



**ESTIMACIÓN DEL RETORNO Y RIESGO ESPERADO DE UN *EXCHANGE TRADED FUND*
(*ETF*) APLICANDO MODELOS DE *MACHINE LEARNING* (*ML*).**

**Eduardo
Sagarzazu Astuy**

**Director:
Juan David
Martínez Gordillo**

**Facultad de Economía
Universidad del Rosario**

**Bogotá, Colombia
2022**

Resumen

Los *Exchange Traded-Funds (ETFs)* se han convertido en una de las posibilidades más llamativas para inversores alrededor del mundo. La posibilidad de realizar una sola inversión con el riesgo ya diversificado y la facilidad que presentan los ETFs, ha hecho que el número de estos se haya disparado en el mercado, por lo que la estimación y anticipación de estos activos ha adquirido una gran importancia. En el presente estudio se tiene como objetivo estimar el retorno y riesgo esperado de un ETF integrado por Criptomonedas, Acciones, y Commodities, mediante algoritmos de *Machine Learning (ML)*. Para alcanzar este objetivo, se construyeron tres ETFs con distintos perfiles de riesgo a base de 23 activos (serie de tiempo de su variación porcentual), y a base de la volatilidad de cada uno de ellos. Posteriormente, se realizó la estimación con los modelos *Extreme Gradient Boosting (XGB)*, *Extra Trees (ET)*, *K Neighbor (KNN)*, y *Neural Prophet*. Como resultado, se obtuvo que es posible anticipar que los tres ETFs tienen potencial de crecimiento, y presentan diferentes oportunidades de inversión en cada uno de ellos. Se concluye que la estimación es posible, sin embargo, se deben tener en cuenta distintos modelos para llegar a conclusiones más completas y aplicables.

Palabras Clave: *ETF, Machine Learning, Estimación, Variación Porcentual y Volatilidad.*

Abstract

The *Exchange Traded-Funds (ETFs)* have become one of the most striking possibilities for investors around the world. The possibility of making only one investment that already has the risk diversified and its easiness, has caused the number of ETFs in the market to skyrocket, therefore the estimation and anticipation of these assets has become of great importance. The objective of this study is to estimate the expected risk and return of an ETF with Cryptocurrency, Stocks, and Commodities, by algorithms of *Machine Learning (ML)*. To reach this objective, three different ETFs were created with different risk profiles using the same 23 assets (time series of percentual variation) and using the volatility of each asset. Then, the estimation was done using the models *Extreme Gradient Boosting (XGB)*, *Extra Trees (ET)*, *K Neighbor (KNN)* y *Neural Prophet*. As a result, it is possible to anticipate that all three ETFs have the possibility of growth, and they present different investment opportunities in each of them. In conclusion, the estimation is possible, but it is necessary to consider different models to obtain more complete and applicable conclusions.

Key Words: *ETF, Machine Learning, Estimation, Percentual Variation and Volatility.*

Tabla de Contenido

Resumen	2
Abstract	3
1. Introducción	5
2. Revisión Bibliográfica	6
3. Metodología	9
4. Resultados	14
4.1 Análisis Exploratorio de Datos	14
4.2 Análisis Resultados	17
4.2.1 ETF Menor Riesgo Relativo	17
1. Modelo 1 (Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending)	18
2. Modelo 2 (Extra Trees w/ Cond. Deseasonalize & Detrending)	19
3. Modelo 3 (K Neighbors w/ Cond. Deseasonalize & Detrending)	20
4. Modelo 4 (Neural Prophet)	21
4.2.2 ETF Riesgo Relativo Medio	22
1. Modelo 1 (Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending)	22
2. Modelo 2 (Extra Trees w/ Cond. Deseasonalize & Detrending)	23
3. Modelo 3 (K Neighbors w/ Cond. Deseasonalize & Detrending)	24
4. Modelo 4 (Neural Prophet)	25
4.2.3 ETF Mayor Riesgo Relativo	26
1. Modelo 1 (Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending)	26
2. Modelo 2 (Extra Trees w/ Cond. Deseasonalize & Detrending)	27
3. Modelo 3 (K Neighbors w/ Cond. Deseasonalize & Detrending)	28
4. Modelo Neural Prophet	29
5. Contribución	30
6. Conclusiones	30
7. Referencias	32
8. Anexos	34

1. Introducción

En un mundo de constante cambio, es necesario mantenerse al tanto y reconocer aquellas cosas que llegan para quedarse. Una de las cosas que llegó para quedarse fueron los ETFs, pues se convirtieron en una herramienta revolucionaria para las inversiones en el mundo (Norrestad, 2022). Los ETFs logran que cualquier persona sin mucho conocimiento de los mercados de capitales, realicen inversiones con un análisis de riesgo claro y preciso.

Otro de los acontecimientos que ha irrumpido en la sociedad son las criptomonedas. A pesar del poco conocimiento que se tiene de su inicio, se han convertido en uno de los activos de mayor interés para inversionistas en todo el mundo (de Best, 2022). Las criptomonedas facilitaron prescindir del intermediario de muchas transacciones financieras, además de crear un ecosistema de confianza donde las transacciones son seguras, inmediatas y anónimas. Dada la importancia que han tomado estos elementos en la cotidianidad de los mercados de capitales, se han realizado distintas investigaciones para aplicar más herramientas a estos cambios y así poder obtener un mayor provecho de estos.

Las investigaciones han tenido un rango de aspectos para explorar, sin embargo, para la realización de la investigación actual se tiene como centro aquellas que utilizan para su desarrollo mecanismos de ML. Los investigadores utilizan estos mecanismos con el objetivo de anticipar el comportamiento de los activos financieros y lo hacen con distintas variables objetivo como el precio, la volatilidad, el cambio porcentual, entre otros. Desde los primeros años de la década pasada, la aplicación de algoritmos matemáticos complejos se usaba para entender y anticipar el movimiento de los activos financieros.

No obstante, las investigaciones han dejado distintos vacíos por explorar, por ejemplo: Las investigaciones se han centrado en predecir el precio, más no se ha buscado predecir variables como el retorno o el riesgo, del mismo modo, las investigaciones han permanecido en el mismo grupo de activos, ninguna investigación ha intentado hacer la predicción de un

conjunto de activos que asimile el portafolio de un inversor privado o un ETF como nueva herramienta de inversión.

En este contexto surge la siguiente pregunta de investigación ¿Hasta qué punto el retorno y el riesgo esperado de un ETF creado con acciones, commodities y criptomonedas es estimable aplicando modelos de *Machine Learning* (ML)?

2. Revisión Bibliográfica

Deep Learning fue uno de los primeros mecanismos a los que se recurrió para esta tarea. Asimismo, en el 2016 Mows publicaba sus descubrimientos utilizando Deep Learning para la predicción de los precios del mercado de valores (Mows, 2016). Mostró que era posible la predicción de precios luego de enseñar al algoritmo con la serie de tiempo. De esa manera, también comprobó que la hipótesis de mercado aleatorio y del mercado eficiente no se cumplen en el mercado de capitales. Un año más tarde, el equipo liderado por Ramakrishnan (Ramakrishnan, Butt, Chohan, & Ahmad, 2017) utilizó mecanismos parecidos para demostrar que la tasa de cambio de Malasia podía ser anticipada con el comportamiento de cuatro commodities de producción nacional, demostrando con esto, que la herramienta es capaz de solventar discusiones complejas con buenos resultados.

Posteriormente, un grupo de investigadores en la ciudad Londres (Alessandretti, Elbahrawy, Luca, & Baronchelli, 2018), probó que era posible hacer ganancias anormales en el mercado de criptomonedas con estrategias simples de inversión asistidas por el modelo XGBoost y redes de memoria. Mientras que Rose, (Rose, 2018) diseñaba un bot que le permitía hacer operaciones automatizadas en el mercado de capitales, prediciendo el comportamiento de los activos en distintas temporalidades (corto, medio y largo plazo). Snihovyi, Ivanov y Kobets, (Snihovyi, Ivanov, & Kobets, 2018) sostienen que, si determinan las distintas razones por la que los precios cambiaron en el pasado pueden anticipar el comportamiento de los precios en el futuro usando distintos mecanismos de Machine Learning

como corto-largo plazo de redes de memoria, múltiples regresiones lineales y bosques aleatorios.

El artículo de Franco Valencia, Alfonso Gómez y Benjamín Valdés (Valencia, Gómez-Espinosa, & Valdés-Aguirre, 2019) se convierte rápidamente en el estándar de la predicción de precios de criptomonedas. A base de algoritmos estándar de Machine Learning (redes neuronales, bosques aleatorios y vectores de soporte) realizan un análisis de sentimiento sobre distintas criptomonedas, para poder concluir que con el uso de data de Twitter se pueden hacer predicciones sobre el precio de lo que en su momento fueron el Top 4 de criptomonedas por volumen. Los investigadores liderados por Raez Chowdhury, (Chowdhury, Rahmanb, Rahmanc, & Mahdy, 2020) introdujeron los índices. Debido a la alta volatilidad de las criptomonedas, mantuvieron que sería más práctico hacer la predicción sobre un índice compuesto por las criptomonedas y no sobre cada criptomoneda por separado. A diferencia de los anteriores, Derbentsev y su grupo (Derbentsev, Matviychuk, & Soloviev, 2020), notaron que había un campo que nadie se había detenido a estudiar: predicciones en temporalidad mucho más corta (menores a 90 días), para luego hacer un análisis de “qué tan atractivo” era invertir en cada criptomoneda. Hitman e Ismaili (Hitam & Ismail, 2020) dieron un poco de orden a todas las investigaciones e hicieron un ranking de cuál era el algoritmo de redes neuronales artificiales que daba mejores resultados en la predicción de precios de las criptomonedas.

Buscando ampliar las posibilidades de investigación, Teddy Koker y Dimitrios Koutmos (Koker & Koutmos, 2020) demuestran los beneficios que hay en Buy-and-Hold (mantener una posición por un plazo largo, sin importar las fluctuaciones de corto plazo) de las criptomonedas debido a que los riesgos se disminuyen y concluyen que puede ser aplicable al manejo de un portafolio, sin embargo, el rendimiento variará con respecto al entrenamiento del algoritmo. Mittal, Arora y Bhatia (Mittal, Arora, & Bhatia, 2020) fueron un paso más allá y automatizaron el

proceso de aprendizaje de los modelos, para un aprendizaje más dinámico de los comportamientos. Fue la publicación del artículo de Bekiros y Lahmiri (Bekiros & Lahmiri, 2021) lo que volvió a sacudir las investigaciones, ya que cambiaron el método de predicción usando redes neuronales innovadoras para el aprendizaje y predicción de los precios de las criptomonedas.

Godinho y Sebastiao (Godinho & Sebastiao, 2021) agregaron más variables, argumentando que el mercado está pasando un proceso cambiante y que los modelos deberían tener eso en cuenta a la hora de hacer sus predicciones. La investigación liderada por Patrick Jaquart (Jaquart, Dann, & Weinhardt, 2021) volvió a demostrar que la temporalidad de la serie cambia los resultados. Haciendo predicciones en el rango de 1 a los 60 minutos, se muestra que las ganancias de una estrategia de inversión de tan corto plazo no generan los retornos esperados por el gran costo de transacciones. Finalmente, Ming Chen, Ur Rehman y Vinh Vo (Ming Chen, Ur Rehman, & Vinh Vo, 2021) se dieron cuenta que estos mecanismos pueden ser implementados en otros activos financieros como los commodities y los resultados son bastantes favorables.

Por otro lado, algunos investigadores tomaron una ruta un poco más teórica donde contribuyeron con ideas innovadoras como el uso de herramientas más nuevas y experimentales para la predicción del comportamiento de variables económicas y financieras. Ese es el caso de la compilación de ensayos que hizo Lawani o Reforgaito, Conosli y Saisana donde argumentan todas las aplicaciones que tiene la Data Science en el mundo de la economía y las finanzas. Sabry lideró al grupo de investigadores que listaron los retos, pero también las oportunidades que tiene aplicarle Inteligencia Artificial a las criptomonedas.

Se sintetiza lo anterior y se tiene que, a lo largo de estos 6 años, la cantidad de investigaciones que utilizan las herramientas que brinda Machine Learning (ML) para las predicciones de distintas variables económicas y financieras ha aumentado. Además, se tiene

que todas las investigaciones comprueban la viabilidad de los resultados que se obtienen al implementar la herramienta.

3. Metodología

1. Selección de activos

Para la elección de los activos se tiene como parámetro principal, importancia en el mercado. En las acciones se escogen a líderes de sus respectivos sectores (Alphabet, Amazon, Apple, Bank of America, Goldman Sachs, Hyatt, JP Morgan Chase, Microsoft, Nike y Visa) en los *commodities* se seleccionan cinco (Maíz, Petróleo WTI, Oro, Gas Natural y Trigo) de las materias primas más importantes por volumen de comercialización e importancia de sus precios para la economía mundial y las criptomonedas son aquellas que presentaron la mayor capitalización del mercado para el 31 de diciembre de 2021 (Cardano, Bitcoin, Dogecoin, Ethereum, Solana, Tether y XRP).

Durante la selección de activos se consideró incluir activos de menor riesgo como son los bonos. No obstante, incluir activos de tan bajo riesgo ocasiona que la importancia de las criptomonedas se vea muy disminuida, y dado que, uno de los aspectos innovadores de la investigación es la inclusión de las criptomonedas esto sería contraproducente.

2. Construcción de series de tiempo (Precios altos y bajos)

Se construyeron las series de tiempo de los 23 activos, recopilando las series de tiempo desde el 1 de enero de 2015 (1/1/2015) hasta el 31 de diciembre de 2021 (31/12/2021), con ayuda de herramientas Bloomberg (Bloomberg, 2022) (*commodities* y acciones) y Messari (Crypto Research, Data & Tools, 2022) (criptomonedas). Se toma este período de tiempo debido a que, antes del 2015 la información de criptomonedas es muy escasa, pues, solo 3 de ellas existían previamente.

3. Cálculo de precio promedio diario

Teniendo el precio más alto y el más bajo del día, se suman ambos y se dividen por dos para obtener el precio promedio del día del activo.

4. Cálculo de variación porcentual diario de cada activo

Se utiliza el precio promedio de cada activo y se calcula el delta de cada uno de ellos con la formula $\Delta = \frac{P_{Día\ 2} - P_{Día\ 1}}{P_{Día\ 1}}$. De esta manera, se tiene una serie de tiempo con la variación porcentual diaria por activo.

5. Volatilidad promedio de cada activo y clasificación por nivel de riesgo.

Para calcular el riesgo que representa la inversión en cada uno de estos activos, se utiliza la Volatilidad, por eso se toma la volatilidad de los 30, 60, 90, 120 y 180 días de cada uno de los activos. Se calcula el promedio de volatilidad de cada uno de los activos, sumando cada una de las volatilidades y dividiéndolo en cinco.

Se ordenan los activos por su calificación de riesgo, del menos riesgoso al más riesgoso.

6. Agrupación en tres bloques: bajo, medio y alto riesgo

Al tener los activos clasificados por su riesgo, se dividen estos en tres grupos. El primer grupo consiste en los 7 activos menos riesgosos; el segundo grupo consiste de los 8 activos que siguen en la clasificación y finalmente los 7 activos más riesgosos son agrupados en el tercer grupo.

7. Ponderación

A cada grupo se le asigna un peso específico dependiendo del perfil de riesgo de cada uno, basado en una tabla de construcción de inversiones dependiendo del perfil de riesgo recuperada de Australian Unity (Australian Unity Real Wellbeing, 2021). A partir de esto se obtiene la siguiente tabla:

Clasificación de riesgo	ETFs		
	Menor Riesgo Relativo	Riesgo Medio Relativo	Mayor Riesgo Relativo
R B I A E J S O G O	54%	32%	21%
R I E M E D I S G O	24%	37%	34%
R A I L E T S O G O	22%	31%	45%

8. Construcción de los ETF

Se construyen tres ETFs con distintos perfiles de riesgo, dando distintos pesos a los grupos dependiendo el perfil de riesgo del ETF. El primer ETF tiene el perfil de riesgo más bajo relativo (ETF Menor Riesgo Relativo). El segundo ETF tiene el perfil de riesgo medio relativo (ETF Riesgo Medio Relativo). El tercer ETF tiene el perfil de riesgo más alto relativo (ETF Mayor Riesgo Relativo).

Activos	Clasificación de riesgo	ETFs		
		Menor Riesgo Relativo	Riesgo Medio Relativo	Mayor Riesgo Relativo
Tether	R B A J O G O	7.71%	4.57%	3.00%
GC1 Comdt		7.71%	4.57%	3.00%
CL1 Comdt		7.71%	4.57%	3.00%
NKE US Equity		7.71%	4.57%	3.00%
JPM US Equity		7.71%	4.57%	3.00%
AAPL US Equity		7.71%	4.57%	3.00%
BAC US Equity		7.71%	4.57%	3.00%
GS US Equity	R I E S G O	3.00%	4.63%	4.25%
V US Equity		3.00%	4.63%	4.25%
MSFT US Equity		3.00%	4.63%	4.25%
GOOGL US Equity		3.00%	4.63%	4.25%
C 1 COMB Comdt		3.00%	4.63%	4.25%
AMZN US Equity		3.00%	4.63%	4.25%
H US Equity		3.00%	4.63%	4.25%
W 1 Comdt	R A I L E T S O G O	3.00%	4.63%	4.25%
Bitcoin		3.14%	4.43%	6.43%
NG1 Comdt		3.14%	4.43%	6.43%
Ethereum		3.14%	4.43%	6.43%
XRP		3.14%	4.43%	6.43%
Dogecoin		3.14%	4.43%	6.43%
Cardano		3.14%	4.43%	6.43%
Solana		3.14%	4.43%	6.43%

9. Modelos

Se utilizarán cuatro modelos de anticipación para la solución de la investigación. Los primeros tres se ejecutan a través de la herramienta de PyCaret, mientras que el último modelo es una herramienta desarrollada por Facebook para la anticipación de series de tiempo con modelos neuronales.

El primer modelo, Extreme Gradient Boost es un modelo que implementa arboles de decisión con la capacidad de paralelización y distribución de computación que permite la solución al problema de sobreajuste, pero aun así sufre un poco con los datos atípicos.

El segundo modelo, Extra Trees es un modelo que implementa árboles de decisión, que antes de ejecutar la ramificación toma una partición de los datos para hacer un estudio breve que determina si la ramificación es adecuada o no. Lo que resulta en una variación más pequeña que otros modelos de árboles de decisión, aunque toma más tiempo y poder computacional para la ejecución.

El tercer modelo, K Nearest Neighbors es un modelo que asume que existen datos parecidos en la vecindad de un dato específico, tomando la idea de similaridad ofrece resultados con bajos márgenes de error. Es un modelo que tiene versatilidad y buenos resultados, que se ve afectado cuando el número de datos aumenta.

El cuarto modelo, Neural Prophet es un modelo que implementa redes neuronales para la anticipación de series de tiempo complejas, comparado con otros modelos de características similares es más sencillo y de confianza que otros, aunque es un modelo que todavía está en desarrollo.

Para los cuatro modelos se tomarán los errores con respecto al Out-Sample (se toma el set de datos y se divide en dos, con un grupo se entrena al algoritmo, y con el otro, se pone a prueba y se le miden los errores con respecto al de prueba y no al de entrenamiento) de esta forma, el algoritmo está siendo evaluado con data que no ha visto anteriormente, por ende, no hay ningún tipo de sesgo en la medición predictiva de los modelos.


10. Ejecución

Se toma cada uno de los ETFs y se realizan los modelos que anticipan la variación porcentual diaria de los ETF en un período de 180 días en el futuro.


4. Resultados

4.1 Análisis Exploratorio de Datos

Para entender mejor los activos que componen los ETFs, se mira más de cerca la composición y el comportamiento que tiene cada uno de ellos por separado. Para tener una idea más clara, primero se mira el histograma de cada uno de los activos.



En cada uno de los histogramas se ve cómo la variación porcentual diaria está con centro 0 en todos los casos, sin embargo, mientras que para casi todos los *commodities* y acciones el total de los datos se encuentran en un intervalo cercano a más o menos el 0.15, en las criptomonedas se ven unos intervalos muchos más grandes, lo que va de la mano con los resultados de la volatilidad, exponiendo las criptomonedas como los activos más riesgosos. Se sigue con una tabla de correlaciones de los distintos activos.



Como se puede observar en la tabla anterior, la correlación entre los distintos activos varía bastante entre unos y otros. A excepción del grupo de los commodities también se puede ver con claridad que entre activos de la misma clase siempre hay una mayor correlación. En los commodities se destaca la correlación negativa que tienen con el oro, en la mayoría de los casos, confirmando así que es un activo refugio, por lo que se comporta de manera contraria a


los demás. En las acciones la correlación más baja es de 0.2 (entre Hyatt y Amazon) y la más alta es de 0.9 (entre JP Morgan Chase y Bank of America), también se debe destacar que Visa es la compañía con una correlación promedio más alta. En las criptomonedas el panorama es muy parecido al esperado. Bitcoin es líder del mercado y la mayoría sigue el comportamiento de esta; de igual manera sorprende ver que Cardano y Solana son las que más alejadas están del grupo con correlaciones contra Bitcoin de 0.21 y 0.22, respectivamente, y sorprende aún más que la correlación entre Cardano y Solana es del 0.61.

Ahora que se tiene una comprensión más extensa de la composición y el comportamiento de cada uno de los activos, se continúa con los resultados obtenidos luego de realizar la investigación.


4.2 Análisis Resultados

4.2.1 ETF Menor Riesgo Relativo

Compuesto por un 54% de activos bajo riesgo, 24% de activos medio riesgo y 22% de activos de riesgo alto. Se hace un breve análisis exploratorio del ETF; el histograma cumple una distribución con características similares a la de los activos individuales.




1. Modelo 1 (Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending)




Se anticipa que el ETF va a tener una variación porcentual diaria muy estable con unos cambios menores al dos por ciento. Asimismo, se anticipa que el ETF va a permanecer constante, cercano al cero por ciento, durante el período. Aun así, se puede ver que durante el período de estudio hay unas oportunidades que pueden estudiarse más a detalle para obtener ganancias de las inversiones, como, por ejemplo: el crecimiento en el mes de marzo (18 a 21 de marzo) o el del mes de abril (12 a 14 de abril). Por otro lado, se tiene que el modelo tiene un Mean Absolute Error (MAE) de 0.0066 y un Root Mean Square Deviation (RMSE) de 0.0086, por lo que a la hora de aplicar los resultados obtenidos es necesario complementar el modelo con más información para minimizar aún más el error.

2. Modelo 2 (Extra Trees w/ Cond. Deseasonalize & Detrending)




El modelo anticipa que el ETF va a tener una variación porcentual diaria menor al uno por ciento durante el período de estudio. En el modelo se pueden ver algunas tendencias que toma el ETF durante el período, una tendencia bajista desde mediados de mayo. Además, anticipa que por la mayor parte del tiempo el ETF va a tener un comportamiento negativo. No se puede ver con claridad oportunidades que se puedan aprovechar para obtener rendimiento de inversiones en el ETF. Adicionalmente, el modelo tiene MAE de 0.0067 y RMSE de 0.0086 por lo que es necesario que se tenga mayor precaución a la hora de tomar decisiones en base de este modelo.

3. Modelo 3 (K Neighbors w/ Cond. Deseasonalize & Detrending)



En el modelo se anticipan unos movimientos muy agresivos entre un día y el siguiente, aunque la variación diaria nunca es mayor al diez por ciento, si se ven muchas oportunidades de inversión que pueden ser explotadas al principio de cada mes, por lo que se puede decir que el modelo anticipa una periodicidad en el ETF. No obstante, el modelo anticipa que el valor del ETF cumple con una tendencia estable, donde no se puede concluir si este aumenta o disminuye en una inversión de un plazo más largo. Además, el modelo tiene MAE de 0.0068 y RMSE de 0.0089 que para las anticipaciones del modelo podrían ser de los crecimientos y caídas más grandes o podrían minimizar las fluctuaciones y disminuir las oportunidades de inversión.


4. Modelo 4 (Neural Prophet)



El modelo anticipa que el ETF va a tener solo crecimiento durante el período de estudio, anticipa variaciones porcentuales solo positivas, la mayor siendo cercana al diez por ciento. El modelo anticipa unas tendencias claras, se tiene una tendencia alcista en enero, en marzo y en mayo; unas tendencias bajistas en febrero, abril y en junio. Aunque en el día a día hay muchas oportunidades de inversión que se podrían aprovechar, estas tendencias presentan mejores oportunidades, al ser un crecimiento por un período más largo de tiempo. Asimismo, el modelo tiene MAE de 0.0080 y RMSE de 0.0094 que para las fluctuaciones que anticipa el modelo puede que las tendencias tengan mayores beneficios de lo esperado, por lo que acompañar el modelo de otros estudios ayuda a sacar mejores conclusiones de este.


4.2.2 ETF Riesgo Relativo Medio

Compuesto en un 32% de activos bajo riesgo, 37% de activos medio riesgo y 31% de activos en riesgo alto. Del análisis exploratorio del ETF se obtiene que el histograma tiene su centro cero y un rango de más o menos 0.1, no obstante, este ETF presenta una cantidad un poco más grande de datos atípicos.



1. Modelo 1 (Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending)


Actual vs. 'Out-of-Sample' Forecast



El modelo hace las anticipaciones y muestra que el ETF va a tener un cambio porcentual diario que nunca supera el diez por ciento, anticipa que el ETF no va a tener ninguna tendencia muy marcada, pero sí que va a tener bastantes oportunidades que pueden ser aprovechadas


para obtener mejores retornos que en otras inversiones. Se puede esperar que el ETF le otorgue al inversor la oportunidad de tener rendimientos en períodos de tiempo corto, ya que se ve que las subidas se ven seguidas de bajadas muy veloces. Además, el modelo tiene *MAE* de 0.0081 y *RMSE* de 0.0107 por lo que las oportunidades de inversión marcadas anteriormente, deben ser revisadas con mayor cuidado.

2. Modelo 2 (Extra Trees w/ Cond. Deseasonalize & Detrending)




El modelo anticipa que el ETF va a tener un comportamiento cíclico, donde el cambio porcentual positivo, va a significar un cambio porcentual en sentido contrario, haciendo que el ETF tenga una tendencia estable, por lo que una inversión de un período más grande no va a tener un retorno muy alto. Del mismo modo, el modelo anticipa que no se van a presentar muchas oportunidades para hacer inversiones que no sean de una temporalidad muy baja. Adicionalmente, el modelo tiene *MAE* de 0.0082 y *RMSE* de 0.0102 que pueden hacer que el ETF se comporte de una manera distinta a la anticipada, haciendo que sea necesario una revisión de otros factores.

3. Modelo 3 (K Neighbors w/ Cond. Deseasonalize & Detrending)



El ETF, de acuerdo con este modelo va a presentar demasiadas oportunidades de inversión de corto plazo que resultaran rentables, se ven altas caídas y bajadas en espacios de tiempo muy corto que permitirán hacer varias inversiones que resultaran en unas ganancias para el inversor. No obstante, el modelo anticipa que los cambios porcentuales no van a ser superiores al cinco por ciento en ningún momento durante el período de estudio. Además, el modelo tiene MAE de 0.0081 y RMSE de 0.0105 que, dada la anticipación que estima el modelo agrega un mayor riesgo a tomar una decisión de inversión basada únicamente en la estimación de este modelo particular.


4. Modelo 4 (Neural Prophet)



Neural Prophet anticipa que el ETF va a tener variaciones positivas durante todo el período de estudio, anticipa que va a tener unas tendencias muy marcadas que culminan en una estabilización cercana al diez por ciento. Se ve una tendencia alcista muy marcada en enero y marzo, una tendencia bajista en febrero y en abril y una tendencia estable de mayo para adelante. Asimismo, el modelo anticipa que el ETF va a tener un crecimiento de hasta el 16% en su punto más alto. Para complementar lo anterior, el modelo tiene un MAE de 0.0096 y un RMSE de 0.0109 lo que puede impulsar las tendencias que anticipa el modelo o puede contrarrestar el movimiento de esta, haciendo que las inversiones no sean igual de llamativas.


4.2.3 ETF Mayor Riesgo Relativo

Compuesto en un 21% de activos bajo riesgo, 34% de activos medio riesgo y 45% de activos de riesgo alto. Haciendo un análisis exploratorio del ETF se tiene que el histograma tiene su centro cero y un rango de más o menos 0.1.



1. Modelo 1 (Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending)


Actual vs. 'Out-of-Sample' Forecast



El *Extreme Gradient Boosting* anticipa que el ETF, del que se esperan más altos rendimientos, va a presentar un límite de crecimiento superior del diez por ciento y un límite inferior de tan solo el cinco por ciento, por lo que se puede decir que el ETF va a tener mayores crecimientos que decrecimientos durante el período de estudio. No se


pueden observar tendencias durante los 180 días de estudio, sin embargo, si se ven oportunidades que pueden ser aprovechadas en períodos de inversión más cortos, no obstante, también hay que tener en cuenta que hay que anticipar caídas muy rápidas después de cualquier subida por lo que hay que saber cuándo salirse. Adicionalmente, el modelo tiene el MAE de 0.0104 y el RMSE de 0.0128 que debido a las anticipaciones que hace el modelo, generan un riesgo para tomarlo como referencia única en un proceso de decisión.

2. Modelo 2 (Extra Trees w/ Cond. Deseasonalize & Detrending)




El modelo anticipa que el ETF va a tener un comportamiento muy distintivo a comparación de los demás, pues anticipa que el modelo nunca va a tener variaciones negativas, teniendo como límite inferior el cero. No obstante, tampoco se ven oportunidades de inversión muy significativas, ya que el ETF se va a tomar unos días creciendo, pero nunca superior al siete por ciento y luego se va a tomar unos días cayendo para luego, con una temporalidad distinta, repetir los movimientos. De igual manera, el modelo tiene 0.0105 de MAE y 0.0129 de RMSE, por lo que no se puede concluir con seguridad que el ETF vaya a presentar la estabilidad estimada por el modelo inicialmente.

3. Modelo 3 (K Neighbors w/ Cond. Deseasonalize & Detrending)



Se anticipa que el ETF va a tener varias oportunidades de inversión tanto en un corto plazo (diario) como también unas pequeñas tendencias que abren oportunidades de inversión en medio plazo (semanas). Se puede ver esa pequeña tendencia desde finales de abril hasta inicios-mediados de mayo, donde también hay crecimientos diarios significativos, teniendo el más alto en ese período de tiempo (cercano al diez por ciento). El modelo anticipa que con un poco más de estudio se pueden explorar y explotar oportunidades de inversión con rendimientos llamativos. Sin embargo, el modelo tiene un MAE de 0.0108 y RMSE de 0.0135 por lo que las oportunidades que anticipa el modelo pueden ser aún más llamativas para posibles inversores o no tan llamativas como se estimaba.

4. Modelo Neural Prophet



El modelo anticipa que el mayor crecimiento del ETF se dio en febrero y que entre marzo y abril se iba a dar su segundo crecimiento, aunque se puede ver un inicio de crecimiento a finales de junio. Por otro lado, anticipa que en febrero se iba a tener una caída muy significativa y que luego, desde inicios de abril hasta mediados de junio se va a tener una tendencia bajista muy clara. Por lo que se puede decir que el modelo anticipa que no es sensato hacer inversiones en este ETF durante esta temporalidad, a no ser que sea una inversión Short del ETF, aprovechando así la oportunidad que anticipa el modelo. Así mismo, el modelo tiene un MAE de 0.012 y RMSE de 0.0139, haciendo necesario la ayuda de otros estudios y argumentos para la realización de una inversión con un riesgo aún menor.

5. Contribución

Teniendo en cuenta los resultados obtenidos de la investigación se puede argumentar que el presente trabajo de investigación contribuye al estado del arte, presentando una idea innovadora que toma en cuenta distintas herramientas para acercarse a los retos que enfrentan aquellos no familiarizados con las inversiones.

Propone una solución al riesgo de volatilidad que tienen las criptomonedas para convertirlas en inversiones más atractivas para los adversos al riesgo. Enseña la viabilidad de utilizar mecanismos de Machine Learning (ML) para anticipar el comportamiento de ETFs y distintos activos financieros para una inversión más segura.

6. Conclusiones

Teniendo en cuenta lo anterior, se puede concluir que cuando se utilizan los mismos modelos sin importar el ETF hay unos comportamientos parecidos que son referentes al modelo específico. De la misma manera, se tiene que cada uno de los ETFs presenta unas ventajas y desventajas específicas en cada uno de ellos. Debido a la composición de los ETFs se sabe cuál de ellos es más riesgoso por lo que también se puede entender sobre cuál de las anticipaciones hay que tener más cuidado.

Para el ETF Menor Riesgo Relativo se tiene que los resultados presentan un crecimiento muy pequeño en variaciones porcentuales diarias, aunque en los diferentes modelos también presenta un comportamiento más estable. Mientras que para el ETF Riesgo Medio Relativo se tienen resultados que son más llamativos-, si bien presentan unas volatilidades más grandes de lo que se podría esperar para el perfil de riesgo, también presenta un crecimiento más grande del esperado. Finalmente, en el ETF Mayor Riesgo Relativo no se ve la volatilidad que se esperaría y se observan unos rendimientos menores a los esperados para el riesgo que tiene la composición del activo.

De igual manera, los resultados muestran que para el ETF Menor Riesgo Relativo el modelo Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending tiene la mayor precisión, con un retorno esperado cercano al 1% y con un riesgo esperado de 0.0086. Por otro lado, para el ETF Riesgo Relativo Medio el modelo Extra Trees w/ Cond. Deseasonalize & Detrending tiene la mayor precisión, con un retorno esperado cercano al 2.5% y con un riesgo

esperado de 0.0102. Por último, para el ETF Mayor Riesgo Relativo el modelo Extreme Gradient Boosting w/ Cond. Deseasonalize & Detrending tiene la mayor precisión, con un retorno esperado cercano al 5% y con un riesgo esperado de 0.0128.

Se llega a la conclusión de que es posible hacer la estimación del retorno y riesgo esperado de un ETF con mecanismos de *Machine Learning (ML)*, no obstante, para que los resultados tengan mayor validación y confianza es necesario que se utilicen distintos mecanismos y no uno particular, ya que los resultados entre uno y otro varían mucho. Se recomienda que se tomen en cuenta distintos modelos de estimación y que se acompañen los resultados obtenidos del ejercicio, con otros métodos más tradicionales a la hora de realizar la inversión.

De igual manera, se concluye que es necesario aclarar que los resultados obtenidos de esta investigación no deben ser tomados en ningún momento como consejos o instrucciones para la realización de inversiones, si no que los mecanismos y herramientas de *Machine Learning (ML)* dan un nuevo método de estudio de inversiones que vale la pena ser implementado con mayor regularidad a la hora de hacer estudios de inversión.

7. Referencias

- Abraham, S. (2021, Enero 1). *Investopedia*. Retrieved from Investopedia:
<https://www.investopedia.com/articles/investing/040115/how-create-your-very-own-etf.asp>
- Alake, R. (2021, Mayo 5). *Towards Data Science*. Retrieved from Towards Data Science:
<https://towardsdatascience.com/machine-learning-in-the-world-of-blockchain-and-cryptocurrency-68651ebaecd7>
- Alessandretti, L., Elbahrawy, A., Luca, M., y Baronchelli, A. (2018). Anticipating Cryptocurrency prices using Machine Learning. *Complexity*, 1-16.

- Australian Unity Real Wellbeing. (2021). *What is the risk/return profile of your portfolio?* Australian Unity.
- Bekiros, S., y Lahmiri, S. (2021). Deep Learning Forecasting in Cryptocurrency High-Frequency Trading. *Cognitive Computation*, 485-487.
- Bloomberg. (2022). *Bloomberg Anywhere*. Retrieved from Bloomberg Terminal:
https://bba.bloomberg.net/?utm_source=bloomberg-menu&utm_medium=help2019
- Chowdhury, R., Rahmanb, M. A., Rahmanc, M. S., y Mahdy, M. (2020). *An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning*. Dhaka: Physica A: Statistical Mechanics and its Applications.
- Crypto Research, Data y Tools. (2022). Messari. Retrieved from Messari.io: <https://messari.io/>
- de Best, R. (2022, Marzo 7). Statista. Retrieved from Statista Statics:
<https://www.statista.com/statistics/730876/cryptocurrency-maket-value/>
- Derbentsev, V., Matviychuk, A., y Soloviev, V. (2020). Forecasting of Cryptocurrency Prices Using Machine Learning. In C. E. Lukáš Pichl, *Advanced Studies of Financial Technologies and Cryptocurrency Markets* (pp. 211-231). Singapore: Springer.
- Facebook. (2022). *Neural Prophet*. Retrieved from Neural Prophet Forecasting:
<https://neuralprophet.com/html/contents.html>
- Godinho, P., y Sebastiao, H. (2021). Forecasting and trading cryptocurrencies with machine learning under changing market conditions. *Financial Innovation*, Article number 3.
- Hitam, N. A., y Ismail, A. R. (2020). *Comparative Performance of Machine Learning Algorithms for Cryptocurrency Forecasting*. Kuala Lumpur: International Islamic Univerity Malaysia.
- Jaquart, P., Dann, D., y Weinhardt, C. (2021). Short-term bitocin market prediction via Machine Learning. *The Journal of Finance and Data Science*, 45-66.
- Just ETF. (2021, Marzo 21). *Just ETF*. Retrieved from Just ETF:
<https://www.justetf.com/en/how-to/invest-in-crypto.html>
- Koker, T., y Koutmos, D. (2020). *Cryptocurrency Trading using Machine Learning*. Worcester: Journal Risk and Financial Management.
- Koval, M. (2021, Abril 5). *Analytics Vidhya*. Retrieved from Data Science Blogathon:
<https://www.analyticsvidhya.com/blog/2021/04/how-ai-is-used-in-the-cryptocurrency-mar ket/>
- Lawani, A. (2018). *Three essays on the application of the Machine Learning methods in Economics*. Kentucky: University of Kentucky.
- Ming Chen, J., Ur Rehman, M., y Vinh Vo, X. (2021). Clustering commodity markets in space and time: Clarifying returns, volatility, and trading regimes through unsupervised machine learning. *Resources Policy*, Volume 73, ISSN 0301-4207.
- Mittal, R., Arora, S., y Bhatia, M. (2020). Automated Cryptocurrencies prices prediction using Machine Learning. *International Journal of Semantic Computer*, 1758-1761.

- Mows, B. (2016). *Deep Learning for Stock Market Prediction: Exploiting Time-Shifted Correlations of Stock Price Gradients*. Edinburgh: University of Edinburgh.
- Norrestad, F. (2022, Enero 11). *Statista*. Retrieved from Statista Statics: <https://www.statista.com/statistics/350525/number-etfs-usa/#:~:text=In%202020%2C%20there%20were%20%2C204%20ETFs%20in%20the%20United%20States.>
- Norris, E. (2021, Enero 8). *Investopedia*. Retrieved from Investopedia: <https://www.investopedia.com/articles/exchangetradedfunds/11/building-an-etf-portfolio.asp>
- PyCaret. (2022). *PyCaret*. Retrieved from PyCaret: <https://pycaret.org/>
- Ramakrishnan, S., Butt, S., Chohan, M., y Ahmad, H. (2017). Forecasting Malaysian exchange rate using machine learning techniques based on commodities prices. *International Conference on Research and Innovation in Information Systems (ICRIIS)*, 1-5.
- Reforgaito, D., Conosli, S., y Saisana, M. (2020). *Data Science for Economics and Finance*. Ispra: Springer.
- Rose, L. (2018). *Automated Stock Market using Machine Learning*.
- Sabry, F., Labda, W., Erbad, A., y Malluhi, Q. (2020). Cryptocurrencies and Artificial Intelligence: Challenges and Opportunities. *IEEE Access*, 175840-175858.
- Saldana, M. (2021, Mayo 20). *Medium*. Retrieved from Medium CoinMonks: <https://medium.com/coinmonks/predicting-cryptocurrency-markets-with-machine-learning-474a2f4f5da3>
- Sealfon, R. (2021, Agosto 10). *Medium*. Retrieved from Medium CoinMonks: <https://medium.com/morphware/how-useful-is-machine-learning-in-cryptocurrency-trading-dc31164aaf5b>
- Snihovyi, O., Ivanov, O., y Kobets, V. (2018). Cryptocurrencies Prices Forecasting With Anaconda. *ICT in Education, Research and Industrial Applications*, 453-456.
- Valencia, F., Gómez-Espinosa, A., y Valdés-Aguirre, B. (2019). Price Movement Prediction of Cryptocurrencies Using Sentiment Analysis and Machine Learning. *Entropy*, 589.

8. Anexos

Anexo 1:

Conservative portfolio



Balanced portfolio



Fact sheet What is the risk/return profile of your portfolio?

Growth portfolio







Tabla de *Australian Unity* con la que se construyeron los ETFs.

Anexo 2:


Serie de tiempo de los 3 ETFs.

Anexo 3:

Gráficos diagnósticos del ETF Menor Riesgo Relativo.

Anexo 4:

Gráficos diagnósticos del ETF Riesgo Medio Relativo.

Anexo 5:

Gráficos diagnósticos del ETF Mayor Riesgo Relativo.

Anexo 6:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0036	0.0039	0.9041	1.0716	0.3306	-0.0223
1	2021-10-22	0.0058	0.0069	1.4502	1.5328	0.5358	-0.1916
2	2021-10-29	0.0039	0.0046	1.3959	1.5280	0.3608	-1.2541
3	2021-11-05	0.0052	0.0065	1.2326	1.5142	0.4765	-0.3741
4	2021-11-12	0.0055	0.0070	3.5820	1.5626	0.5113	-1.2336
5	2021-11-19	0.0060	0.0114	0.9595	1.1279	0.5517	-0.2482
6	2021-11-26	0.0059	0.0082	0.9010	1.0497	0.5483	-0.4377
7	2021-12-03	0.0109	0.0144	76.3220	1.6834	1.0150	-0.1034
8	2021-12-10	0.0075	0.0103	0.7940	1.1806	0.6941	-0.3737
9	2021-12-17	0.0112	0.0125	2.1144	1.2902	1.0358	-0.2600
Mean	nan	0.0066	0.0086	8.9656	1.3541	0.6060	-0.4499
SD	nan	0.0025	0.0033	22.4662	0.2231	0.2308	0.4146

Tabla de Error del Modelo 1 del ETF Menor Riesgo Relativo.

Anexo 7:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0041	0.0050	0.8674	1.1946	0.3738	-0.6813
1	2021-10-22	0.0065	0.0076	2.4582	1.5207	0.6028	-0.4190
2	2021-10-29	0.0039	0.0046	1.4264	1.6966	0.3610	-1.2712
3	2021-11-05	0.0050	0.0064	1.3529	1.5834	0.4588	-0.3198
4	2021-11-12	0.0049	0.0060	2.0103	1.9975	0.4553	-0.6396
5	2021-11-19	0.0081	0.0119	3.2444	1.4916	0.7498	-0.3745
6	2021-11-26	0.0072	0.0091	1.1551	1.7103	0.6649	-0.7861
7	2021-12-03	0.0094	0.0141	56.2473	1.6028	0.8717	-0.0603
8	2021-12-10	0.0069	0.0082	0.8449	1.4851	0.6394	0.1406
9	2021-12-17	0.0115	0.0130	1.9163	1.7219	1.0629	-0.3710
Mean	nan	0.0067	0.0086	7.1523	1.6005	0.6240	-0.4782
SD	nan	0.0023	0.0032	16.3803	0.1975	0.2144	0.3741

Tabla de Error del Modelo 2 del ETF Menor Riesgo Relativo.

Anexo 8:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0031	0.0034	0.7619	0.9784	0.2831	0.1992
1	2021-10-22	0.0061	0.0075	0.9462	1.4754	0.5610	-0.3795
2	2021-10-29	0.0035	0.0042	1.1125	1.4433	0.3245	-0.8374
3	2021-11-05	0.0062	0.0084	1.4108	1.3857	0.5686	-1.3267
4	2021-11-12	0.0046	0.0054	4.0469	1.4402	0.4232	-0.3462
5	2021-11-19	0.0072	0.0116	2.1384	1.1308	0.6655	-0.2923
6	2021-11-26	0.0077	0.0093	1.7688	1.5331	0.7180	-0.8626
7	2021-12-03	0.0097	0.0143	144.7063	1.6175	0.8969	-0.0970
8	2021-12-10	0.0081	0.0109	0.9202	1.4456	0.7496	-0.5294
9	2021-12-17	0.0121	0.0141	1.4755	1.9164	1.1172	-0.6084
Mean	nan	0.0068	0.0089	15.9288	1.4366	0.6308	-0.5080
SD	nan	0.0026	0.0037	42.9354	0.2408	0.2443	0.4091

Tabla de Error del Modelo 3 del ETF Menor Riesgo Relativo.

Anexo 9:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0033	0.0040	1.6125	0.9573	0.2865	0.3797
1	2021-10-22	0.0058	0.0078	1.9024	0.9389	0.5011	-0.0512
2	2021-10-29	0.0072	0.0126	2.2769	1.2712	0.6286	-7.3566
3	2021-11-05	0.0058	0.0073	3.2300	1.7294	0.5017	0.0086
4	2021-11-12	0.0055	0.0064	1.5371	1.5235	0.4805	-0.0012
5	2021-11-19	0.0087	0.0126	1.2385	1.4408	0.7553	-0.3300
6	2021-11-26	0.0082	0.0101	6.0787	1.7355	0.7170	-0.3585
7	2021-12-03	0.0140	0.0199	2.3917	1.4349	1.2215	-0.2105
8	2021-12-10	0.0099	0.0117	0.9379	1.5246	0.8617	-0.2115
9	2021-12-17	0.0122	0.0141	1.4607	1.4159	1.0604	-0.6180
Mean	nan	0.0081	0.0107	2.2666	1.3972	0.7014	-0.8749
SD	nan	0.0031	0.0043	1.4156	0.2608	0.2710	2.1753

Tabla de Error del Modelo 1 del ETF Riesgo Medio Relativo.

Anexo 10:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0050	0.0063	2.5331	1.4629	0.4323	-0.5130
1	2021-10-22	0.0071	0.0083	1.2280	1.9037	0.6169	-0.1818
2	2021-10-29	0.0037	0.0048	1.0057	1.3697	0.3222	-0.2337
3	2021-11-05	0.0059	0.0075	3.0194	1.7815	0.5146	-0.0550

Tabla de Error del Modelo 2 del ETF Riesgo Medio Relativo.

Anexo 11:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0055	0.0065	7.9541	1.6161	0.4737	-0.5914
1	2021-10-22	0.0068	0.0074	1.4404	1.7071	0.5934	0.0509
2	2021-10-29	0.0039	0.0056	0.9228	1.1635	0.3420	-0.6446
3	2021-11-05	0.0072	0.0097	8.6964	1.7031	0.6255	-0.7356
4	2021-11-12	0.0061	0.0070	1.8518	1.5233	0.5289	-0.2168
5	2021-11-19	0.0093	0.0137	1.4127	1.5787	0.8115	-0.5756
6	2021-11-26	0.0080	0.0100	3.6075	1.7037	0.6947	-0.3236
7	2021-12-03	0.0137	0.0206	0.8171	1.2835	1.1911	-0.2914
8	2021-12-10	0.0098	0.0116	0.9645	1.5183	0.8483	-0.1925
9	2021-12-17	0.0112	0.0131	1.0625	1.7625	0.9723	-0.3889
Mean	nan	0.0081	0.0105	2.8730	1.5560	0.7081	-0.3909
SD	nan	0.0027	0.0043	2.8363	0.1854	0.2397	0.2317

Tabla de Error del Modelo 3 del ETF Riesgo Medio Relativo.

Anexo 12:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0065	0.0076	2.1424	1.2972	0.4799	0.0141
1	2021-10-22	0.0100	0.0122	1.3466	1.7335	0.7385	-0.2957
2	2021-10-29	0.0057	0.0071	2.6801	1.0850	0.4206	-0.1794
3	2021-11-05	0.0085	0.0105	1.3819	1.7528	0.6259	-0.0365
4	2021-11-12	0.0084	0.0098	1.5282	1.6217	0.6177	-0.2144
5	2021-11-19	0.0084	0.0098	1.5282	1.6217	0.6177	-0.2144
6	2021-11-26	0.0084	0.0098	1.5282	1.6217	0.6177	-0.2144
7	2021-12-03	0.0084	0.0098	1.5282	1.6217	0.6177	-0.2144
8	2021-12-10	0.0084	0.0098	1.5282	1.6217	0.6177	-0.2144
9	2021-12-17	0.0084	0.0098	1.5282	1.6217	0.6177	-0.2144
Mean	nan	0.0081	0.0105	2.8730	1.5560	0.7081	-0.3909
SD	nan	0.0027	0.0043	2.8363	0.1854	0.2397	0.2317

Tabla de Error del Modelo 1 del ETF Mayor Riesgo Relativo.

Anexo 13:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0075	0.0087	1.3524	1.5976	0.5502	-0.2981
1	2021-10-22	0.0093	0.0110	1.3311	1.4296	0.6858	-0.0574
2	2021-10-29	0.0071	0.0081	2.4077	1.4318	0.5228	-0.5371
3	2021-11-05	0.0087	0.0104	1.4567	1.6029	0.6394	-0.0263
4	2021-11-12	0.0097	0.0124	1.2399	1.7701	0.7177	-1.0455
5	2021-11-19	0.0106	0.0140	38.0135	1.3899	0.7838	-0.2456
6	2021-11-26	0.0100	0.0128	1.2285	1.8313	0.7409	-0.3868
7	2021-12-03	0.0166	0.0226	0.9558	1.7232	1.2275	0.1498
8	2021-12-10	0.0122	0.0142	0.9334	1.4328	0.8940	-0.0823
9	2021-12-17	0.0134	0.0151	1.2841	1.5904	0.9811	-0.7683
Mean	nan	0.0105	0.0129	5.0203	1.5800	0.7743	-0.3298
SD	nan	0.0027	0.0039	11.0045	0.1494	0.2016	0.3488

Tabla de Error del Modelo 2 del ETF Mayor Riesgo Relativo.

Anexo 14:

	cutoff	MAE	RMSE	MAPE	SMAPE	MASE	R2
0	2021-10-15	0.0085	0.0096	2.2305	1.5836	0.6215	-0.5829
1	2021-10-22	0.0100	0.0109	1.5650	1.8560	0.7356	-0.0302
2	2021-10-29	0.0040	0.0055	1.0714	0.9434	0.2963	0.2912
3	2021-11-05	0.0093	0.0123	1.2434	1.5277	0.6874	-0.4463
4	2021-11-12	0.0075	0.0087	2.3968	1.3992	0.5493	-0.0072
5	2021-11-19	0.0127	0.0176	6.6676	1.5685	0.9386	-0.9727
6	2021-11-26	0.0098	0.0125	1.6178	1.7876	0.7254	-0.3308
7	2021-12-03	0.0186	0.0260	1.1473	1.7499	1.3687	-0.1286

Tabla de Error del Modelo 3 del ETF Mayor Riesgo Relativo.