo de acciones ordinarias en el año 2022 equivalente a \$41,341,690.04, y para el año 2023 esta llega a ser \$56,775,159.64, con un crecimiento porcentual del 37% en tan solo un año.

Pese al crecimiento de la transaccionalidad en acciones de la Bolsa de Valores ecuatoriana, hoy en día, los inversores y analistas financieros enfrentan diariamente desafíos en su toma de decisiones, debido a la falta de herramientas predictivas y visuales que les permitan mantenerse informados sobre los movimientos del mercado. Esta carencia de recursos adecuados limita la capacidad de los individuos para optimizar sus estrategias de portafolio.

Los bancos son aquellas empresas que datan de ser las más antiguas cotizantes en la Bolsa de Valores ecuatoriana, así como las acciones más transaccionadas, por lo cual deberían contar con un análisis más exhaustivo en temas de modelos y predicciones. Actualmente, son cuatro los bancos que tienen datos suficientes para aplicar un modelo.

Los modelos autoregresivos integrados de promedios móviles (ARIMA) son herramientas muy poderosas en la predicción de series de tiempo, ya que consideran tres factores de alto valor: la autoregresión, la diferenciación temporal y la media móvil, lo que asegura una predicción estadísticamente completa.

Por ende, este estudio trata de proveer un adelanto a lo que la Bolsa de Valores debería llegar a tener: un análisis técnico de las fluctuaciones de precio, así como una visualización que permita a los inversionistas que conocen el ámbito financiero obtener un análisis más completo para sus inversiones.

Revisión Literaria

La predicción del comportamiento de las acciones bancarias es un campo de estudio crítico en el ámbito financiero, donde la precisión y la confiabilidad de los modelos predictivos desempeñan un papel crucial en la toma de decisiones de inversión. En este contexto, diversos enfoques y metodologías han sido investigados para determinar cuál es el más adecuado para pronosticar los precios de las acciones bancarias con la mayor precisión posible. Dentro de estas metodologías, el modelo ARIMA ha surgido como uno de los enfoques más prometedores y ampliamente utilizados en la predicción financiera.

Uno de los estudios que respalda la eficacia del modelo en la predicción de acciones bancarias es el realizado por Diana Marcela Gómez Rueda en 2021. Su investigación tuvo como objetivo desarrollar un modelo predictivo del índice bursátil colombiano de deuda pública tasa fija COLTES LP entre enero de 2016 y mayo del 2021. La fuente de datos utilizada fue el índice bursátil de COLTES de largo plazo a partir de datos históricos. Utilizando la metodología ARIMA, Gómez Rueda encontró que el modelo presentó los mejores datos respecto a los criterios AIC (Criterio de Información de Akaike) y BIC (Criterio de Información Bayesiano), y se evidenció la ausencia de autocorrelación serial en los errores. Como resultado, ARIMA demostró ser un modelo eficiente para la predicción del índice bursátil colombiano (Gómez Rueda, 2021).

Otro estudio relevante es el llevado a cabo por Echazarreta de la Mancha en 2022. Su investigación se centró en el pronóstico del precio de las acciones, con el objetivo de demostrar que los modelos de series de tiempo pueden pronosticar de manera consistente el precio de las acciones. Utilizó información diaria de 100 acciones que se encuentran en el índice S&P500 y evaluó varios modelos, incluyendo ARIMA, Holt-Winters, Redes Neuronales, LSTM (Long Short-Term Memory) y XGBoost. Echazarreta de la Mancha encontró que ARIMA fue el mejor modelo en 74 ocasiones, seguido por Holt-Winters y XGBoost en 21 y 5 ocasiones respectivamente. Las redes neuronales LSTM tuvieron el peor desempeño en su estudio. Como implicación, se recomienda utilizar ARIMA para

predecir acciones debido a su eficacia demostrada en múltiples ocasiones (Echazarreta de la Mancha, 2022).

En otro estudio, se investigó la aplicación de técnicas de machine learning para la predicción de los precios de la acción APPLE. Su objetivo fue comparar el nivel de predicción de determinadas técnicas como series de tiempo y machine learning en el contexto del pronóstico del precio de la acción APPLE. Utilizó Yahoo Finance como fuente de información del histórico de los precios y evaluó modelos como ARIMA, Regresión Lineal Múltiple y XGBoost Regression. Broncano encontró que los modelos de machine learning, como la regresión lineal múltiple o la técnica de Extreme Gradient Boosting (XGBOOST), resultaron ser modelos eficaces en cuanto a la capacidad predictiva de los precios de la acción Apple que cotiza en la Bolsa de Valores de New York. Sin embargo, recomienda utilizar ARIMA para predecir acciones cuando solo se tiene histórico de precios, más cuando se agrega un contexto externo, es mejor utilizar XGBoost (Broncano, 2022).

Además, Khan y Alghulaiakh propusieron un ARIMA model for accurate time series stocks forecasting. Su objetivo fue predecir el precio de las acciones de Netflix utilizando ARIMA. Utilizaron datos diarios del precio de las acciones proporcionados por Yahoo! Finance. Los autores encontraron que ARIMA mostró resultados precisos en el cálculo de precios futuros, lo que demuestra el potencial del uso del modelo en datos de series temporales para obtener predicciones precisas sobre datos de acciones. Esto ayudará a los inversores en acciones en sus decisiones de inversión (Khan & Alghulaiakh, 2020).

Finalmente, Rubio y Alba propusieron un modelo híbrido ARIMA-SVR, (Support Vector Regression) para pronosticar el precio de acciones colombianas seleccionadas. Utilizaron históricos de: Bancolombia, Ecopetrol, Tecnoglass y Grupo Aval como fuente de datos. Evaluaron los modelos ARIMA y SVR y encontraron que el modelo híbrido mejoró los modelos componentes en cuatro medidas de precisión en la mayoría de los casos. Sin embargo, el modelo híbrido no aplicó para el banco (Rubio & Alba, 2022).

En resumen, los hallazgos de la revisión literaria revelaron que el modelo ARIMA ha demostrado su eficacia en la predicción de precios de acciones y rendimientos financieros en diferentes contextos y mercados. Se encontró que ARIMA fue efectivo en la predicción de índices bursátiles, precios de acciones individuales y rendimientos financieros en varios estudios revisados. Además, se observó que ARIMA ha sido particularmente útil en bancos y cuando se dispone de datos históricos limitados y no se cuenta con información externa adicional.

Aunque la mayoría de los estudios revisados respaldaron la efectividad de ARIMA en la predicción financiera, algunos estudios comparativos destacaron la utilidad de otros modelos, como XGBoost y Redes Neuronales, en ciertos contextos y condiciones específicas. Sin embargo, estos hallazgos contrastantes no invalidan la eficacia de ARIMA, sino que resaltan la importancia de considerar diferentes enfoques y metodologías dependiendo de las características y la complejidad de los datos disponibles.

En conclusión, los hallazgos de la investigación respaldan la relevancia y la viabilidad del uso de ARIMA en el contexto de este proyecto de investigación. Dado que el objetivo principal es predecir los rendimientos de las acciones bancarias en la bolsa ecuatoriana utilizando datos históricos, ARIMA se presenta como una opción sólida y confiable debido a su capacidad para modelar tendencias y patrones en series de tiempo financieras. Sin embargo, también se considerará la posibilidad de explorar otros modelos y enfoques, como XGBoost y Redes Neuronales, para obtener una visión más completa y precisa del rendimiento futuro del portafolio de bancos.

Tabla 1.

Tabla de referencias

Autor	Objetivos de la investigación	Problema abordado	Fuente de datos utilizados	Metodología implementada	Resultados	Implicaciones
Gómez Rueda, D. M. (2021).	Modelo predictivo del índice bursátil colombiano de deuda pública tasa fija COLTES LP entre enero 2016 y mayo del 2021	Disminuir el nivel de incertidumbre para el inversionista.	Índice bursátil de COLTES de largo plazo a partir de los datos históricos registrados entre enero del año 2016 y mayo del 2021.	ARIMA	El Modelo ARIMA presentó los mejores datos respecto a los criterios AIC y BIC, y se evidenció la ausencia de autocorrelación serial en los errores.	ARIMA resultó ser un modelo eficiente para la predicción

<p>Frutos Serrano, S. (2022).</p>	<p>Comparación entre XGBoost y Regresión Lineal Múltiple para la predicción de la evolución del precio de las acciones</p>	<p>Identificar el mejor modelo para predecir el precio de acciones</p>	<p>Yahoo Finance, los datasets para dos entidades: BNP Paribas (BNP.PA.csv) y Microsoft (MSFT.csv).</p>	<p>Regresión múltiple, Xgboost</p>	<p>Regresión Lineal Múltiple realiza predicciones más precisas que XGBoost en cualquiera de sus modos. Con lo que, para cualquiera de los casos analizados (tanto si la empresa sigue una tendencia constante que no obligue a extrapolar como si no es así y la extrapolación es necesaria)</p>	<p>Regresión Lineal Múltiple es el algoritmo que se recomienda ya que es el que mejores resultados ofrece.</p>
-----------------------------------	--	--	---	------------------------------------	--	--

<p>Echazarreta de la Mancha, S. A. (2022).</p>	<p>Pronóstico del precio de las acciones</p>	<p>Demostrar que los modelos de series de tiempo pueden pronosticar de manera consistente el precio de las acciones.</p>	<p>Se utilizo información diaria de 100 acciones que se encuentran en el índice S&P500.</p>	<p>ARIMA, Holt-Winters , RedesNeuronales , LSTM , XGBoost</p>	<p>ARIMA fue el mejor modelo en 74 ocasiones. Le siguen los modelos Holt-Winters y XGBoost con 21 y 5 selecciones respectivamente. Finalmente, las redes neuronales LSTM tuvieron el peor desempeño.</p>	<p>Se recomienda utilizar ARIMA para predecir acciones</p>
--	--	--	---	---	--	--

<p>Broncano, R. E. (2022).</p>	<p>Aplicación de técnicas de machine learning para la predicción de los precios de la acción APPLE</p>	<p>Comparar el nivel de predicción de determinadas técnicas como series de tiempo y machine learning en el contexto del pronóstico del precio de la acción APPLE</p>	<p>Yahoo Finance, se utilizó como una fuente de información del histórico de los precios.</p>	<p>ARIMA, Regresión Lineal Múltiple, XGBOOST Regression.</p>	<p>Los modelos de machine learning como la regresión lineal múltiple o la técnica de Extreme Gradient Boosting (XGBOOST) resultaron ser modelos eficaces en cuanto a la capacidad predictiva de los precios de la acción Apple que cotiza en la Bolsa</p>	<p>Se recomienda utilizar ARIMA para predecir acciones cuando solo se tiene historicos, cuando se pone un contexto externo es mejor Xgboost</p>
--------------------------------	--	--	---	--	---	---

					de Valores de New York	
Ning, Y., Kazemi, H., & Tahmasebi, P. (2022).	A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet	Predicir el rendimiento de producción en reservorios no convencionales	Datos representativos de producción de petróleo de un pozo ubicado en el reservorio de la Cuenca de Denver-Julesburg	ARIMA, red LSTM y Prophet	Los resultados muestran que ARIMA y LSTM tienen un mejor rendimiento que Prophet, probablemente porque no todos los datos de producción de petróleo incluyen influencias estacionales.	ARIMA y LSTM tienen un mejor rendimiento que Prophet

<p>Khan, S., & Alghulaiakh, H. (2020).</p>	<p>ARIMA model for accurate time series stocks forecasting</p>	<p>Predicir el precio de las acciones de NETFLIX utilizando ARIMA</p>	<p>Yahoo! Finance [20]. The dataset contains Netflix daily stock price data</p>	<p>ARIMA</p>	<p>ARIMA mostró resultados precisos en el cálculo de precios futuros, lo que demuestra el potencial del uso del modelo ARIMA en datos de series temporales para obtener predicciones precisas sobre datos de acciones. Esto ayudará a los inversores en acciones en sus</p>	<p>Se recomienda ARIMA</p>
--	--	---	---	--------------	---	----------------------------

					decisiones de inversión.	
Rubio, L., & Alba, K. (2022).	Forecasting Selected Colombian Shares Using a Hybrid ARIMA-SVR Model	Adicionar un modelo de vectores para reducir el factor volatilidad en ARIMA	Yahoo Finance for Bancolombia, Ecopetrol, Tecnoglass, and Grupo Aval	ARIMA y SVR	El modelo híbrido mejora los modelos componentes (ARIMA y SVR) en cuatro medidas de precisión en la mayoría de los casos (excepto para Bancolombia).	El modelo híbrido no aplicó para banco

Objeto de Estudio

El objeto de estudio de este proyecto de investigación es el desarrollo de un modelo predictivo ARIMA para el portafolio de bancos de la bolsa ecuatoriana. Este modelo tendrá como objetivo principal predecir los rendimientos futuros de las acciones bancarias mediante un modelo estadístico.

Adicionalmente, se enfoca en una herramienta de visualización que facilite la comprensión del mercado. Esta herramienta permitirá visibilizar las predicciones del modelo, facilitando así el análisis técnico de las acciones bancarias para los inversores.

Planteamiento del Problema

El problema que se aborda en este proyecto radica en la falta de herramientas predictivas precisas y confiables para los inversores y analistas financieros de la bolsa ecuatoriana, específicamente en relación con las inversiones en acciones bancarias. La ausencia de un modelo predictivo automático y una plataforma visual para la toma de decisiones dificulta a los actores del mercado financiero obtener una visión clara y precisa del rendimiento futuro del portafolio de bancos.

Este problema es crítico debido a que la toma de decisiones en el mercado bursátil requiere de información precisa y oportuna para maximizar los rendimientos y minimizar los riesgos asociados con las inversiones. La falta de herramientas predictivas adecuadas puede llevar a decisiones erróneas, pérdida de capital y oportunidades de inversión desaprovechadas. Por lo tanto, contar con un modelo predictivo confiable se vuelve fundamental para mejorar la eficacia y la rentabilidad de las operaciones financieras en el mercado de valores ecuatoriano.

Objetivo general

Proponer una herramienta que ayude en la toma de decisiones de inversión, para el portafolio de bancos en la bolsa de valores de Ecuador.

Objetivos específicos

- 1) Implementar y ajustar un modelo ARIMA utilizando los datos recopilados para predecir los rendimientos futuros del portafolio de bancos.
- 2) Evaluar la precisión del modelo ARIMA utilizando métricas de error cuadrático.
- 3) Desarrollar una visualización interactiva para la información recolectada, incluyendo gráficos de rendimientos históricos y predicciones futuras del portafolio de bancos.

Justificación

El modelo ARIMA es particularmente efectivo en la captura de relaciones temporales en los datos debido a su capacidad para modelar y combinar tres componentes clave: la autoregresión (AR), la integración (I) y la media móvil (MA). La autoregresión permite que el modelo utilice valores pasados de la serie temporal para predecir futuros, capturando patrones de dependencia temporal. La integración ayuda a transformar una serie no estacionaria en una estacionaria, lo cual es esencial para aplicar técnicas de series temporales de manera efectiva. Finalmente, la media móvil utiliza errores de predicciones pasadas para ajustar el modelo, mejorando su precisión.

Esta combinación permite que ARIMA maneje tanto tendencias como patrones cíclicos en los datos, haciendo que sea una herramienta robusta y flexible para la predicción de series temporales. Los hallazgos de diversas investigaciones respaldan la relevancia y la viabilidad del uso de ARIMA en el contexto de este proyecto de investigación.

Rubio y Alba (2022) propusieron un modelo híbrido ARIMA-SVR para pronosticar el precio de acciones colombianas seleccionadas. Utilizaron históricos de Bancolombia, Ecopetrol, Tecnoglass y Grupo Aval como fuente de datos. Evaluaron los modelos ARIMA y SVR y encontraron que el modelo híbrido mejoró los modelos componentes en cuatro medidas de precisión en la mayoría de los casos. Sin embargo, el modelo híbrido no se aplicó para el banco.

Echazarreta de la Mancha (2022) evaluó varios modelos, incluyendo ARIMA, Holt-Winters, Redes Neuronales, LSTM y XGBoost. Echazarreta de la Mancha encontró que ARIMA fue el mejor modelo en 74 ocasiones, seguido por Holt-Winters y XGBoost en 21 y 5 ocasiones respectivamente.

Estas referencias indican que ARIMA es una herramienta poderosa y adecuada para la predicción de series temporales en el contexto de las acciones bancarias. Este proyecto busca aprovechar la eficacia del modelo ARIMA para proporcionar a los inversores y analistas financieros una herramienta predictiva confiable y valiosa.

Metodología

En 1970, Box y Jenkins propusieron un modelo metodológico para la estimación de modelos en series de tiempo. Esta metodología sirve como una ayuda al investigador, en la que los propios datos temporales de la variable estudiada indican las características de la estructura probabilística subyacente (Chávez Quisbert, 1997).

Según Shumway y Stoffer (2017), muchas veces los modelos de regresión clásica no son suficientes para explicar todo lo que sucede en una serie de tiempo. Por eso comienzan explicando la autoregresión (AR). Los modelos autorregresivos están basados en la idea de que una variable x puede ser explicada en función de p , siendo “ p ” el número de veces que tienen que suceder para llegar a ser igual a la x actual.

Luego tenemos los modelos de medias móviles (MA), que se determinan como aquellos que explican el valor de la variable en un periodo t en función de un término independiente y la sucesión de errores que corresponden a periodos precedentes que están ponderados (De Arce & Mahía, 2003).

Para la construcción del modelo ARIMA, seguimos los siguientes pasos clave:

Determinación de la estacionariedad

El primer paso es determinar si la serie temporal es estacionaria. Una serie estacionaria es aquella cuyas propiedades estadísticas, como la media y la varianza, no cambian con el tiempo. Utilizamos pruebas estadísticas como la prueba de Dickey-Fuller aumentada (ADF) para verificar la estacionariedad. Si la serie no es estacionaria, se diferenciará hasta que se vuelva estacionaria.

Identificación de los parámetros

Para identificar los parámetros del modelo ARIMA, utilizamos la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF):

p : el número de términos autoregresivos se identifica observando el gráfico PACF.

d : el número de diferencias necesarias para hacer que la serie sea estacionaria se determina a través de la diferenciación de la serie original.

q : el número de términos de medias móviles se identifica observando el gráfico ACF.

Estimación del modelo

Una vez identificados los parámetros, se procede a estimar el modelo ARIMA utilizando la siguiente fórmula general:

$$\begin{aligned} ARIMA &= (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d X_t \\ &= (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \epsilon_t \end{aligned}$$

Donde:

Componente AR: Se refiere a los términos $(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ que modelan la dependencia de los valores pasados.

Componente I: Se refiere a $(1 - B)^d$ que realiza las diferencias para hacer la serie estacionaria.

Componente MA: Se refiere a los términos $(1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q)$ que modelan la dependencia de los errores pasados.

Dataset

Obtención del dataset y evaluación exploratoria de campos

Se recopila la información de un origen confiable, en este caso, los históricos de precios de las acciones bancarias desde el año 2022 hasta julio de 2024, obtenidos de la página web de la Bolsa de Valores de Quito.

Tabla 2.

Base de datos BVQ

FECHA	EMISOR	VALOR	VALOR NOMINAL	PRECIO	NUMERO ACCIONES	VALOR EFECTIVO	PROCEDENCIA
03-ene-2022	BANCO GUAYAQUIL S.A.	ACCIONES	1,00	0,99	3.500	3.465,00	Q
03-ene-2022	BANCO DE LA PRODUCCION S.A . PRODUBANCO	ACCIONES	1,00	0,65	8.678	5.640,70	Q
03-ene-2022	BANCO GUAYAQUIL S.A.	ACCIONES	1,00	0,99	30.000	29.700,00	Q

Fuente: Bolsa de Valores de Quito. (n.d.). Cotizaciones históricas. Bolsa de Valores de Quito.
<https://www.bolsadequito.com/index.php/estadisticas/boletines-2/cotizaciones-historicas>

Esta información fue evaluada campo por campo para determinar las variables más relevantes para el modelo.

Tabla 3.

Campos de base de datos

Variable	Fuente de Datos	Naturaleza o Tipo de Datos	Descripción
FECHA	Archivo Excel de la Bolsa de Valores de Quito	Fecha (dd- mmm- aaaa)	Fecha en la que se registró la transacción de acciones.
EMISOR	Archivo Excel de la Bolsa de Valores de Quito	Texto	Nombre de la empresa o entidad emisora de las acciones.
VALOR	Archivo Excel de la Bolsa de Valores de Quito	Texto	Tipo de valor transaccionado (en este caso, acciones).
VALOR NOMINAL	Archivo Excel de la Bolsa de Valores de Quito	Numérico (decimal)	Valor nominal de cada acción transaccionada.
PRECIO	Archivo Excel de la Bolsa de Valores de Quito	Numérico (decimal)	Precio al que se transaccionó cada acción.
NUMERO ACCIONES	Archivo Excel de la Bolsa de Valores de Quito	Numérico (entero)	Número de acciones transaccionadas en la operación.

VALOR EFECTIVO	Archivo Excel de la Bolsa de Valores de Quito	Numérico (decimal)	Valor total de la transacción, calculado como el número de acciones multiplicado por el prec
-----------------------	---	--------------------	--

Como se puede observar, y dado que la finalidad del modelo es trabajar con series de tiempo, necesitaremos una variable independiente (tiempo) y una variable dependiente (precio) que intentaremos predecir. Los campos para utilizar serán los denominados "Fecha" y "Precio". Sin embargo, para los siguientes pasos, los campos "Emisor" y "Valor" serán clave para la limpieza de datos.

Carga de Dataset e importación de librerías

Dado que el objeto de estudio se llevará a cabo en el lenguaje Python, utilizando el entorno de Google Colab, es necesario preparar todo para la aplicación y generación del modelo. Para esto, importaremos las siguientes librerías:

Pandas: Esta librería se utiliza para la manipulación y análisis de datos. Facilita la carga, limpieza, y procesamiento de datos en estructuras de datos tabulares, como DataFrames.

NumPy: Proporciona soporte para operaciones matemáticas avanzadas y manejo eficiente de arreglos numéricos. Es fundamental para realizar cálculos y operaciones matemáticas en los datos.

Seaborn: Es una biblioteca de visualización de datos basada en Matplotlib que ofrece una interfaz de alto nivel para dibujar gráficos estadísticos atractivos y informativos.

Matplotlib.pyplot: Es una biblioteca de visualización de datos que permite crear gráficos y figuras en Python. Se utiliza para la creación de gráficos estáticos, animados e interactivos.

Statsmodels.api: Proporciona herramientas para la estimación de modelos estadísticos y la realización de pruebas estadísticas. Es esencial para ajustar y evaluar el modelo ARIMA.

Sklearn.metrics: Contiene funciones para evaluar el rendimiento de modelos de machine learning mediante métricas de evaluación como el error cuadrático medio (MSE) y el error absoluto medio (MAE).

Estas librerías son esenciales para la manipulación de datos, visualización, y el análisis estadístico necesario para el desarrollo y validación del modelo ARIMA.

Así mismo, se procede a cargar el archivo en formato ".xlsx" utilizando el código `from google.colab import files` y seleccionando el archivo desde la ruta donde se descargó.

Limpieza de datos

Partiendo del objetivo de obtener la mejor predicción posible dentro del modelo ARIMA, es fundamental evaluar varios aspectos. El primero es retener la mayor cantidad de información relevante y específica. Dado que necesitamos desarrollar un modelo para cada emisor, es esencial filtrar los datos por emisor. Al hacer esto, aseguramos que estamos trabajando con los datos de un solo banco, lo que permite un análisis más preciso y detallado.

Utilizaremos para el ejemplo a “BANCO BOLIVARIANO C.A.”; sin embargo, todos los emisores seguirán el mismo procedimiento.

1. Filtrado por emisor

Una vez tengamos el emisor filtrado, nos aseguraremos de que el campo “Fecha” se encuentre como tipo de datos “datetime”. Esto con la finalidad de que el modelo pueda reconocer el campo y podamos dividir los tiempos en la temporalidad adecuada.

2. Campo fecha a “datetime”

Para continuar, verificamos que no se encuentren datos nulos y afortunadamente no encontramos datos nulos para ningún emisor.

3. Verificar datos nulos

El siguiente paso es asegurarnos que los datos se encuentren ordenados por fecha. Los ordenamos.

4. Ordenar por fecha y resampleo de frecuencia

Seleccionaremos solo aquellas columnas que utilizaremos para continuar con la limpieza de datos.

Debido a la cantidad de transacciones diarias que existen para cada emisor, se consideró que la mejor temporalidad para nuestro análisis es la mensual. Esta elección nos permitirá manejar un volumen de datos más manejable y significativo, al mismo tiempo que captura las tendencias y patrones importantes en el comportamiento de las acciones bancarias.

5. Foward fill

Por último, y siguiendo la lógica del mercado de valores, en donde si un mes no se registran transacciones, se toma el precio de la última transacción, utilizamos el método "Forward Fill" para rellenar los valores faltantes con el último precio registrado.

Modelo ARIMA

Algunas consideraciones, para entender la aplicación del modelo son:

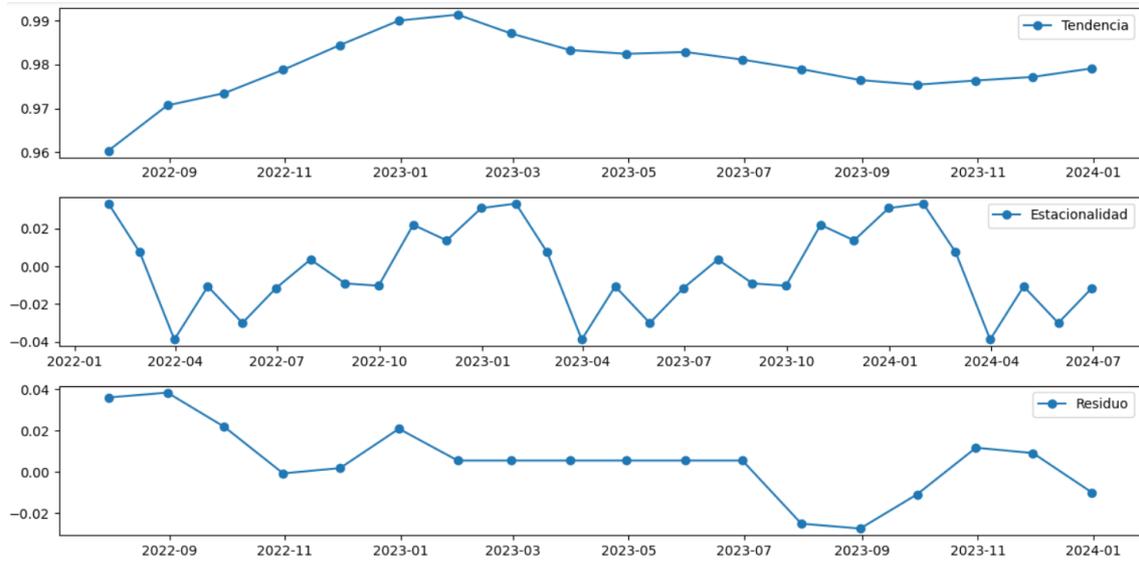
- El modelo fue desarrollado con la herramienta Google Colab
- El ejemplo para describir es con el emisor “BANCO BOLIVARIANO C.A.”
- Todos los demás emisores siguieron la misma metodología

1. Análisis exploratorio de datos

Se realiza un análisis exploratorio de datos para entender las características principales del dataset, identificar patrones, tendencias y estacionalidades en los precios de las acciones. Esto incluye la visualización de datos, el cálculo de estadísticas descriptivas y la identificación de posibles outliers.

Figura 1.

Descomposición de datos



Como se puede observar, la descomposición de datos nos brinda la tendencia en este caso horizontal, un patron estacional y un ruido con atípicos en sus inicios y final.

2. Pruebas de estacionariedad

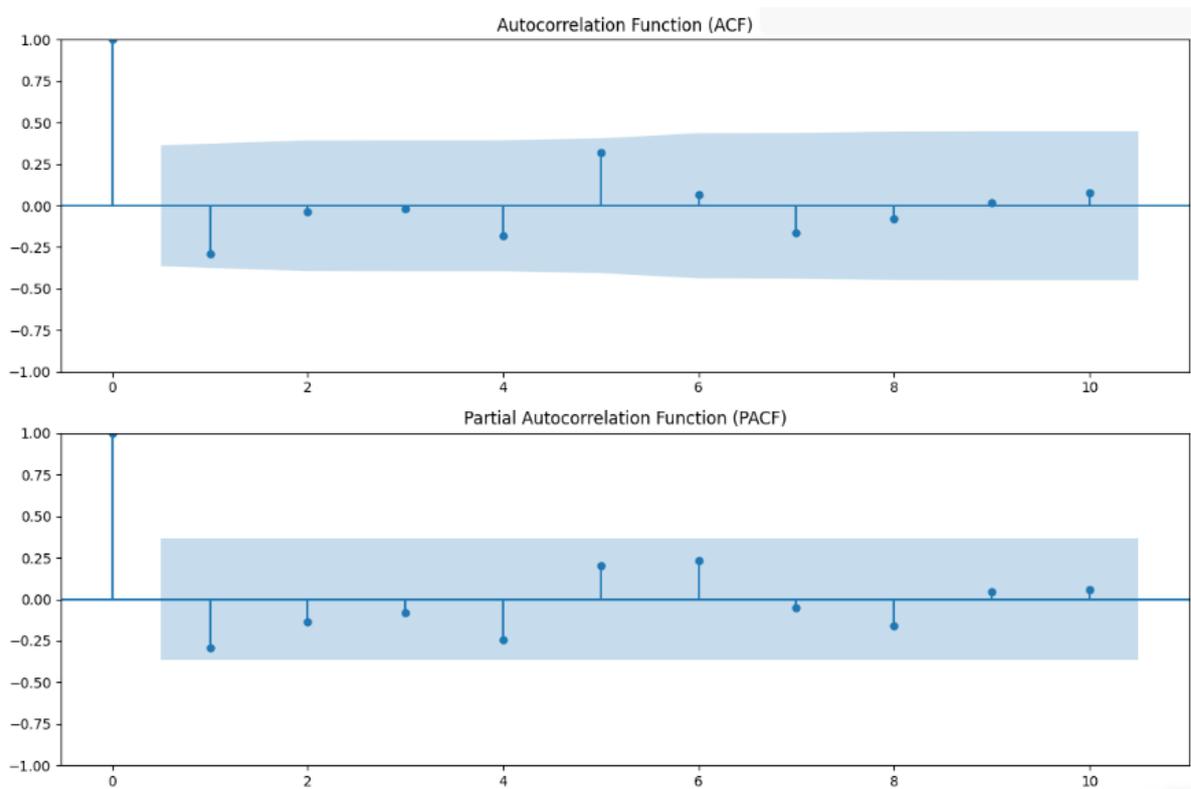
Se aplica la prueba de Dickey-Fuller aumentada (ADF) para verificar la estacionariedad. Si la serie no es estacionaria, se diferenciará hasta que se vuelva estacionaria. De acuerdo con el número de veces que se tenga que diferenciar la serie, determinaremos el valor de "d". dentro de los parámetros ARIMA.

3. ACF y PACF para definir “p” y “q”

Se grafican las funciones tanto de autocorrelación como de autocorrelación parcial, con la finalidad de determinar “p” y “q”.

Figura 2.

Gráficos ACF y PACF



El grafico brinda un claro inicio en el cuarto eslabón lo cual indica, un indicador de tres para p y q.

4. División de datos de prueba y entrenamiento

Debido al tamaño de los datos, se definió un 75% de entrenamiento para todos los emisores. Dividir los datos nos sirve para evaluar la precisión del modelo cuando se ponga a prueba.

5. Ajuste del modelo

Una vez identificados los valores de p, d, q procedemos a ajustar el modelo.

6. Predicciones

Realizamos el forecast del modelo para posteriormente evaluar su efectividad.

7. Medir error cuadrático

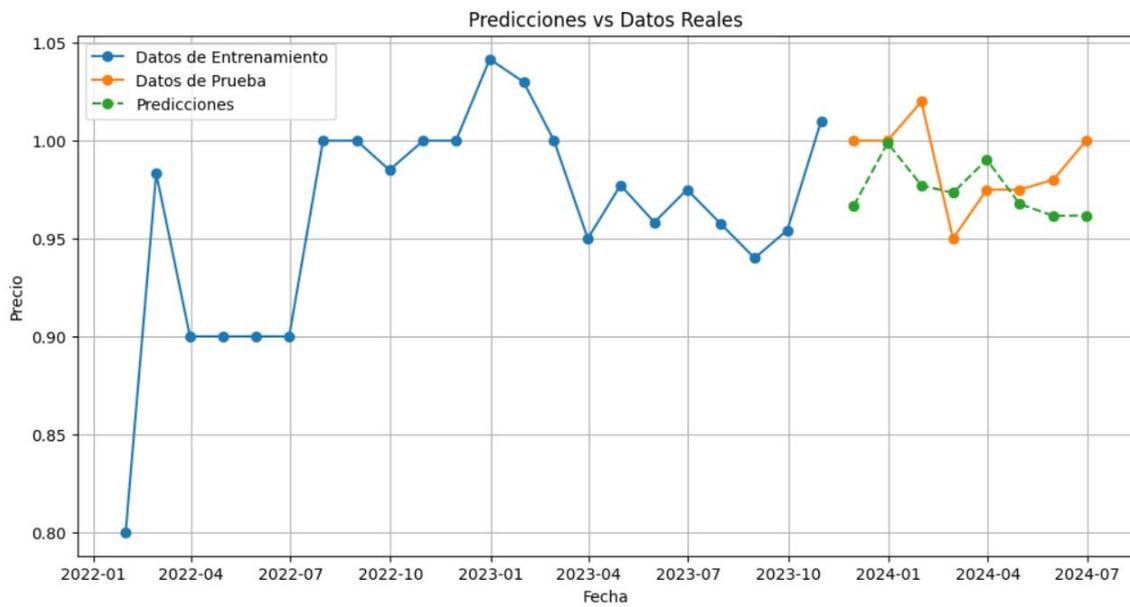
Medimos el error cuadrático, en caso de tener un error no aceptable, se reajusta el modelo. Es mejor el error cercano a cero.

8. Visualizamos las predicciones vs los datos reales

Confirmamos que nuestras predicciones se acercan a los datos reales del 25% de datos de prueba.

Figura 3.

Predicciones vs datos de prueba.



Aquí se puede observar en verde, como las predicciones difieren o coinciden con los valores que fueron dados en la temporalidad descrita.

Resultados del modelo

Una vez ejecutados los modelos, para aquellos bancos que contaban con data suficiente para generar un modelo predictivo, estos fueron los resultados:

Tabla 4.

Resultados modelo ARIMA

Banco	Modelo ARIMA	MSE
Produbanco	ARIMA (3, 1, 3)	0.00252474095093591
Banco Guayaquil	ARIMA (1, 1, 1)	0.009425566063699861
Banco Bolivariano	ARIMA (4, 0, 7)	0.0006968103649956127
Banco del Pichincha	ARIMA (5, 0, 5)	56.124461126325784 (Por valor atípico)

Como se puede observar, los modelos tienden a un error cuadrático de cero, lo cual es una buena señal de la efectividad del modelo, esto quiere decir que los valores predichos no difieren tanto de los valores dados en el tiempo de análisis del modelo.

Herramienta de visualización

La herramienta visual se desarrolla en el entorno de Power BI, que proporciona diversas visualizaciones útiles para el inversionista. Esta plataforma permite no solo la representación gráfica de datos históricos, sino también la integración de las predicciones generadas por el modelo ARIMA para cada emisor.

Obtención de información

1. Obtención de datos históricos

Para este apartado, hemos realizado una conexión con el archivo .xlsx obtenido de la fuente primaria previamente explicada, que fue descargado de la página web de la Bolsa de Valores de Quito.

Tabla 5.

Datos históricos en power query

FECHA	EMISOR	VALOR	VALOR NOMINAL	PRECIO	NUMERO ACCIONES	VALOR EFECTIVO	PROCEDENCIA	INDUSTRIA
lunes, 3 de enero de 2022	MUTUALISTA PICHINCHA	CERTIFICADOS DE APORTACION	700	100	7	100	Q	MUTUALISTA
lunes, 3 de enero de 2022	MUTUALISTA PICHINCHA	CERTIFICADOS DE APORTACION	700	100	7	100	Q	MUTUALISTA
lunes, 3 de enero de 2022	MUTUALISTA PICHINCHA	CERTIFICADOS DE APORTACION	700	100	7	100	Q	MUTUALISTA
lunes, 3 de enero de 2022	MUTUALISTA PICHINCHA	CERTIFICADOS DE APORTACION	700	100	7	100	Q	MUTUALISTA
lunes, 3 de enero de 2022	MUTUALISTA PICHINCHA	CERTIFICADOS DE APORTACION	700	100	7	100	Q	MUTUALISTA
lunes, 3 de enero de 2022	MUTUALISTA PICHINCHA	CERTIFICADOS DE APORTACION	700	100	7	100	Q	MUTUALISTA

2. Obtención de predictivos

Ejecutaremos un script de Python descrito en el Anexo 1, integrado en Power BI, mediante el cual se ajustarán, emisor por emisor, los modelos ARIMA validados previamente. De esta manera, obtendremos una tabla que contendrá los precios promedios resampleados a frecuencia mensual, así como las predicciones para los siguientes seis meses. El script de ejemplo que se ejecutará será para "BANCO BOLIVARIANO C.A."; sin embargo, todos los emisores se tratarán con la misma metodología.

Ejecutado el script para cada uno de los emisores, obtendremos diferentes dataframes que tendremos que integrar. Una vez integrados, obtendremos la tabla final que consolidará toda la información de los precios promedios mensuales y las predicciones para los próximos tres meses.

Tabla 6.

Datos predictivos en power query

EMISOR	FECHA	PRECIO	PREDICCIONES_FUTURAS	FECHA - Copia	RESUMEN
<ul style="list-style-type: none"> ● Válido 100 % ● Error 0 % ● Vacío 0 % 	<ul style="list-style-type: none"> ● Válido 100 % ● Error 0 % ● Vacío 0 % 	<ul style="list-style-type: none"> ● Válido 83 % ● Error 0 % ● Vacío 17 % 	<ul style="list-style-type: none"> ● Válido 17 % ● Error 0 % ● Vacío 83 % 	<ul style="list-style-type: none"> ● Válido 100 % ● Error 0 % ● Vacío 0 % 	<ul style="list-style-type: none"> ● Válido 100 % ● Error 0 % ● Vacío 0 %
BANCO GUAYAQUIL S.A.	31/1/2022	1,00	null	31/1/2022	1,00
BANCO GUAYAQUIL S.A.	28/2/2022	1,02	null	28/2/2022	1,02
BANCO GUAYAQUIL S.A.	31/3/2022	1,01	null	31/3/2022	1,01
BANCO GUAYAQUIL S.A.	30/4/2022	1,02	null	30/4/2022	1,02
BANCO GUAYAQUIL S.A.	31/5/2022	1,03	null	31/5/2022	1,03
BANCO GUAYAQUIL S.A.	30/6/2022	1,04	null	30/6/2022	1,04
BANCO GUAYAQUIL S.A.	31/7/2022	1,03	null	31/7/2022	1,03

En donde:

Emisor: Nombre de la institución bancaria que fue objeto de modelo (texto)

Fecha: Mes y año en el que se registra el precio (Fecha)

Precio: Precio histórico promedio mensual (Moneda)

Predicciones_futuras: Precio predicho con el modelo ARIMA (Moneda)

Fecha_copia: Copia del mes y año en el que se registra el precio (Fecha)

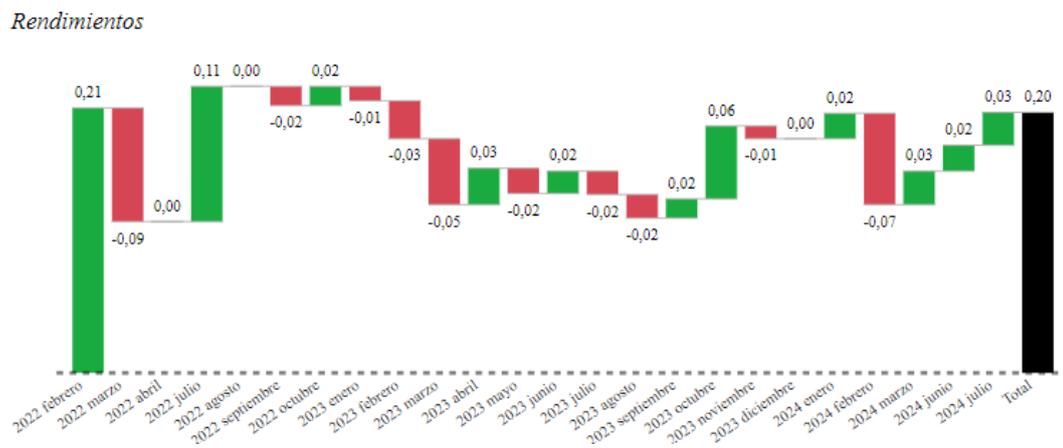
Resumen: Precio tanto histórico como predicho que se registra (Moneda)

Gráfico de volumen y precio



El volumen refleja el sentimiento del mercado. Un aumento en el volumen puede indicar un mayor interés y participación en el mercado, lo que puede ser un signo de cambios significativos en el precio. Por ejemplo, un volumen alto en una tendencia alcista puede sugerir optimismo entre los inversores.

Gráfico de rendimientos



Los rendimientos logarítmicos tienen la propiedad de ser aditivos a través del tiempo. Esto significa que los rendimientos logarítmicos de periodos sucesivos se pueden sumar para obtener el rendimiento total, lo que facilita el análisis de la evolución del precio a lo largo del tiempo. Adicionalmente permiten comparar cambios proporcionales en el precio de un activo de manera uniforme. Esto es especialmente útil cuando se analizan movimientos de precios grandes y pequeños en una escala común.

Gráfico de oportunidades

EMISOR L	enero	febrero	marzo	abril	mayo	junio	julio	agosto	septiembre	octubre	noviembre	diciembre
 Prodtibanco	↑ \$0,99	↑ \$1,00	↑ \$1,00	↑ \$0,97	↗ \$0,96	→ \$0,90	↘ \$0,86	↓ \$0,84	↓ \$0,81	↓ \$0,80	↓ \$0,81	↓ \$0,81
 Banco Bolivariano	↑ \$1,02	↓ \$0,95	↘ \$0,98	↘ \$0,98	↘ \$0,98	→ \$1,00	↑ \$1,03	→ \$0,99	↗ \$1,02	↑ \$1,03	↑ \$1,02	↑ \$1,04
 Banco Guayaquil	↑ \$1,11	↑ \$1,13	↓ \$0,94	↓ \$0,98	↓ \$0,97	↘ \$1,02	↘ \$1,01	↘ \$1,01	↘ \$1,01	↘ \$1,01	↘ \$1,01	↘ \$1,01

Las flechas que indican si el precio subió o bajó respecto a la media, proporcionando una representación clara y rápida de la tendencia del precio. Los colores que indican los precios más altos y bajos ayudan a resaltar puntos clave en el gráfico, haciendo más fácil identificar áreas de interés. Por último, permiten comparar emisores en una misma serie temporal.

Discusión sobre resultados

Modelo ARIMA

El análisis del modelo ARIMA ha revelado información valiosa sobre la dinámica de las series temporales de los precios de las acciones para los bancos analizados. A pesar de que ningún modelo es completamente determinístico y siempre existe un margen de error, los errores cuadráticos obtenidos en los modelos aplicados son notablemente bajos. Este hallazgo es altamente positivo, ya que indica que los modelos están capturando de manera efectiva las tendencias y patrones subyacentes en los datos históricos.

Entre los bancos evaluados, el modelo ARIMA para Banco Bolivariano ha demostrado ser el más preciso, con el menor error cuadrático medio (MSE). Este resultado sugiere que el modelo está adecuadamente ajustado a la serie temporal del Banco Bolivariano, proporcionando predicciones más confiables en comparación con otros bancos analizados. Los modelos para Produbanco y Banco Guayaquil también presentan un buen desempeño, aunque no alcanzan el nivel de precisión del Banco Bolivariano.

Sin embargo, el modelo para Banco del Pichincha ha mostrado un ajuste deficiente, reflejado en un MSE considerablemente alto. Este problema podría atribuirse a eventos específicos que han distorsionado los datos. En particular, la recompra de acciones a valor nominal realizada por Banco del Pichincha en agosto y septiembre de 2023 ha alterado significativamente los precios, introduciendo un sesgo en el modelo.

Para mitigar el impacto de estos eventos, se ajustó el modelo utilizando el precio de julio de 2023 como referencia para los meses de agosto y septiembre de 2023. Este ajuste permitió recalibrar el modelo ARIMA a (3,1,3), resultando en

una disminución del MSE en un 90%, aunque aún considerable. Este ajuste sugiere que, aunque el modelo mejoró, es esencial explorar otros enfoques y modelos para optimizar aún más las predicciones para Banco del Pichincha.

Herramienta de visualización

Las herramientas de visualización avanzadas han demostrado ser fundamentales para la toma de decisiones informadas en el análisis de acciones. Utilizando gráficos y otros métodos visuales, se puede obtener una visión clara de las tendencias y oportunidades en los mercados financieros.

Gráfico de Velas: El análisis del gráfico de velas revela una tendencia alcista para Banco Bolivariano. A pesar de esta tendencia positiva, el precio actual de \$1,03 aún no ha alcanzado el máximo registrado de \$1,10 en enero de 2023. Dado que el precio sigue una tendencia ascendente, se puede anticipar que es probable que continúe subiendo. Esto sugiere una posible oportunidad para mantener las acciones con la expectativa de que el precio alcanzará o superará el máximo previo.

Gráfico Predictivo: El gráfico predictivo indica una fuerte caída en el próximo mes, seguida por una recuperación que tomará aproximadamente dos meses para alcanzar el nivel actual y cuatro meses para superarlo. Esta predicción implica que, para los inversionistas actuales, podría ser un buen momento para vender, antes de que el precio potencialmente caiga y luego se recupere.

Gráfico de Volumen: El gráfico de volumen muestra un aumento en el número de acciones transaccionadas, lo cual es un indicador de alta demanda para las acciones de Banco Bolivariano. Este incremento en el volumen sugiere que hay interés creciente en la acción, lo que refuerza la idea de que podría ser un buen momento para vender.

Cuadro de Rendimientos: El análisis del cuadro de rendimientos muestra un crecimiento del 20% en el valor comercial de las acciones desde 2022. Dado este aumento significativo en dos años, es razonable anticipar que el crecimiento en el próximo año puede ser limitado. Esto refuerza la recomendación de considerar la venta de las acciones, ya que el potencial de crecimiento adicional puede ser menor.

Gráfico de Oportunidades: Finalmente, el gráfico de oportunidades revela que, en comparación con otros emisores, la acción de Banco Bolivariano está actualmente a un precio alto. Sin embargo, también es la acción con la mayor proyección de crecimiento, lo que podría atraer el interés de los inversionistas. Esto podría generar una demanda adicional y mantener el precio elevado, aunque las oportunidades de venta pueden ser preferibles dado el contexto actual.

El MSE como medida financiera.

El MSE (Mean Squared Error) es una medida de la variabilidad de las predicciones del modelo con respecto a los valores reales. Aunque el MSE, brinda una idea de qué tan buenos son los pronósticos en promedio, no define directamente en cuánto puede variar una predicción específica. Para entender en cuánto puede variar la predicción, es útil convertir el MSE a la raíz del error cuadrático medio (RMSE), que está en las mismas unidades que los datos originales.

$$RMSE = \sqrt{MSE}$$

El RMSE nos dice que, en promedio, la predicción del modelo ARIMA para el precio de la acción puede variar aproximadamente (\pm) unidades del valor real del precio de la acción. Este valor representa la desviación estándar del error de predicción, y da una mejor idea de la precisión del modelo en términos de la variabilidad esperada de las predicciones.

Para expresar el error como un porcentaje, necesitamos calcular el porcentaje de RMSE respecto al valor medio de la serie temporal del precio de la acción. Esto se conoce como el Error Cuadrático Medio Relativo (RMSRE).

RMSRE

$$RMSRE = (\text{Valor Medio RMSE}) \times 100$$

Así, podremos definir el porcentaje de variación de la predicción, de acuerdo con el error medido.

Implicaciones a los inversionistas y la sociedad en general

Para los Inversionistas:

Decisiones Informadas y Precisas: La aplicación de modelos ARIMA y herramientas de visualización avanzadas como Power BI proporciona a los inversionistas una base sólida para tomar decisiones más informadas y precisas. Al ofrecer predicciones detalladas y análisis claros, estas herramientas permiten a los inversionistas anticipar movimientos del mercado, identificar oportunidades de inversión y ajustar sus estrategias de manera proactiva. Esto reduce la incertidumbre y ayuda a maximizar los rendimientos potenciales, minimizando al mismo tiempo los riesgos asociados.

Reducción de Riesgos: Con un análisis predictivo más preciso y la visualización de datos históricos y futuros, los inversionistas pueden identificar patrones y tendencias que podrían no ser evidentes de otra manera. Esta capacidad de anticipar cambios en el mercado y ajustar las estrategias de inversión en consecuencia permite una gestión más eficaz del riesgo. La reducción de riesgos financieros contribuye a una mayor confianza en las inversiones y puede mejorar la estabilidad de los portafolios de inversión.

Optimización de Estrategias de Inversión: Las herramientas de visualización permiten a los inversionistas analizar datos complejos de manera más intuitiva y comprensible. Esto facilita la identificación de los mejores momentos para comprar o vender activos y la evaluación de la viabilidad de diferentes estrategias de inversión. Al optimizar las estrategias basadas en datos precisos y actualizados, los inversionistas pueden mejorar significativamente sus resultados financieros.

Para la Sociedad en General:

Fortalecimiento del Mercado Financiero: La capacidad de los inversionistas para tomar decisiones más informadas y precisas contribuye a un mercado financiero más estable y eficiente. Cuando los inversionistas actúan basándose en análisis detallados y predicciones precisas, el mercado tiende a reflejar mejor los fundamentos económicos y las expectativas del futuro. Esto puede reducir la volatilidad y la incertidumbre en los mercados financieros, creando un entorno económico más seguro y predecible.

Reducción de la Volatilidad Económica: La mejora en la precisión de las predicciones y la toma de decisiones informadas ayuda a reducir las fluctuaciones extremas en los precios de los activos y las inversiones. Menos volatilidad y mayor estabilidad en los mercados financieros se traducen en un entorno económico más predecible, lo que beneficia a toda la sociedad al proporcionar un contexto más estable para el crecimiento económico y la planificación financiera a largo plazo.

Democratización del Acceso a Información Financiera: La disponibilidad de herramientas avanzadas de análisis y visualización democratiza el acceso a la información financiera. No solo los grandes inversionistas, sino también los pequeños inversionistas y el público en general, pueden acceder a análisis de alta calidad. Esta democratización fomenta una mayor participación en los mercados financieros, promoviendo la inclusión financiera y permitiendo que más personas participen en la creación de riqueza y el desarrollo económico.

Incremento en la Inclusión Financiera y el Crecimiento Económico: Al facilitar el acceso a información y herramientas de inversión de calidad, se puede aumentar la participación de individuos y grupos previamente excluidos del mercado de valores. Con una mayor participación, se incrementa la inversión y el ahorro en la economía, lo que impulsa el crecimiento económico y el desarrollo social. Un mayor nivel de inclusión financiera también contribuye a una mayor equidad en las oportunidades económicas y a la creación de un entorno financiero más inclusivo y justo.

Conclusiones y recomendaciones

Conclusiones

El análisis y la aplicación de modelos ARIMA, junto con herramientas avanzadas de visualización como Power BI, han demostrado ser fundamentales para la toma de decisiones en el ámbito financiero. En particular, el modelo ARIMA para Banco Bolivariano se ha destacado por su precisión, con el error cuadrático medio (MSE) más bajo en comparación con otros emisores. Esto indica que el modelo está capturando de manera efectiva la dinámica de las series de tiempo y ofrece predicciones confiables.

Por otro lado, el modelo para Banco del Pichincha presentó un MSE significativamente alto, lo cual sugiere un ajuste deficiente y la necesidad de revisar y posiblemente ajustar el modelo. La revisión reveló que eventos específicos, como la recompra de acciones a valor nominal en agosto y septiembre de 2023, influyeron de manera significativa en los precios. Al ajustar los precios de estos meses a los valores de julio de 2023, el MSE del modelo mejoró en un 90%, aunque sigue siendo considerable, lo que indica que podrían ser necesarios otros enfoques para obtener una mayor precisión.

Las herramientas visuales, como los gráficos de velas, predicciones, volumen, rendimientos y oportunidades de inversión, proporcionan una perspectiva valiosa y detallada sobre el comportamiento de las acciones. Estas visualizaciones permiten identificar tendencias, evaluar la demanda y tomar decisiones estratégicas basadas en datos claros. Por ejemplo, el gráfico de velas para Banco Bolivariano muestra una tendencia alcista con un precio que aún no ha alcanzado su máximo histórico, sugiriendo un potencial de crecimiento. El análisis predictivo y el gráfico de volumen corroboran la tendencia actual y sugieren un buen momento para vender. El gráfico de rendimientos muestra un crecimiento significativo en dos años, indicando que una venta podría ser prudente para evitar la sobrevaloración futura.

Recomendaciones

Validación con Modelos Adicionales: Se recomienda probar otros modelos predictivos, como XGBoost, para comparar y determinar cuál se ajusta mejor a los datos y proporciona predicciones más precisas. La diversificación de modelos puede mejorar la robustez de las predicciones y reducir el riesgo asociado.

Análisis Fundamental Complementario: Es crucial que los inversionistas complementen el análisis técnico con un análisis fundamental exhaustivo. Esto incluye la revisión de noticias económicas, estados financieros, eventos corporativos y otros factores que puedan influir en el comportamiento de las acciones. Un enfoque holístico proporcionará una base más sólida para las decisiones de inversión.

Uso de Herramientas Visuales: Continuar utilizando herramientas de visualización avanzadas como Power BI para realizar análisis detallados y tomar decisiones informadas. Estas herramientas no solo mejoran la comprensión de los datos históricos y predictivos, sino que también permiten una mejor comunicación de las estrategias de inversión.

Acceso y Inclusión Financiera: Promover la democratización del acceso a la información financiera es esencial. Facilitar el acceso a análisis de alta calidad para pequeños inversionistas y el público en general puede aumentar la participación en los mercados financieros, fomentando la inclusión financiera y contribuyendo al crecimiento económico y desarrollo social.

Monitoreo Continuo: Mantener un monitoreo constante de los modelos y ajustar las estrategias según sea necesario. El mercado es dinámico, y los modelos deben ser revisados y actualizados regularmente para reflejar los cambios en las condiciones del mercado y mejorar la precisión de las predicciones.

Implementar estas recomendaciones ayudará a optimizar las estrategias de inversión, minimizar los riesgos y promover un entorno financiero más estable y accesible.

Referencias

- Gómez Rueda, D. M. (2021). *Modelo predictivo del índice bursátil colombiano de deuda pública tasa fija COLTES LP entre enero 2016 y mayo del 2021*.
- Frutos Serrano, S. (2022). *Comparación entre XGBoost y regresión lineal múltiple para la predicción de la evolución del precio de las acciones*.
- Echazarreta de la Mancha, S. A. (2022). *Pronóstico del precio de las acciones*. Universidad Autónoma de Nuevo León.
- Broncano, R. E. (2022). Aplicación de técnicas de machine learning para la predicción de los precios de la acción APPLE. *Revista de Investigación de Sistemas e Informática*, 15(1), 13-22.
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Khan, S., & Alghulaiakh, H. (2020). ARIMA model for accurate time series stocks forecasting. *International Journal of Advanced Computer Science and Applications*, 11(7). <https://doi.org/10.14569/IJACSA.2020.0110706>
- Rubio, L., & Alba, K. (2022). Forecasting selected Colombian shares using a hybrid ARIMA-SVR model. *Mathematics*, 10(13), 2181. <https://doi.org/10.3390/math10132181>
- Chávez Quisbert, N. (1997). Modelos ARIMA. *Revista Ciencia y Cultura*, (1), 23-30.
- Shumway, R. H., & Stoffer, D. S. (2017). *ARIMA models*. In *Time series analysis and its applications: With R examples* (pp. 75-163). Springer.
- De Arce, R., & Mahía, R. (2003). *Modelos ARIMA*. Programa CITUS: Técnicas de Variables Financieras, 5.

Anexo 1.

Script de python

```
import pandas as pd
from statsmodels.tsa.arima.model import ARIMA

# Leer los datos desde un archivo Excel
data = pd.read_excel(r'C:\Users\Asus\Desktop\PERSONAL\ACCIACCIONES BOLSA ECUADOR.xlsx',
sheet_name='Hoja1')

# Nombre del emisor específico
emisor = 'BANCO BOLIVARIANO C.A.'

# Filtrar por emisor específico
data_filtered = data[data['EMISOR'] == emisor]

# Seleccionar columnas relevantes (FECHA y PRECIO)
data_filtered_numeric = data_filtered[['FECHA', 'PRECIO']]

# Convertir FECHA a tipo datetime si no lo está ya
data_filtered_numeric['FECHA'] = pd.to_datetime(data_filtered_numeric['FECHA'])

# Resamplear los datos a frecuencia mensual, tomando el promedio del precio
data_monthly = data_filtered_numeric.resample('M', on='FECHA').mean()

# Rellenar valores faltantes con el último valor observado
data_monthly['PRECIO'] = data_monthly['PRECIO'].fillna(method='ffill')

# Ajuste del modelo ARIMA
modelo = ARIMA(data_monthly['PRECIO'], order=(4, 0, 7)) # Orden (p, d, q)
modelo_fit = modelo.fit()

# Predicción para los próximos n pasos
n_steps = 6 # Predicción para los próximos 6 meses
future_predictions = modelo_fit.forecast(steps=n_steps)

# Crear un índice de fechas para las predicciones futuras
last_date = data_monthly.index[-1] # Última fecha en el dataset
date_range = pd.date_range(start=last_date, periods=n_steps+1, freq='M')[1:] # Genera fechas para los próximos n
pasos

# DataFrame para almacenar las predicciones futuras con nombre del emisor
future_dates = pd.DataFrame({
    'EMISOR': [emisor] * n_steps,
    'FECHA': date_range,
    'PREDICCIONES_FUTURAS': future_predictions
})

# Agregar el nombre del emisor al historial mensual
```

```
data_monthly['EMISOR'] = emisor

# Concatenar historial mensual y predicciones futuras
resultados_finales = pd.concat([data_monthly.reset_index(), future_dates], ignore_index=True)

# Reordenar las columnas para tener EMISOR al principio
resultados_finales = resultados_finales[['EMISOR', 'FECHA', 'PRECIO', 'PREDICCIONES_FUTURAS']]

# Devolver el DataFrame combinado como salida
resultados_finales
```