

**Evaluación de Modelos de Inteligencia Artificial tipo LLM en la Predicción de Mercados
Financieros**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

AUTOR

ALVARO GABRIEL SALAS WALLACH

PROFESOR GUIA

WERNER KRISTJANPOLLER R.

SANTIAGO DE CHILE, 23 DE NOVIEMBRE 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: Evaluación de modelos de lenguaje de gran escala en la predicción de mercados financieros

Nombre del candidato(a): Alvaro Salas Wallach

Carrera / Grado: Ingeniería Civil Industrial

Campus: Vitacura Departamento: Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Werner Kristjanpoller, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (marcar una opción):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 01-01-2026

Firma: Werner Kristjanpoller

Estudiante o Candidato(a):

Fecha: 5-7-2026

Firma: AS

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Contenido

1	Agradecimientos	5
2	Resumen Ejecutivo / Abstract.....	6
3	Problema de investigación	7
3.1	Preguntas de investigación:.....	10
4	Objetivos	11
4.1	Objetivo general:.....	11
4.2	Objetivo específico:	11
5	Marco Teórico:	13
5.1	Inteligencia Artificial: Definición y evolución.....	13
5.2	Diferencias entre IA, Machine Learning, Deep Learning y LLM	16
5.3	El mercado financiero y sus desafíos de predicción.....	18
5.4	Aplicaciones actuales de la IA	21
5.5	Aplicaciones de la IA en Finanzas.....	26
5.6	Modelos de Lenguaje de Gran Escala (LLM).....	30
5.7	ChatGPT como caso representativo de los LLM	32
5.8	Ingeniería de prompts en el uso de LLM	36
5.9	Estado del arte en predicción financiera con IA y LLM.....	41
6	Metodología.....	45
6.1	Formato de trabajo	45
6.2	Fuentes de datos	46
6.3	Selección de fondos/activos	47
6.4	Datos recolectados	50
6.4.1	NASDAQ Composite (^IXIC)	50
6.4.2	SPDR S&P 500 ETF (SPY).....	58
6.4.3	Euro-Dólar (EUR/USD).....	68
6.4.4	Bitcoin (BTC/USD).....	80
6.4.5	Oro (XAU/USD)	87
6.4.6	Petróleo Brent (BRENT Crude Oil).....	91
6.5	Procesamiento y enmascaramiento de datos.....	96
6.6	Procedimiento experimental.....	101

6.6.1	Identificación de los datos relevantes	101
6.6.2	Recopilación de los Datos	103
6.6.3	Preparación y preprocesamiento de los datos	104
6.6.4	Construcción del prompt	105
6.6.5	Consulta al modelo de lenguaje (LLM)	106
6.6.6	Presentación y análisis de los resultados	107
6.7	Evaluación de resultados.....	108
6.7.1	Análisis Cuantitativo	108
6.7.2	Análisis Cualitativo.....	109
6.8	Limitaciones.....	111
7	Resultados	113
7.1	Andes Global Equity Fund (NASDAQ Composite).....	117
7.2	Oceanis Global Tech (SPDR S&P 500 ETF)	120
7.3	Atlas Macro Opportunities (Euro- Dólar)	123
7.4	Altair Strategic Bond (Bitcoin).....	126
7.5	Delta Currency Asset (Oro).....	129
7.6	Arkan Strategic Fund (Petróleo Brent).....	134
8	Análisis y Discusión	137
8.1	Análisis Cuantitativo	137
8.1.1	Cálculo del error porcentual relativo	139
8.1.2	Evaluación de desempeño por horizonte de tiempo	142
8.1.3	Desempeño por tipo de fondo o activo.....	144
8.1.4	Desempeño individual por fondo o activo.....	147
8.2	Análisis Cualitativo	150
8.2.1	Coherencia argumentativa y estructura del razonamiento.....	151
8.2.2	Correspondencia con la información entregada	153
8.2.3	Uso del lenguaje técnico y comprensión conceptual	155
8.2.4	Sesgos discursivos y patrones de comportamiento	155
9	Conclusión.....	157
10	Perspectivas futuras	160
11	Referencias	163
12	Anexo	169

1 Agradecimientos

Previo a introducirnos del todo en esta memoria, quiero expresar mi más profundo agradecimiento a mi familia. A mi mamá Andrea, a mi papá Antonio, a mi hermano Nicolás y a mi abuela Mónica, cuyo apoyo, cariño y paciencia me ayudaron durante el proceso de convertirme en Ingeniero Civil Industrial. También quiero dedicar un agradecimiento especial a mi abuela Eliza, la cual, aunque ya no esté presente, sigue siendo parte de mi inspiración, además de una parte importante de mi camino.

De igual manera quiero mención a mis mascotas, Mandy que ha sido un gran soporte durante este proceso, y a Dominga, que, a pesar de ya no estar con nosotros, fue y sigue siendo una gran inspiración en mi día a día.

Agradezco también a la Universidad Técnica Federico Santa María y al Departamento de Industrias por brindarme las herramientas, conocimientos y oportunidades necesarias para desarrollarme como profesional.

Extiendo un especial agradecimiento a mi profesor guía Werner Kristjanpoller, cuya orientación y dedicación fueron un gran aporte para la realización de esta memoria. Sus comentarios y experiencia permitieron dar forma y profundidad a este estudio.

Finalmente, quiero agradecer a todas las personas que, de alguna u otra manera, aportaron a lo largo de mis estudios, ya sea mediante conversaciones o simplemente acompañándome en los momentos en que lo necesité.

2 Resumen Ejecutivo / Abstract

Este estudio analiza la capacidad de un modelo de lenguaje de gran escala (LLM), específicamente ChatGPT, para predecir valores de cierre en distintos activos financieros. La investigación surge ante el creciente uso de la IA y busca determinar si sus predicciones pueden considerarse confiables para usuarios con poco conocimiento financiero. Para ello, se evaluaron horizontes de 1, 3, 6 y 12 meses utilizando diferentes extensiones de datos históricos.

Los resultados muestran que, aunque el LLM entrega explicaciones coherentes y comprensibles, su precisión cuantitativa es limitada. El modelo solo logra desempeños relativamente aceptables en el corto plazo (no más de 3 meses) y presenta errores significativos en predicciones de mayor horizonte. Además, aumentar la cantidad de datos históricos no mejora la calidad de las estimaciones.

El estudio concluye que ChatGPT, como modelo representativo de los LLM, no debe usarse como herramienta autónoma de predicción financiera, pero sí puede servir como apoyo complementario para interpretar información o comprender tendencias, especialmente cuando es utilizado por usuarios con conocimientos de finanzas.

3 Problema de investigación

Invertir en los mercados financieros, como la bolsa de valores, es una tarea compleja que requiere un análisis cuidadoso de múltiples factores, como las tendencias del mercado, la volatilidad y los riesgos asociados. Para personas con conocimientos limitados en finanzas, esta complejidad puede resultar abrumadora, lo que dificulta tomar decisiones de inversión bien fundamentadas. Es por esto por lo que se recomienda recurrir a profesionales del sector o fuentes especializadas para obtener información confiable sobre el funcionamiento bursátil.

Tras valorar que dispones de una cantidad de dinero que quieres invertir en bolsa, el siguiente paso es informarte sobre el funcionamiento bursátil. Consultar a profesionales del sector, leer medios especializados o realizar alguna formación son ideas para resolver las dudas que te puedan surgir (Santander, 2023).

En respuesta a esta dificultad, el uso de inteligencia artificial (IA) ha cobrado creciente relevancia, y más específicamente, los modelos de aprendizaje automático o más bien modelos de lenguaje de gran escala (LLM), como ChatGPT, Gemini o Copilot, entre los más conocidos. Estos han ganado relevancia para automatizar el análisis de datos y generar recomendaciones personalizadas en distintos ámbitos en este caso, en el sector inversión. Estas técnicas permiten procesar grandes cantidades de datos de forma rápida y precisa, mejorando la toma de decisiones.

Diversos autores señalan tanto las ventajas como las limitaciones de la inteligencia artificial en el análisis de información:

Por un lado, la IA puede procesar grandes cantidades de datos de forma rápida y precisa.

Esto significa que se pueden obtener resultados precisos y fiables. Sin embargo, también

hay algunos inconvenientes. La IA puede ser vulnerable a errores humanos, como el sesgo de los datos (Julliet, 2024) .

Este tipo de limitaciones ha impulsado el desarrollo de enfoques más específicos, como el aprendizaje por refuerzo, orientado a optimizar decisiones financieras, o la minería de texto, que permite integrar información no estructurada en el análisis de mercado.

El aprendizaje por refuerzo, una rama del machine learning, ha demostrado ser particularmente efectivo para optimizar las decisiones financieras, como la asignación de pesos en una cartera de inversión. "Se ha demostrado que las técnicas derivadas del aprendizaje por refuerzo permiten aumentar los beneficios de las operaciones realizadas al optimizar los pesos de una cartera" (Prieto, 2022).

Por otro lado, la minería de texto y el análisis de noticias son elementos clave para mejorar la precisión de los modelos predictivos en los mercados financieros, ya que permiten extraer información relevante en tiempo real y expandiendo las capacidades predictivas de estos modelos. Como señalan Ashtiani & Raahemi (2023), "las noticias son fundamentales para predecir el mercado de valores", y su revisión sistemática se enfoca en técnicas de aprendizaje automático y minería de textos que aprovechan las noticias para mejorar la predicción de los movimientos de mercado."

Según TechJury (2024), más del 78 % de las empresas emplean inteligencia artificial dentro de sus sistemas de Business Intelligence, y aproximadamente el 90 % reporta una mejora en la velocidad de la toma de decisiones, gracias al uso de BI potenciado por IA.

Por consiguiente, podemos inferir que la inteligencia de negocios ya desempeña un papel significativo en la toma de decisiones financieras, al facilitar el análisis ágil y preciso de grandes

volúmenes de datos. Además, su integración con sistemas de IA potencia aún más esos procesos, permitiendo recomendar inversiones o detectar tendencias con mayor velocidad y lucidez.

A pesar de estos avances, surge una pregunta clave: ¿Qué tan acertadas son estas predicciones generadas por IA y modelos de aprendizaje automático en contextos de mercado volátiles? Aunque las técnicas de IA y machine learning han demostrado ofrecer predicciones precisas y fiables, también pueden estar sujetas a sesgos en los datos, lo que puede afectar la calidad de las recomendaciones. Como se ha planteado, “son innumerables las publicaciones sobre la Inteligencia Artificial; muchas destacan sus grandes beneficios, mientras que otras cuestionan su impacto y la confianza que podemos depositar en ella” (Pastor, 2022).

En base a esto, este estudio busca evaluar la efectividad de los sistemas de IA, conocidos como LLM o modelo largo de lenguaje, para esto tendremos considerado a ChatGPT como un modelo representativo dentro de los sistemas de lenguaje de gran escala (LLM). Dado lo que menciona Picazo-Sánchez (Analysing the impact of ChatGPT in research, 2024), “en diciembre de 2022, OpenAI lanzó ChatGPT, que en pocos meses se convirtió en el ejemplo más representativo de los LLM”, se justifica su elección como caso de análisis en esta investigación. Para evaluar la efectividad, se medirá sus márgenes de error y la coherencia de sus predicciones, con el objetivo de determinar su utilidad práctica para inversionistas con conocimientos limitados en finanzas.

3.1 Preguntas de investigación:

¿En qué medida las recomendaciones generadas por un LLM pueden considerarse confiables para usuarios con conocimientos limitados en finanzas?

¿Qué capacidad muestra un LLM para identificar patrones emergentes en los mercados financieros y aportar valor en la toma de decisiones de inversión?

¿En qué medida la extensión del período de datos históricos entregados a un LLM influye en la precisión de sus predicciones financieras?

¿Qué tan consistentes son las predicciones de un LLM en distintos horizontes de tiempo (1, 3, 6 y 12 meses)?

¿Qué nivel de error presentan las predicciones un LLM en comparación con los valores reales del mercado financiero, y cómo se evalúan en relación con los criterios de aceptación definidos en la investigación?

4 Objetivos

4.1 Objetivo general:

Examinar la efectividad de un modelo de lenguaje de gran escala (LLM), específicamente para este caso ChatGPT, en la predicción de movimientos futuros en los mercados financieros, mediante la evaluación de sus niveles de error y la consistencia de sus predicciones en distintos horizontes de tiempo, con el fin de determinar su utilidad como apoyo en la toma de decisiones de inversión para un perfil de bajo conocimiento en el área.

4.2 Objetivo específico:

Evaluar la precisión de las predicciones generadas por un modelo de lenguaje de gran escala representativo, utilizando niveles de error porcentuales en los movimientos de diversos mercados financieros (fondos de inversión de renta variable).

Analizar la consistencia de las predicciones del LLM en distintos horizontes temporales (1, 3, 6 y 12 meses), ya sea en una estimación inicial como en casos con actualizaciones de información de los distintos horizontes temporales.

Determinar en qué medida la extensión del período de datos históricos entregados al LLM influye en la precisión de sus predicciones financieras.

Examinar la utilidad práctica de las recomendaciones generadas por el LLM para inversionistas con pocos conocimientos del mundo financiero, considerando su claridad y aplicabilidad.

Identificar las principales limitaciones del LLM al ser utilizado como herramienta de apoyo en la toma de decisiones de inversión considerando procesos de actualización de información.

5 Marco Teórico:

5.1 Inteligencia Artificial: Definición y evolución

“La Inteligencia Artificial (IA), acuñada en 1956 por John McCarthy, se refiere a una rama de la informática dedicada a desarrollar sistemas que puedan aprender, razonar y resolver problemas de manera similar a un ser humano” (Fernandez, 2024). Desde sus primeros días como un concepto futurista, la IA ha evolucionado significativamente, pasando de las películas de ciencia ficción a aplicaciones prácticas en la vida cotidiana.

Dicho de otra manera, en base a lo mencionado por el Parlamento Europeo (2021), la inteligencia artificial es una tecnología que permite a las máquinas realizar tareas que normalmente requieren inteligencia humana, como la toma de decisiones, el reconocimiento de patrones y el aprendizaje. Su propósito es optimizar procesos en diversos sectores al manejar grandes cantidades de datos de manera eficiente.

Los inicios de la Inteligencia Artificial (IA) se remontan a mediados del siglo XX. En particular, se considera que el término y el campo fueron introducidos oficialmente durante la conferencia de Dartmouth en 1956, donde John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude Shannon (científicos informáticos estadounidenses) entre otros científicos propusieron crear máquinas inteligentes, el objetivo de esta conferencia era buscar cómo hacer que las máquinas utilicen el lenguaje, formen abstracciones y conceptos que utilizan los humanos. Tal como menciona Sandra Peter (2024), este evento marcó el inicio formal de la IA como campo de investigación.

Según lo que se menciona Tim Mucci (IBM, 2024), da a entender que uno de los primeros hitos relevantes en la evolución de la Inteligencia Artificial fue el desarrollo de Shakey a fines de

los años sesenta, el cual es o fue el primer robot capaz de razonar sobre sus propias acciones al integrar percepción, planificación y resolución de problemas, lo que marcó no solo una transición operacional en este campo, si no que un avance significativo. Asimismo, en 1969, Arthur Bryson y Yu-Chi Ho introdujeron un nuevo algoritmo llamado “backpropagation”, técnica la cual posteriormente se consolidaría como fundamental para el entrenamiento de redes neuronales profundas. Por otro lado, Arthur Samuel, pionero en el concepto de “machine learning”, creó un programa informático que mejoraba su rendimiento constantemente jugando damas, logrando aprender e incluso superar al programador en este juego.

"Es importante resaltar que el 'deep learning' (DL) es un subcampo dentro del 'machine learning' (ML), así que cuando hablamos de DL, nos referimos a un tipo de ML más especializado, cuya arquitectura se basa en redes neuronales más complejas" (Sacie, 2024).

En conclusión, la historia de la inteligencia artificial ha tenido una evolución progresiva desde concepciones teóricas y robots experimentales hasta tecnologías empíricas que sentaron las bases del Machine Learning (ML) y, las que, con el tiempo y gracias al crecimiento exponencial de la capacidad computacional y la disponibilidad de grandes volúmenes de datos, el campo avanzó hacia el Deep Learning (DL), lo que potenció las redes neuronales profundas y arquitecturas sofisticadas. Posteriormente, llegaron los modelos de lenguaje de gran escala o LLM. Este recorrido es clave para lograr entender cómo se originaron herramientas como ChatGPT, Gemini, Copilot, entre otras.

La evolución desde los primeros sistemas de inteligencia artificial hasta el desarrollo de sistemas de Machine Learning y Deep Learning ha tenido un impacto significativo más allá de solo el ámbito técnico. Sino que, los avances en estas tecnologías han permitido que procesos complejos sean automatizados y que las máquinas puedan aprender y tomar decisiones y en caso

de fallar, poder aprender para corregir para que no se repita el fallo, influyendo en los sistemas sociales y el comportamiento individual.

En este sentido, como destaca Nieves Aravena (UC, 2023) desde la Universidad Católica, las tecnologías de IA ya no se pueden considerar solamente como herramientas técnicas, debido a que han comenzado a condicionar aspectos fundamentales de la vida cotidiana y la estructura social.

“Nuestra hipótesis es que el fenómeno de la inteligencia artificial no se puede reducir a una cuestión puramente tecnológica, ya que de forma creciente las aplicaciones de la IA están condicionando el funcionamiento de los sistemas democráticos y las políticas públicas, el mundo de la innovación y la producción cultural, la economía e incluso los espacios íntimos de las relaciones sentimentales” (Tironi, 2023).

5.2 Diferencias entre IA, Machine Learning, Deep Learning y LLM

Es fundamental distinguir entre Inteligencia Artificial (IA), Machine Learning y Deep Learning para comprender mejor su aplicación en el análisis financiero.

Inteligencia Artificial (IA) es el término más amplio, que abarca cualquier sistema o máquina que pueda realizar tareas que normalmente requieren inteligencia humana, como el reconocimiento de patrones, la toma de decisiones y el procesamiento de datos.

Machine Learning (ML), o aprendizaje automático, es una subdisciplina de la IA que se centra en el desarrollo de algoritmos que permiten a las máquinas aprender de los datos, mejorar su rendimiento y hacer predicciones sin ser programadas explícitamente para cada tarea. En el ámbito financiero, el machine learning se utiliza para identificar patrones en datos históricos de precios, analizar tendencias (y ciclicidades o estacionalidad) y hacer predicciones. Un ejemplo de ML son los sistemas de recomendación en plataformas como Netflix o Spotify, que analizan los hábitos de visualización o escucha de los usuarios para sugerir contenido personalizado.

Deep Learning (DL) es un nivel más avanzado de machine learning que utiliza redes neuronales profundas para procesar grandes cantidades de datos no estructurados y complejos. Las redes neuronales profundas permiten identificar patrones sutiles en grandes conjuntos de datos, lo cual es crucial en la predicción de mercados financieros, donde los datos suelen ser voluminosos y poco estructurados (Alonso, 2024). Un ejemplo claro de DL es el reconocimiento facial en los teléfonos móviles, que utiliza redes neuronales profundas para identificar rostros con gran precisión.

De estos tres conceptos (IA, ML y DL) surge la base técnica de los Modelos de Lenguaje de Gran Escala (LLM). Según AWS, los LLM son “son modelos de aprendizaje profundo muy

grandes que se preentrenan con grandes cantidades de datos” (What is LLM (Large Language Model)?, s.f.). Por lo que podemos comprender que los LLM vienen de DL o del concepto inicial de IA. Un ejemplo cotidiano de LLM es el uso de asistentes conversacionales como Siri, capaces de responder preguntas, o traducir información en lenguaje natural (lenguaje humano).

Dicho lo anterior, podemos llevar a una relación jerárquica, en donde desde el concepto inicial de IA, se crea el ML (machine learning), y del ML surge el DL (Deep learning), y con el DL llegamos a los LLM (large language model, o modelo de lenguaje grande). estos modelos no solo son escalas superiores comparadas con DL tradicionales, sino que también transforman el procesamiento del lenguaje natural en tareas como generación de texto, resumen o traducción, gracias a su habilidad para comprender relaciones semánticas entre palabras y frases a través de redes profundas y autoatención.

Estas distinciones son claves para la investigación, ya que cada una de estas tecnologías tiene aplicaciones específicas en el análisis de datos financieros. Mientras que el machine learning puede ser útil para analizar series de tiempo y patrones históricos, el deep learning es capaz de manejar conjuntos de datos más complejos y extraer patrones ocultos, lo que es especialmente relevante en mercados volátiles, y además los modelos de lenguaje de gran escala (LLM) aportan la capacidad de procesar y generar en el lenguaje natural, permitiendo analizar grandes volúmenes de información textual como noticias, reportes o comentarios de mercado, siendo de fácil uso para las personas, al utilizar el lenguaje natural.

5.3 El mercado financiero y sus desafíos de predicción

Los mercados financieros son espacios, físicos o virtuales, en los cuales interactúan diversos agentes económicos con el fin de intercambiar activos financieros, tales como acciones, bonos, divisas o derivados.

La relevancia de los mercados financieros radica en su capacidad de estimular el crecimiento económico y favorecer la estabilidad del sistema. Según la Comisión para el Mercado Financiero de Chile (CMF) (CMF Chile, s.f.), el mercado de capitales es uno de los impulsores claves de la economía, dado que permite que agentes económicos con excedentes de recursos ahorren e inviertan, mientras que los deficientes de recursos acceden a recursos a través de la emisión de instrumentos financieros.

La volatilidad en los mercados financieros representa un obstáculo no menor para lograr predicciones fiables o útiles. En situaciones donde los precios no reflejan toda la información disponible, sino que además responden a expectativas o rumores, los movimientos abruptos se vuelven frecuentes. Eduardo Quiroga (2017) menciona que en mercados con menor eficiencia, estos episodios de alta fluctuación dificultan enormemente la predicción del comportamiento de los activos, pues los modelos de predicción basados en datos históricos pierden precisión ante estos eventos inesperados.

La volatilidad anteriormente mencionada, también es explicada por efectos de los comportamientos especulativos (expectativas o rumores), que en muchas ocasiones generan “burbujas” financieras. Estas “burbujas” surgen cuando los precios de los activos se alejan de sus valores esperados (según características económicas reales y medibles), debido a una especulación excesiva, generando un crecimiento artificial que, tarde o temprano, desemboca en que la

“burbuja” explota. En base a lo mencionado por Jorge Uribe y Julián Fernández (Burbujas financieras y comportamiento reciente de los mercados de acciones en América Latina, 2014), las burbujas financieras no solo generan una distorsión en la asignación eficiente de recursos, sino que también provocan crisis cuando finalmente estallan, amplificando la inestabilidad de los mercados y evidenciando las limitaciones de los modelos tradicionales de predicción.

Con el fin de mitigar la incertidumbre asociada a la volatilidad de los mercados financieros, se emplean diversos índices que permiten sintetizar el comportamiento general del mercado y ofrecer una referencia estable para el análisis.

“Se utiliza el índice COLCAP, que refleja la variación de las empresas más líquidas de la bolsa de valores colombiana y a su vez contiene las acciones de las empresas más importantes del país. Como metodología, se aplicó el modelo de vectores autorregresivos generalizados (VAR), cuyos resultados mostraron que el índice COLCAP reacciona positivamente ante aumentos de la actividad económica, la actividad industrial y los precios del petróleo; y negativamente ante la tasa de cambio y la tasa de desempleo.” (Viáfara, Gómez, & Mejía, 2023)

El extracto anterior, evidencia cómo la dinámica del mercado bursátil (o mercado financiero) es directamente influenciada por los cambios en variables macroeconómicas. El hecho de que el índice COLCAP reaccione de forma positiva a la actividad económica, industrial y al precio del petróleo, y negativamente ante la tasa de cambio y el desempleo, demuestra que los mercados financieros son altamente sensibles a variaciones del entorno macroeconómico. Los modelos de predicción basados únicamente en series históricas de precios tienen limitaciones significativas, ya que no incluyen estas variables macroeconómicas. Lo que se traduce en que la

incorporación de indicadores macroeconómicos en modelos predictivos se vuelve esencial para mejorar la precisión y robustez de las proyecciones.

Además, este hallazgo refuerza la relevancia de aplicar herramientas que puedan considerar más variables, como la inteligencia artificial y en particular los LLM, que permiten integrar información heterogénea y adaptarse a contextos de incertidumbre económica elevada.

El hecho que una parte de los participantes de este mercado financiero carece de conocimientos técnicos avanzados para interpretar adecuadamente los indicadores económicos y tomar decisiones de inversión fundamentadas, aumenta la probabilidad de cometer errores de juicio, dejarse llevar por la especulación o sobre reaccionar a eventos externos, lo a su vez cual incrementa la volatilidad y la incertidumbre en el mercado.

Dada estas dificultades, el uso de herramientas de apoyo en la toma de decisiones resulta fundamental. La IA, y en particular los LLM, ofrecen la posibilidad de procesar grandes volúmenes de información, identificar patrones ocultos y presentar resultados de manera accesible y entendible a usuarios con diferentes niveles de conocimiento. Estas tecnologías permiten democratizar el acceso a información financiera de calidad, reduciendo la brecha entre expertos e inversionistas de bajo conocimiento. De este modo, la IA facilita una toma de decisiones más informada e inclusiva en entornos caracterizados por alta complejidad e incertidumbre.

5.4 Aplicaciones actuales de la IA

La inteligencia artificial ha evolucionado para convertirse en una herramienta clave en numerosos sectores, transformando profundamente la manera en que se abordan tareas críticas y se toman decisiones. Su capacidad para procesar y analizar grandes volúmenes de datos en tiempo real ha ampliado su aplicación en áreas como la salud, la educación, las finanzas y el transporte, permitiendo desde la personalización de tratamientos médicos hasta la optimización de inversiones y la conducción autónoma. A continuación, se presentan ejemplos concretos que ilustran cómo la IA está marcando una diferencia significativa en estos campos.

Salud:

Actualmente, las funciones más comunes de la IA en entornos médicos son el apoyo a las decisiones clínicas y el análisis de imágenes. Las herramientas de apoyo a la toma de decisiones clínicas ayudan a los proveedores a tomar decisiones sobre tratamientos, medicamentos, salud mental y otras necesidades de los pacientes al proporcionarles un acceso rápido a información o investigaciones relevantes para sus pacientes. En imágenes médicas, las herramientas de IA se emplean para analizar tomografías computarizadas, radiografías, resonancias magnéticas y otras imágenes en busca de lesiones u otros hallazgos que un radiólogo humano podría pasar por alto.

(IBM, (s.f.))

Educación:

La inteligencia artificial en el aula permite la creación de chats que pueden ayudar de modo virtual al alumnado. Con este sistema, y tal y como lo usan las empresas, se pueden solucionar problemas sencillos del día a día que suelen ser recurrentes (INESDI, 2023).

En base a lo mencionado por Padilla (2019), la inteligencia artificial en la educación se utiliza para personalizar el aprendizaje mediante herramientas como chatbots, que apoyan a los estudiantes respondiendo preguntas en tiempo real, y plataformas de autoaprendizaje adaptativas, que se ajustan al estilo y ritmo de cada estudiante. Estas tecnologías facilitan la evaluación automática y permiten a los docentes identificar áreas de mejora, optimizando así el proceso educativo y promoviendo una experiencia más personalizada y eficiente.

Finanzas:

La inteligencia artificial (IA) en finanzas ayuda a obtener estadísticas para el análisis de datos, la medición del rendimiento, las predicciones y la previsión, los cálculos en tiempo real, el servicio de atención al cliente, la recuperación inteligente de datos y mucho más. Es un conjunto de tecnologías que permite que las organizaciones de servicios financieros comprendan mejor mercados y clientes, analicen y aprendan de los recorridos digitales y, al mismo tiempo, interactúen de forma similar a la inteligencia humana y las interacciones a gran escala (Google Cloud, s.f.).

Ambiente empresarial:

Conforme a lo establecido por AWS (s.f.), se tiene Amazon Q, el cual es un asistente basado en inteligencia artificial generativa que mejora la productividad empresarial al integrarse con sistemas internos para automatizar tareas, responder preguntas y generar contenido. Este facilita el desarrollo de software, análisis de negocios y atención al cliente al ofrecer soluciones

personalizadas y en tiempo real, optimizando recursos y apoyando la toma de decisiones informadas.

Vida cotidiana:

La aplicación de las inteligencias artificiales no solo se limita a ambientes académicos, empresariales o números, sino que también se ha incorporado a la vida cotidiana. Por ejemplo, según Babiloni (29 ejemplos de cómo ChatGPT nos puede ayudar en nuestra rutina diaria desde el móvil, 2024), ChatGPT puede ayudar en situaciones cotidianas como cocinar, sugiriendo una receta viable cuando solo se dispone de pocos ingredientes en casa. También menciona que puede asistir en el uso de herramientas informáticas como Google Sheets o Excel, explicando qué funciones utilizar cuando el usuario sabe lo que necesita lograr, pero desconoce el nombre de la fórmula. También puede colaborar en la organización personal, generando listas de tareas o ayudando a estructurar agendas diarias, y además en la traducción rápida de textos, apoyando en la comprensión de información en otros idiomas sin necesidad de usar aplicaciones especializadas.

En resumen, la inteligencia artificial está transformando la manera en que interactuamos con la tecnología al ofrecer soluciones innovadoras y eficientes en múltiples áreas de la sociedad. Desde su capacidad para agilizar procesos empresariales, como en el caso de Amazon Q, su aplicación en sectores esenciales como la salud, la educación y las finanzas, e incluso está revolucionando la vida cotidiana. Estas aplicaciones reflejan su versatilidad y el impacto significativo que tiene en mejorar la calidad de vida, incrementar la productividad y abordar desafíos complejos de manera más efectiva.

“Una de las cuestiones más publicitadas por los desarrolladores de sistemas de IA es la posibilidad de obtener con un “prompt” la información que se requiere en un momento determinado bajo la idea de que esta información será siempre correcta. Esta afirmación es parcialmente verdadera, dado que los modelos amplios de lenguaje tienen porcentajes de errores comprobados que pueden llegar al 60 por ciento.

Por eso es crucial actuar como curador de contenidos respecto de los productos que se obtienen por IA. Solo un experto en cada materia puede detectar errores y sesgos.

Esto va de la mano con la idea general de racionalidad que se otorga a los modelos amplios de lenguaje. Se debe evitar considerar las respuestas que se obtienen de la IA como los modelos últimos de racionalidad científica y social.

La utilización del material obtenido de los modelos amplios de lenguaje debe sujetarse a un continuo escrutinio y depuración." (Unesco, 2025)

Con lo mencionado anteriormente, se puede entender que no es recomendable confiar “a ciegas” en los resultados de la inteligencia artificial. Entiendase se entiende que las respuestas generadas, lejos de ser verdades absolutas, deben ser evaluadas de manera crítica, ya que pueden contener imprecisiones o errores graves. Esto se vuelve especialmente importante al considerar que, en situaciones sensibles como el apoyo emocional, muchas personas pueden depositar una confianza excesiva en herramientas como ChatGPT.

“Un adolescente tenía tendencias suicidas. ChatGPT fue el amigo en quien confió.

Cada vez más gente recurre a los chatbots en busca de apoyo emocional.” (Hill, 2025)

“Business intelligence se refiere a los procesos y las herramientas que se usan para analizar los datos de negocio, convertirlos en información estratégica accionable, y ayudar a todos en la organización a tomar mejores decisiones fundamentadas. También conocido como sistema de soporte de decisiones (DSS), un sistema de BI analiza los datos actuales e históricos y presenta los hallazgos en informes fáciles de digerir, dashboards, gráficos y mapas que pueden compartirse con toda la empresa.” (SAP, s.f.)

Se puede entender business intelligence como un conjunto de procesos y herramientas que permiten transformar los datos brutos en información valiosa y estratégica para apoyar la toma de decisiones dentro de una organización.

La incorporación de la Inteligencia Artificial (IA) ha potenciado de manera significativa el alcance de BI (business intelligence), debido a que permiten pasar de datos brutos a información valiosa. Mientras que tradicionalmente el BI se centraba en ofrecer análisis descriptivos e históricos, la potencia de la IA permite avanzar hacia enfoques predictivos y prescriptivos. Lo que significa que no solo interpretar lo que ocurrió en el pasado, sino logra anticipar posibles escenarios futuros y sugerir acciones específicas basadas en patrones de comportamiento identificados en los datos.

En el ámbito financiero, esta integración resulta particularmente valiosa, ya que la IA aplicada al BI puede facilitar la identificación de tendencias de mercado, la detección temprana de anomalías y la generación de recomendaciones personalizadas de inversión. Por lo que, la sinergia entre ambas disciplinas contribuye a una mejor toma de decisiones y a fortalecer la ventaja competitiva de quienes las implementan.

5.5 Aplicaciones de la IA en Finanzas

Lograr una buena predicción de las series temporales (serie de observaciones sobre una variable medida en intervalos de tiempo) es fundamental en el ámbito de finanzas, debido a que permite tener un anticipo precios, tasas de interés e índices bursátiles (como S&P500, Nasdaq composite, entre otras). Si bien los modelos estadísticos tradicionales como ARIMA o GARCH han sido ampliamente utilizados, debido a su gran utilidad en el estudio de estos campos, el desarrollo de los modelos de lenguaje de gran escala (LLM) ha abierto nuevas posibilidades de análisis que pueden lograr mejores resultados.


Según lo mencionado por Hua Tang, Mingyu Jin, Chong Zang y Qinkai Yu (ResearchGate, 2024), los LLM pueden abordar esta tarea utilizando un modelo que no haya recibido un entrenamiento específico previo para este tipo de problemas, teniendo buenos resultados cuando existen tendencias claras y estacionalidad definida. Además, mencionan que la IA (o los LLM) funcionan bien con patrones regulares, pero presentan dificultades en series sin periodicidad.

Unos de los hallazgos relevantes de lo mencionado por los autores, es que existe una mayor influencia por parte de los datos recientes frente a los históricos, lo que conecta con el análisis de esta investigación sobre la extensión de los periodos de entrada (si es conveniente, o no agregar más fechas). Además de esto, se evidencian limitaciones al manejar múltiples periodicidades, lo cual es común en el ámbito financiero, y la necesidad de complementar con información externa, como pueden ser hechos históricos relevantes o indicadores macroeconómicos. Dicho esto, se puede sugerir que los LLM representan un avance prometedor en este campo, aunque todavía presentan limitaciones que requieren ser complementadas con métodos más especializados, con el fin de lograr mayor precisión en entornos financieros.

Además de los desafíos identificados en la predicción de series temporales, la inteligencia artificial (IA), entendida aquí como los modelos de lenguaje de gran escala (LLM), juega un papel fundamental en la medición de la incertidumbre económica, especialmente en mercados financieros donde los cambios y fluctuaciones pueden ser súbitos e impredecibles. Una aplicación destacada en este ámbito es el uso de técnicas de minería de texto y análisis de sentimiento para analizar noticias, informes financieros y redes sociales en tiempo real. Estas herramientas permiten evaluar el estado de ánimo del mercado y anticipar posibles cambios en el comportamiento de los inversores. Por ejemplo, un análisis de noticias financieras en tiempo real puede ayudar a identificar rápidamente una tendencia hacia el optimismo o el pesimismo en el mercado, lo cual puede ser un indicador clave para predecir movimientos futuros (Corinna Ghirelli, 2024).

Ilustración 1

Medición de la incertidumbre económica mediante inteligencia artificial



Fuente: (Corinna Ghirelli, 2024)

En la Ilustración 1; **Error! No se encuentra el origen de la referencia.** se muestra cómo la IA se utiliza para medir la incertidumbre económica a través de indicadores que se alimentan de

datos en tiempo real, como noticias y publicaciones en redes sociales. El uso de IA permite analizar estos datos y generar un indicador de incertidumbre, ofreciendo una visión clara de la estabilidad o volatilidad del mercado en un momento dado.

Según Liu y Wang (Analysis of Financial Market using Generative Artificial Intelligence, 2024), el impacto de la inteligencia artificial generativa o en este caso los LLM en el contexto de mercados financieros va más allá del simple procesamiento del sentimiento en textos, también introduce asesorías financieras virtuales, evaluaciones de riesgos e identificación de patrones emergentes en los mercados financieros. Ellos señalan que los modelos generativos tienen la capacidad de integrar y analizar grandes volúmenes de datos, en este caso datos financieros, los cuales los utilizan para proporcionar recomendaciones estratégicas a inversores, logrando superar algunas limitaciones de los modelos de asesoría tradicionales que no aprovechan tanta diversidad de información.

Dada la existencia de estas aplicaciones de IA en finanzas, es relevante observar cómo distintas organizaciones, de variados sectores han comenzado a incorporar herramientas basadas en LLM o IA en sus operaciones.

“Las empresas que utilizan Microsoft 365 Copilot para plataformas de IA generativa incluyen: Mayo Clinic, una organización de atención médica en Estados Unidos con 80.221 empleados e ingresos de 17,90 mil millones de dólares; Lumen Technologies, una organización de comunicaciones en Estados Unidos con 25.000 empleados e ingresos de 13,11 mil millones de dólares; Emirates NBD Bank, un banco de Emiratos Árabes Unidos con 14.000 empleados e ingresos de 12,00 mil millones de dólares; Cushman & Wakefield, una empresa estadounidense del sector inmobiliario con 53.000 empleados e ingresos de 9,50 mil millones de dólares; AmBank,

un banco de Malasia con 8.200 empleados e ingresos de 1,05 mil millones de dólares, entre muchos otros.” (AppsRunTheWorld, s.f.)

En base a lo anterior, se puede decir que los LLM o en este caso Microsoft 365 Copilot no se limitan solamente a mejorar la productividad administrativa, sino que también fortalece la capacidad de las instituciones financieras. La inclusión de bancos como Emirates NBD y AmBank en esta lista refleja que la adopción de IA generativa ya no es solo una tendencia emergente, sino que una práctica más cotidiana dentro del sector bancario.

5.6 Modelos de Lenguaje de Gran Escala (LLM)

Los Modelos de Lenguaje de Gran Escala (LLM) constituyen una categoría avanzada de sistemas de deep learning (DL) diseñados para procesar y generar lenguaje natural. Según lo que mencionan en AWS (What is LLM (Large Language Model)?, s.f.), los LLM son modelos de DL, que utilizan el lenguaje natural y que a su vez emplean arquitecturas basadas en transformers (modelo de DL que utiliza cierto mecanismo para procesar datos en paralelo, identificando qué partes de una secuencia son más relevantes entre sí), capaces de aprender patrones lingüísticos y semánticos a gran escala.

Por otro lado, de lo que menciona IBM (¿Qué son los grandes modelos de lenguaje (LLM)?, 2023), podemos extraer que los LLM son un tipo de modelos fundacionales de deep learning entrenados con enormes volúmenes de datos mediante arquitecturas basadas en transformers. Debido a ello, los LLM son capaces de procesar (como input) y generar (como output) lenguaje natural con alta precisión, identificar patrones lingüísticos complejos y generalizar su conocimiento para múltiples tareas. Sus aplicaciones más comunes son la redacción de texto, la traducción de textos, resúmenes de información y generación o interpretación de imágenes, entre otras cosas lo que los convierte en herramientas versátiles que pueden adaptarse a distintos contextos e industrias, como la programación, la salud o incluso las finanzas.

Entre los modelos más conocidos de LLM se encuentran ChatGPT (OpenAI), Gemini (Google), Copilot (Microsoft), DeepSeek y Meta AI (Meta). A nivel especializado, destacan modelos orientados al sector financiero como InvestLM y FinGPT. No obstante, empresas como IBM también han desarrollado modelos propios, como la serie Granite, integrada en watsonx.ai, orientada a aplicaciones empresariales.

Cabe recalcar que no todos los sistemas de ML o DL son LLM. Mientras que ML y DL abarcan un espectro amplio de aplicaciones (imágenes, series temporales, análisis de datos, entre otras cosas), los LLM son una rama más específica dedicada a funcionar en el ambiente de lenguaje natural, ya sea el procesamiento y generación de este. Dicho de otra forma, todos los LLM se apoyan en ML y DL, pero no todo ML o DL necesariamente será un LLM.

5.7 ChatGPT como caso representativo de los LLM

Siguiendo lo planteado en la definición del problema, se considera que ChatGPT es representativo para evaluar la efectividad de los LLM. Según lo que mencionan Picazo-Sánchez y Ortiz-Martín (Analysing the impact of ChatGPT in research, 2024), tras el lanzamiento de ChatGPT en diciembre de 2022 por OpenAI, este se consolidó rápidamente como uno de los LLM más representativo, debido a su alta capacidad para generar textos coherentes, resumir información y realizar traducciones en distintos contextos. Uno de los motivos principales para elegirlo el LLM de estudio es su gran popularidad y fácil accesibilidad (no requiere crear cuenta para ocuparlo). Desde su lanzamiento, ChatGPT ya tiene 800 millones de usuarios semanales al mes de Mayo de 2025 según lo que informa Fabio Duarte (Número de usuarios de ChatGPT (julio de 2025), 2025). A diferencia de otros modelos conocidos, ChatGPT tiene libre acceso a una versión gratuita, además de opciones de pago tipo suscripción mensual.

Ilustración 2

Diferencias de características entre los planes de ChatGPT (Gratis, Plus, Pro).

Gratis	Plus	Pro
Descubre cómo la IA puede ayudarte en tus tareas diarias ✓ Acceso a GPT-5 ✓ Datos de la web en tiempo real con la búsqueda ✓ Acceso limitado a subida de archivos, análisis de datos, generación de imágenes y modo de voz ✓ Edición de código con la aplicación de escritorio ChatGPT para macOS ✓ Uso de GPT personalizados ✓ Crear y usar proyectos ¿Ya tienes un plan? Obtén ayuda con la facturación	Multiplica tu productividad y creatividad con acceso ampliado ✓ Todo lo incluido en la versión gratuita ✓ Acceso ampliado a GPT-5, nuestro modelo insignia ✓ Límites ampliados en mensajes, subida de archivos, análisis de datos y generación de imágenes ✓ Modo de voz estándar y avanzado con video y pantalla compartida ✓ Acceso al agente de ChatGPT ✓ Crear y usar tareas y GPT personalizados ✓ Acceso limitado a la generación de videos con Sora ✓ Posibilidad de probar las nuevas funciones	Consigue lo mejor de OpenAI con el máximo nivel de acceso ✓ Todo lo incluido en Plus ✓ Acceso ilimitado a GPT-5 ✓ Accede a GPT-5 Pro, que usa más recursos de computación para dar las mejores respuestas a las preguntas más difíciles ✓ Acceso ilimitado al modo de voz avanzado, con límites más altos para el video y la pantalla compartida ✓ Accede a OpenAI o3-pro, que consume más recursos computacionales para dar las mejores respuestas a las preguntas más difíciles ✓ Acceso ampliado al agente de ChatGPT ✓ Acceso ampliado a la generación de videos de Sora ✓ Acceso a un anticipo de la investigación del agente Codex Acceso ilimitado sujeto a barreras de seguridad contra el abuso. Más información
USD 0 / mes	USD 20 / mes	USD 200 / mes
Versión gratis ↗	Quiero Plus ↗ Sujeto a limitaciones >	Quiero Pro ↗

Fuente: (OpenAI, s.f.)

De manera resumida, lo indicado en la Ilustración 2 los planes que ofrece ChatGPT se diferencian principalmente según el nivel de acceso a modelos o submodelos, la capacidad de uso y las funciones adicionales. La versión gratuita ofrece acceso al modelo GPT-5 con funciones básicas como búsqueda en la web en tiempo real, creación de proyectos, uso de GPT's personalizados y un acceso limitado a la subida de archivos, análisis de datos, generación de imágenes y modo de voz.

El plan Plus, que cuesta 20 USD al mes incluye todo lo que esta incluido en la versión gratuita, pero amplía los límites de uso, ofreciendo un acceso más robusto a GPT-5, además de

habilitar funciones avanzadas como el modo de voz con video y pantalla compartida, acceso al agente de ChatGPT y la posibilidad de probar nuevas funciones.

Por último, el plan Pro, con un costo de 200 USD al mes, está más orientado a un usuario más avanzado, el cual requiere un acceso intensivo y de máxima capacidad. Este plan ofrece un acceso ilimitado a GPT-5 y a versiones más potentes del modelo, como GPT-5 Pro y OpenAI o3-pro, que utilizan más recursos computacionales con el fin de resolver consultas más complejas. También amplía el acceso al modo de voz avanzado, al agente de ChatGPT, a la generación de videos con Sora y a otras herramientas experimentales como el agente Codex.

Ilustración 3

Diferencias de características entre los planes de empresa de ChatGPT.

Business	Enterprise
Un espacio de trabajo seguro con modelos avanzados y conectores a fuentes internas	IA, seguridad y soporte técnico para empresas a gran escala
✓ Mensajes de GPT-5 ilimitados, con amplio acceso a GPT-5 Thinking y acceso a GPT-5 Pro, además de la flexibilidad de agregar créditos según sea necesario ✓ Un espacio de trabajo seguro y especializado con controles de administración esenciales, que cumple con SAML SSO y MFA ✓ En el entrenamiento, los datos se excluyen de forma predeterminada, y se cifran en reposo y en tránsito. Obtén más información ✓ Cumplimiento del RGPD, la CCPA y otras leyes de privacidad. Cumple con las certificaciones CSA STAR, SOC 2 Tipo 2 e ISO/IEC 27001, 27017, 27018 y 27701 ✓ Conectores a aplicaciones para obtener respuestas más personalizadas: Google Drive, SharePoint, GitHub, Notion y más ✓ Características de Business como análisis de datos, modo de grabación, canvas, proyectos, tareas, GPT personalizados para espacios de trabajo e investigación a fondo ✓ Incluye acceso a Codex y al agente ChatGPT para razonar y tomar acciones en tus documentos, herramientas y códigos base	✓ Todo lo que se incluye en el plan Business con una ventana de contexto ampliada que admite entradas más largas y archivos más grandes ✓ Seguridad y controles para empresas, lo que incluye SCIM, análisis de usuarios, verificación de dominios y controles de acceso basados en roles ✓ Privacidad de datos avanzada con políticas de retención de datos personalizados, cifrado en reposo y en tránsito, y, de forma predeterminada, los datos de tu empresa no se incluyen en el entrenamiento Obtén más información ✓ Compatibilidad con la residencia de datos en siete regiones ✓ Asistencia prioritaria las 24 horas del día, los 7 días de la semana, términos legales personalizados y acceso a asesores de inteligencia artificial para los clientes que cumplan los requisitos ✓ Creado para adaptarse a las necesidades con descuentos por volumen, facturación y cobros ACH, así como soporte para un número ilimitado de usuarios
USD 25 por usuario al mes facturado anualmente USD 30 por usuario al mes facturado mensualmente	
Probar ahora >	Contáctanos >

Fuente: (OpenAI, s.f.)

Además de las tres opciones principales orientadas a usuarios individuales (Gratis, Plus y Pro), OpenAI ofrece dos planes adicionales como se muestra en la Ilustración 3 con un mayor enfoque en empresas, estos son el Business y el Enterprise. El plan Business, el cual cuesta 30

USD al mes si se contrata mensualmente, o 25 USD por mes si se contrata de manera anual, está diseñado para empresas o trabajadores que requieren un entorno de trabajo seguro y especializado, el cual incluya controles administrativos avanzados, compatibilidad con normativas de privacidad internacionales y conectores a aplicaciones corporativas (tales como Dropbox, Microsoft Teams, Gmail, entre otras). Por su parte, el plan Enterprise amplía las capacidades del plan Business, añadiendo una mayor seguridad, personalización en la gestión de datos y asistencia prioritaria 24/7. Cabe destacar que estos planes no están pensados para el individuo promedio, sino para contextos empresariales donde se requieren mayores garantías de seguridad, privacidad y capacidad de integración.

Si hablamos ahora de sus fortalezas, ChatGPT destaca su capacidad de procesar y generar lenguaje natural (incluso es capaz de adaptarse a los modismos que se usan en Chile) de manera coherente y adaptarse a distintos contextos según las necesidades del usuario. Asimismo, ofrece un alto grado de versatilidad, ya que puede redactar textos largos (sin caer en redundancias), explicar conceptos complejos, generar recomendaciones e incluso interactuar en distintos idiomas. Todas estas características lo convierten en una herramienta versátil y confiable para múltiples propósitos, desde apoyo educativo hasta análisis preliminar de información en contextos profesionales.

En conclusión, la selección del LLM ChatGPT como caso representativo se basa tanto en su relevancia global como en sus fortalezas. Esto lo convierte en un objeto de análisis pertinente para evaluar el potencial de los LLM en la predicción y generación de recomendaciones, especialmente en contextos donde los usuarios pueden tener conocimientos limitados en el contexto de inversiones financieras.

5.8 Ingeniería de prompts en el uso de LLM

Un prompt es la instrucción escrita que se entrega a un modelo de inteligencia artificial o en este caso, un LLM, para indicarle qué tipo de tarea debe realizar y como la debe realizar, dicho de otra manera, es un input. Esta instrucción puede ser simple (como, por ejemplo, resume este texto, o recomiéndame una película) o más compleja, por ejemplo, analiza la rentabilidad de X fondo de inversión en distintos plazos y en función del contexto económico actual, realiza una “predicción” de ese fondo de inversión, entre otras cosas.


Según Google Cloud (What is prompt engineering?, s.f.), el diseño de prompts efectivos es parte de una disciplina llamada ingeniería de prompts (prompt engineering), cuya finalidad es redactar un prompt que logre obtener respuestas útiles y reproducibles a partir de modelos de lenguaje de gran escala (LLMs).

La importancia de un buen prompt radica en que mejore la precisión de la respuesta, reduce malentendidos o errores en las respuestas generadas, permite controlar el formato y nivel de profundidad de la información y aumenta la utilidad en tareas especializadas como análisis de datos, redacción técnica, simulaciones o predicciones.

De acuerdo con lo expuesto por Yúbal Fernández (Qué es un prompt y por qué son tan importantes para usar la Inteligencia Artificial, 2025), la redacción de un prompt desempeña un papel importante en los LLM, ya que la calidad de la respuesta que se obtendrá depende en cierta medida de la calidad del prompt que se le entrega al LLM. Un prompt bien formulado contribuye a que el sistema genere resultados más coherentes y útiles con respecto a lo que se busca, al mismo tiempo que disminuye la necesidad de repetir o reformular la consulta.

Ilustración 4

Anatomía de un buen prompt



Fuente: (Brockman, 2025)

Según lo mencionado en la Ilustración 4, la efectividad de un modelo como o1 depende de cómo se diseña el prompt. En este sentido, se propone una estructura que considera el objetivo de lo que está buscando (Goal), el formato de salida esperado (Return Format), las restricciones (Warnings) y el contexto (Context Dump), con el fin de mejorar la calidad y utilidad de las respuestas.

Profundizando un poco en lo mencionado, debemos destacar 5 puntos importantes:

1. **Objetivo claro (Goal):** Indica con precisión qué debe hacer exactamente la IA. En esta parte se debe evitar la ambigüedad o la carencia de información. Se deben utilizar verbos claros y directos como analizar, resumir, explicar, comparar, entre otros. Ejemplo: "Analiza si conviene invertir en el fondo X considerando plazos de 1, 3, 6 y 12 meses."
2. **Formato de respuesta esperado (Return Format):** Define el formato de salida: lista, tabla, código, resumen, esquema, en un documento pdf, etc... Ejemplo: "Devuelve la información en formato de tabla, en donde las columnas sean: recomendación, justificación, riesgos y factores clave."
3. **Condiciones o restricciones (Warnings):** Especifica que debe evitarse o los cuidados especiales que la IA debe tener. Ejemplo: "No utilices tecnicismos; la respuesta debe ser de fácil comprensión, para un público con pocos conocimientos en el tema."
4. **Contexto adicional relevante (*Context Dump*):** Proporciona información extra para que la IA pueda entregar una respuesta personalizada y afinar, puede ser: perfil del usuario, finalidad de la tarea, entorno específico o datos. Ejemplo: "Soy estudiante de ingeniería y necesito esta información para una presentación sobre economía."

Finalmente se puede agregar un punto extra de manera opcional:

5. Observaciones opcionales: Consta de añadir advertencias o instrucciones adicionales, como: Ejemplo: "Si necesitas más información, me la puedes solicitar o preguntar antes de dar la repuesta final."

Según Google Cloud (What is prompt engineering?, s.f.), existen aspectos importantes a considerar para elaborar un buen prompt, aparte de la estructura que previamente mencionamos, un buen prompt debe cumplir con los siguientes principios:

- Claridad: la instrucción debe ser concreta, fácil de entender, sin necesidad de hacer interpretaciones o dicho de otra manera, sin ambigüedades.
- Especificidad: es mejor ser detallado con lo que se quiere (esto se apega mucho al punto anterior), se deben evitar generalizaciones.
- Contextualización: proporcionar información sobre el usuario, la tarea o el contexto, con el fin de mejorar la relevancia de la respuesta.
- Iterabilidad: un buen prompt permite ser ajustado o refinado en función del resultado anterior, dicho de otra manera, debe ser posible iterar el prompt para mejorarlo (en caso de no haber logrado del todo su objetivo).

También existen prácticas que permiten un mejor resultado a la hora de redactar un prompt:

1. Utilizar verbos precisos: redacta, resume, analiza, evalúa, clasifica, explica.
2. Definir roles solo si aporta claridad: por ejemplo, “actúa como un asesor financiero”.
Esto no es obligatorio, pero es útil.
3. En caso de ser posible, incluir ejemplos, especialmente cuando el formato de respuesta esperado es complejo.
4. Dividir tareas complejas: realizar primero una parte del análisis antes de pedir una conclusión global.
5. Dar espacio a la retroalimentación: incluir frases como “si necesitas más datos, házmelo saber antes de responder”, “si tienes dudas me las puedes consultar”.

5.9 Estado del arte en predicción financiera con IA y LLM

Numerosos estudios han explorado el uso de la IA en la predicción de mercados financieros, combinando datos numéricos y textuales para mejorar la precisión de las predicciones.

Dentro de estos estudios, se destaca el de Shuochen Bi, Jue Xiao y Tingting Deng, (*The Role of AI in Financial Forecasting: ChatGPT's Potential and Challenges*, 2025) en donde destacan que ChatGPT ha representado un punto de inflexión en el mundo de las finanzas. Su implementación ha dado paso a la automatización de tareas rutinarias, apoyo a la gestión de riesgos y optimización de procesos de análisis, llevando a lograr un mayor grado de productividad en las instituciones financieras. Estos subrayan que su valor no radica en sustituir al criterio humano, sino que apoyarlo para lograr potenciarlo mediante un procesamiento más eficiente de grandes volúmenes de información y la identificación de patrones en datos financieros.

Los experimentos realizados los autores evidencian que el LLM logra superar ciertos enfoques tradicionales en el análisis de sentimiento en titulares de prensa, mejorando la predicción de retornos bursátiles en el corto plazo. También, plantean que utilizar arquitecturas multimodales, que sean capaces de combinar reportes financieros, noticias, redes sociales y conferencias de resultados, permite la apertura de un campo prometedor para el desarrollo de sistemas de predicción más robustos. Sin embargo, los autores advierten que el uso de LLM de forma aislada como predictores financieros resulta ineficaz y riesgoso, siendo más adecuado concebirlos como herramientas complementarias a modelos especializados que fortalezcan la precisión de las proyecciones.

"Investigadores y profesionales han intentado predecir el mercado financiero analizando datos textuales (como artículos de noticias y redes sociales) y datos numéricos (como precios de

acciones y promedios móviles)" (Matin N. Ashtiani, 2023). Aunque el análisis de redes sociales ha sido un tema de estudio popular, las noticias financieras son igualmente importantes para predecir movimientos de mercado, ya que pueden influir en las decisiones de los inversores. Este tipo de análisis, conocido como minería de texto, ha demostrado ser efectivo en la identificación de patrones de comportamiento en el mercado.

Estudios recientes también han destacado el crecimiento en el uso de redes neuronales y modelos de deep learning para procesar grandes volúmenes de datos. A partir de 2018, las redes neuronales recurrentes (RNN) y otros modelos avanzados de procesamiento de lenguaje natural, como los transformadores, han demostrado mejorar la precisión en la predicción de mercados. Sin embargo, aún existen desafíos significativos, como los costos y el tiempo necesarios para recopilar datos, lo que ha llevado a muchos investigadores a desarrollar métodos personalizados de recolección de información.


El incremento en el número de patentes de IA es un claro indicativo del interés de las grandes corporaciones en desarrollar y aplicar esta tecnología. Empresas como Baidu, Tencent, IBM y Microsoft han aumentado sustancialmente sus familias de patentes de IA desde 2013, mostrando una tendencia sostenida en la inversión en investigación y desarrollo en este campo. En particular, la IA tiene aplicaciones crecientes en el sector financiero, donde se emplea en el análisis de datos, la automatización de procesos y la predicción de tendencias (Fernandez, 2024).

Empresas como Baidu, Tencent, IBM y Microsoft lideran a nivel mundial en el número de patentes de inteligencia artificial, mostrando una tendencia sostenida en la inversión en investigación y desarrollo en este campo (Fernández R. , 2024).

Este crecimiento en las patentes indica una fuerte apuesta por el avance de las aplicaciones de IA en diversos sectores, incluyendo el financiero.

Ilustración 5

Empresas con mayor número de patentes de inteligencia artificial en el mundo.



Fuente: (Fernández R. , 2024)

En la Ilustración 5 se presentan las empresas que lideran en el desarrollo de patentes de inteligencia artificial a nivel mundial. La alta inversión en patentes de IA refleja el potencial de esta tecnología para transformar sectores clave, entre ellos las finanzas, donde el análisis de datos y la predicción de tendencias son cada vez más relevantes para la toma de decisiones.

Si revisamos lo mencionado por Carlos González (Yahoo Finance, 2025), en el ámbito de las aplicaciones prácticas, no solo las instituciones financieras tradicionales han comenzado a experimentar con LLM's y sistemas basados en IA, sino que a su vez también han surgido

plataformas comerciales orientadas a facilitar la toma de decisiones de inversión. Un ejemplo de esto es InvestingPro, el cual reúne datos fundamentales, gráficos interactivos y análisis de mercado, incorporando además módulos de IA.

Los estudios revisados destacan que los LLM como ChatGPT no deben considerarse predictores aislados, sino herramientas de apoyo que fortalecen y facilitan la toma de decisiones financieras. Su aplicación ya se refleja en el ámbito empresarial, donde compañías y plataformas integran IA para mejorar el análisis de datos y la identificación de oportunidades en mercados dinámicos.

6 Metodología

6.1 Formato de trabajo

Para el desarrollo de la investigación se llevó a cabo utilizando el LLM ChatGPT, debido a que, como se mencionó anteriormente este es representativo dentro de los LLM's.

ChatGPT se utilizó en su modalidad de chat estándar, lo que permite mantener un flujo lineal y controlado en cada consulta. La razón de esta decisión se debe a la naturaleza del estudio, centrado en aplicar un único prompt fijo y evaluar sus resultados en distintos escenarios de predicción financiera, o en caso de ser necesario un prompt de observaciones adicionales.

Dado lo anterior, no se empleó la funcionalidad Proyecto de ChatGPT, debido a que su principal ventaja, la cual era la organización de múltiples subchats y archivos en un mismo entorno no aportaba un beneficio significativo para este análisis. Dicho de otra manera, cuando se utilizan prompts fijos y consultas puntuales, el uso de Proyectos introduce una complejidad innecesaria y no garantiza una mejora en los resultados.

En conclusión, el uso del chat común asegura que el proceso pueda ser reproducido sin depender de estructuras adicionales, que en este caso no aportaban ningún tipo de valor.

6.2 Fuentes de datos

Las principales fuentes utilizadas para extraer los datos necesarios, pertenecen al ámbito financiero y económico, entre ellas se encuentran Yahoo Finance, FRED (Federal Reserve Economic Data), CBO (Congressional Budget Office), BlackRock, BCE (Banco Central Europeo), Monrningstar, entre otras. También se incluyen repositorios académicos como SSRN, SciELO, Redalyc y similares.

Asimismo, se empleó como fuente ChatGPT, esto con el fin de que el mismo LLM indique que eventos históricos considera relevantes en la evolución de los activos financieros durante el periodo evaluado.

Las fuentes anteriormente mencionadas se consideran confiables debido a su respaldo institucional y su reconocimiento a nivel global. Agregando a esto su actualización constante y amplia cobertura temporal, lo que garantizan la validez y consistencia de la información utilizada, dando para un análisis riguroso y comparativo de los distintos mercados financieros.

6.3 Selección de fondos/activos

Para esta investigación se seleccionaron índices financieros y activos o fondos financieros de alta relevancia internacional: NASDAQ Composite (^IXIC), SPDR S&P 500 ETF (SPY), Euro-Dólar (EUR/USD), Bitcoin (BTC/USD), Oro (XAU/USD) y Petróleo Brent (BRENT Crude Oil). Esta selección de estos índices y activos se fundamenta en criterios de representatividad, disponibilidad de datos históricos y su relevancia a nivel global.

En primer lugar, se encuentra NASDAQ Composite, este fue seleccionado debido a su composición vinculada al sector tecnológico, el cual ha sido uno de los motores clave del crecimiento económico en las últimas décadas.


Esta característica hace que sea un índice con una alta correlación a cambios en el contexto macroeconómico. Asimismo, su volatilidad lo hace adecuado para evaluar la precisión de modelos predictivos en distintos horizontes temporales.

Hay que evitar confundirlo con NASDAQ-100, debido a que son distintos, este está formado por las 100 mayores empresas no financieras que cotizan en el Nasdaq (una bolsa de valores).

El segundo es S&P 500 ETF (SPY), el cual según lo que menciona Valora Analitik (¿Qué es el S&P 500 y por qué es tan importante para el mercado?, 2024) es uno de los índices bursátiles más seguido a nivel global. Este índice está compuesto de las 500 empresas de mayor capitalización en EEUU. Tiene un carácter diversificado, abarcando múltiples sectores económicos, lo que lo convierte en un referente sólido del desempeño general de la economía estadounidense, lo que se traduce en una alta correlación con los índices macroeconómicos del país.

Ilustración 6

Ranking de monedas y paridad cambiaria más negociados en el mercado Forex.



Fuente: (Bank for International Settlements, 2025).

En el ámbito de activos financieros, dentro de los seleccionados se encuentra la paridad Euro-Dólar (EUR/USD), debido a que es el cruce más transado en los mercados de divisas globales, tal como se indica en la Ilustración 6. Este indicador refleja la relación económica entre dos de las principales potencias económicas del mundo. Lo que conlleva a una alta

representatividad y exposición a eventos macroeconómicos lo que lo convierte en un indicador esencial para evaluar la capacidad predictiva de modelos basados en datos financieros.

Como segundo activo financiero, se eligió el Bitcoin (BTC/USD), debido a que es una de las criptomonedas más conocidas y la principal criptomoneda por capitalización de mercado, además de ser pionera en el sector de los activos digitales. Dentro de sus características esta su comportamiento volátil y su creciente integración en portafolios institucionales, lo que lo llevan a ser un activo atractivo para la investigación.

En tercer lugar, se considera el Oro (XAU/USD), debido a que “El Oro es el activo refugio histórico por excelencia” (Estrategias de Inversión, 2025) por lo que se le puede considerar un activo refugio en periodos de inestabilidad económica o política.

Finalmente, se seleccionó el Petróleo Brent (BRENT Crude Oil), aunque el crudo WTI es más utilizado en el mercado estadounidense, se escogió el Brent debido a su mayor representatividad en transacciones internacionales. Debido a que el petróleo es uno de los insumos esenciales en la economía mundial, su comportamiento es un reflejo de los impactos de eventos geopolíticos, y decisiones de organismos internacionales, entre otras cosas. Incluirlo en el análisis permite enriquecer la investigación con un activo que conecta directamente los mercados financieros con la economía real.

6.4 Datos recolectados

6.4.1 NASDAQ Composite (^IXIC)

Tabla 1

Características generales del fondo NASDAQ Composite (^IXIC)

Origen del Índice	Estados Unidos
Nombre del Índice	NASDAQ Composite (^IXIC)
Perfil de Riesgo	Alto
Tipo de Fondo	Índice de Renta Variable (Indexado)
Moneda Base	USD

Fuente: Elaboración propia a partir de (Rhinehart, 2024)

La Tabla 1 indica los principales atributos del índice NASDAQ Composite, incluyendo su origen, nivel de riesgo, tipo de fondo y moneda base. Se incorpora para contextualizar la naturaleza del activo analizado, destacando su carácter de renta variable y su exposición al mercado estadounidense.

Tabla 2

Rentabilidad histórica del fondo NASDAQ Composite (^IXIC) y su índice de referencia (2015-2020)

Año	Rentabilidad total (%)	Índice de Referencia (%)
2015	5,73	9,3
2016	7,5	6,8
2017	28,24	32,5
2018	-3,88	-0,3
2019	35,23	39
2020	43,64	48,5

Fuente: Elaboración propia a partir de (BlackRock, (s.f.)) y (Wikipedia, 2025).

En la Tabla 2 se indican las tasas anuales de rentabilidad del NASDAQ Composite y de su índice de referencia. Su propósito es indicar el desempeño del fondo frente al promedio de su categoría desde el año 2015 al 2020. Estos datos son importantes para analizar la consistencia del fondo y su capacidad de superar los rendimientos del mercado general.

Tabla 3*Datos históricos NASDAQ Composite*

Fecha	Cierre Ajustado	Fecha	Cierre Ajustado	Fecha	Cierre Ajustado
1 dic 2020	12888,28	1 may 2018	7442,12	1 ago 2015	4776,51
1 nov 2020	12198,74	1 abr 2018	7066,27	1 jul 2015	5128,28
1 oct 2020	10911,59	1 mar 2018	7063,01	1 jun 2015	4986,87
1 sept 2020	11167,51	1 feb 2018	7273,01	1 may 2015	5070,03
1 ago 2020	11775,46	1 ene 2018	7411,48	1 abr 2015	4941,42
1 jul 2020	10745,27	1 dic 2017	6903,39	1 mar 2015	4900,88
1 jun 2020	10058,77	1 nov 2017	6873,97	1 feb 2015	4963,53
1 may 2020	9489,87	1 oct 2017	6727,67	1 ene 2015	4635,24
1 abr 2020	8889,55	1 sept 2017	6495,96	1 dic 2014	4736,05
1 mar 2020	7700,1	1 ago 2017	6428,66	1 nov 2014	4791,63
1 feb 2020	8567,37	1 jul 2017	6348,12	1 oct 2014	4630,74
1 ene 2020	9150,94	1 jun 2017	6140,42	1 sept 2014	4493,39
1 dic 2019	8972,6	1 may 2017	6198,52	1 ago 2014	4580,27
1 nov 2019	8665,47	1 abr 2017	6047,61	1 jul 2014	4369,77
1 oct 2019	8292,36	1 mar 2017	5911,74	1 jun 2014	4408,18
1 sept 2019	7999,34	1 feb 2017	5825,44	1 may 2014	4242,62
1 ago 2019	7962,88	1 ene 2017	5614,79	1 abr 2014	4114,56
1 jul 2019	8175,42	1 dic 2016	5383,12	1 mar 2014	4198,99
1 jun 2019	8006,24	1 nov 2016	5323,68	1 feb 2014	4308,12
1 may 2019	7453,15	1 oct 2016	5189,14	1 ene 2014	4103,88
1 abr 2019	8095,39	1 sept 2016	5312	1 dic 2013	4176,59
1 mar 2019	7729,32	1 ago 2016	5213,22	1 nov 2013	4059,89
1 feb 2019	7532,53	1 jul 2016	5162,13	1 oct 2013	3919,71
1 ene 2019	7281,74	1 jun 2016	4842,67	1 sept 2013	3771,48
1 dic 2018	6635,28	1 may 2016	4948,05	1 ago 2013	3589,87
1 nov 2018	7330,54	1 abr 2016	4869,36	1 jul 2013	3626,37
1 oct 2018	7305,9	1 mar 2016	4775,36	1 jun 2013	3403,25
1 sept 2018	8046,35	1 feb 2016	4557,95	1 may 2013	3455,91
1 ago 2018	8109,54	1 ene 2016	4613,95	1 abr 2013	3328,79
1 jul 2018	7671,79	1 dic 2015	5007,41	1 mar 2013	3267,52
1 jun 2018	7510,3	1 nov 2015	5108,67	1 feb 2013	3160,19
		1 oct 2015	5053,75		
		1 sept 2015	4620,16		

Fuente: Extraído de (Yahoo Finance, 2025).

La Tabla 3 indica los valores de cierre ajustado de manera mensual, del índice en el periodo a analizar (2015 a 2020). Esta información es utilizada como base cuantitativa para la predicción de tendencias y estacionalidades, ciclicidades o irregularidades por parte del LLM.

Tabla 4

Eventos históricos con impactos en el índice según el LLM

Año	Evento	Descripción	Impacto en el Fondo
2013	Caída del petróleo	Pasa de >100 USD a <50 USD/barril	Energía cae, consumo se fortalece
2014	Tensión Rusia-Ucrania (Crimea)	Inestabilidad geopolítica	Leve impacto
2015	Crisis en China	Bolsa china colapsa, devaluación del yuan	Fondo cae 10%
2015	Caída en commodities	Petróleo, cobre, etc. en mínimos	Presión a sectores industriales
2015	Subida de tasas por la Fed	Primera alza en casi 10 años (diciembre)	Cambio de ciclo monetario
2016	Brexit	Reino Unido vota salir de la UE	Caída de 5% en Fondo en 2 días, luego rebote
2016	Elección de Trump	Sorpresa electoral → impulso a sectores cíclicos	Fondo sube fuerte desde noviembre
2017	Reforma tributaria	Rebaja de impuestos corporativos al 21%	Fondo sube con fuerza todo el año
2017	Baja volatilidad histórica	Prácticamente sin correcciones >5%	Subida tranquila y estable
2018	Guerra comercial EE.UU.-China	Aranceles y tensiones bilaterales	Caídas intermitentes
2018	Subidas agresivas de tasas por la Fed	4 alzas de tasas en el año	Fondo cae ~20% en Q4
2018	Volatilidad repunta	VIX alcanza máximos de 2 años	Inversores defensivos
2019	Tregua comercial parcial	EE.UU. y China firman “fase 1”	Confianza se recupera
2019	Bajas de tasas por la Fed	3 recortes de tasas en el año	Impulso adicional al Fondo

2019	Inversión de curva de rendimientos	Riesgo de recesión percibida	Alerta en mercados
2020	Pandemia COVID-19	Cierre global de economías en marzo	Fondo cae ~34% en 1 mes
2020	Intervención sin precedentes Fed y Congreso	Estímulo monetario y fiscal masivo	Fondo se recupera y marca máximos en agosto
2020	Elecciones presidenciales	Biden gana, expectativas de más gasto fiscal	Positiva para sectores “verdes”

Fuente: (ChatGPT, 2025).

En la Tabla 4 se listan los principales eventos económicos, políticos y financieros identificados por la inteligencia artificial (ChatGPT) que afectan la evolución del NASDAQ Composite entre 2013 y 2020. Esta incluye acontecimientos como crisis financieras, políticas monetarias, elecciones presidenciales y tensiones geopolíticas. Su finalidad es contextualizar las fluctuaciones del índice y reconocer la influencia de factores exógenos sobre su rendimiento.

Tabla 5

Indicadores macroeconómicos trimestrales: PIB nominal, PIB real (ambos en billones de dólares) e índice de precios (2013–2025) de EEUU

date_fmt	PIB nominal	PIB real	Índice de precios	date_fmt	PIB nominal	PIB real	Índice de precios
2013-01	16569,6	16383	100,982	2019-07	21542,5	19121,1	109,928
2013-04	16637,9	16403,2	101,057	2019-10	21729,1	19222	110,301
2013-07	16848,7	16531,7	101,466	2020-01	21539,7	18977,4	110,661
2013-10	17083,1	16663,6	101,88	2020-04	19245,81	17062,72	110,1118
2014-01	17104,6	16616,5	102,357	2020-07	20082,37	17744,89	110,5537
2014-04	17432,9	16841,5	102,846	2020-10	20488,53	18087,13	110,7384
2014-07	17721,7	17047,1	103,123	2021-01	20828,27	18352,14	110,9793
2014-10	17849,9	17143	102,992	2021-04	21159,47	18582,49	111,3599
2015-01	17984,2	17277,6	102,542	2021-07	21513,47	18822,71	111,7851
2015-04	18219,4	17405,7	103,048	2021-10	21750,64	18959,97	112,1681
2015-07	18344,7	17463,2	103,339	2022-01	21967,63	19069,86	112,61
2015-10	18350,8	17468,9	103,253	2022-04	22182,42	19169,12	113,1043
2016-01	18424,3	17556,8	103,297	2022-07	22406,99	19272,03	113,6176
2016-04	18637,3	17639,4	103,91	2022-10	22634,91	19377,15	114,1142
2016-07	18806,7	17735,1	104,344	2023-01	22863,99	19482,57	114,6137
2016-10	18991,9	17824,2	104,812	2023-04	23083,63	19574,97	115,137
2017-01	19190,4	17925,3	105,355	2023-07	23318,92	19677,69	115,6672

2017-04	19356,6	18021	105,596	2023-10	23567,58	19790,17	116,1967
2017-07	19611,7	18163,6	106,033	2024-01	23828,95	19908,3	116,7516
2017-10	19918,9	18322,5	106,733	2024-04	24085,79	20019,89	117,316
2018-01	20163,2	18438,3	107,401	2024-07	24340,44	20128,7	117,8821
2018-04	20510,2	18598,1	107,988	2024-10	24599,65	20239,54	118,4537
2018-07	20749,8	18732,7	108,413	2025-01	24871,54	20360,01	119,0217
2018-10	20897,8	18783,5	108,772	2025-04	25146,49	20480,2	119,5996
2019-01	21098,8	18927,3	108,879	2025-07	25424,23	20600,73	120,1821
2019-04	21340,3	19021,9	109,522	2025-10	25704,31	20721,63	120,7663

Fuente: (Congressional Budget Office (CBO), 2025).

Esta tabla reúne variables macroeconómicas clave como el PIB nominal, PIB real y el índice de precios. Su incorporación permite relacionar el desempeño del mercado bursátil con el entorno macroeconómico estadounidense, integrando factores de crecimiento, inflación y producción en el análisis.

6.4.2 SPDR S&P 500 ETF (SPY)

Tabla 6

Características generales del fondo SPDR S&P 500 ETF (SPY)

Origen del Fondo	Estados Unidos
Nombre del Fondo	SPDR S&P 500 ETF (SPY)
Perfil de Riesgo	Medio - Alto
Tipo de Fondo	ETF Renta Variable (Indexado)
Moneda Base	USD

Fuente: Elaboración propia.

La Tabla 6 presenta las principales características del fondo SPDR S&P 500 ETF (SPY), destacando su origen estadounidense, su naturaleza como fondo indexado de renta variable y su perfil de riesgo medio-alto.

Tabla 7

Comparativa rentabilidades anuales entre SPY y la categoría

Rentabilidad Anual		
Año	SPY	Categoría
2020	18,37%	15,83%
2019	31,22%	28,78%
2018	-4,56%	-6,27%
2017	21,70%	20,44%
2016	12,00%	10,37%
2015	1,25%	-1,07%
2014	13,46%	10,96%
2013	32,31%	31,50%
2012	15,99%	14,96%
2011	1,89%	-1,27%
2010	15,06%	14,01%

Fuente: Extraído de (Yahoo Finance, 2025).

La Tabla 7 muestra la rentabilidad anual del fondo SPY en comparación con la de su categoría. Se observan variaciones coherentes respecto a la categoría, evidenciando que el fondo replica los movimientos del mercado.

Tabla 8

Indicadores financieros y técnicos de los fondos analizados: Cierre ajustado, RSI (14) e IPC promedio (2011–2020).

Fecha	Cierre ajustado	RSI 14	IPC Todos los ítemes	Fecha	Cierre ajustado	RSI 14	IPC Todos los ítemes
2020-12-01	349,52	68,7363511	260,47	2015-12-01	172,75	58,8896632	236,53
2020-11-01	338,47	66,8141008	260,23	2015-11-01	176,83	62,7463234	237,34
2020-10-01	305,26	59,9402439	260,39	2015-10-01	176,19	62,3875343	237,84
2020-09-01	311,82	62,3074561	260,28	2015-09-01	161,54	52,7058622	237,95
2020-08-01	325,25	67,3650106	259,92	2015-08-01	166,63	57,479231	238,32
2020-07-01	304,03	62,9529801	259,10	2015-07-01	177,45	69,991503	238,65
2020-06-01	285,86	58,4910628	257,80	2015-06-01	172,69	67,0625662	238,64
2020-05-01	282,12	57,5130241	256,39	2015-05-01	177,12	73,2402809	237,81
2020-04-01	269,29	54,0653586	256,39	2015-04-01	174,88	72,0305429	236,60
2020-03-01	237,55	43,5409274	258,12	2015-03-01	172,40	70,6672752	236,12
2020-02-01	273,04	57,1319339	258,68	2015-02-01	175,94	75,5480321	234,72
2020-01-01	296,51	70,6798297	257,97	2015-01-01	166,57	70,5485203	233,71
2019-12-01	295,18	70,3093482	256,97	2014-12-01	170,72	77,0254933	234,81
2019-11-01	288,26	68,3789539	257,21	2014-11-01	172,10	79,2727592	236,15
2019-10-01	278,19	65,3333234	257,35	2014-10-01	167,49	77,2102459	237,43
2019-09-01	270,92	62,9404403	256,76	2014-09-01	162,88	74,8900983	238,03
2019-08-01	266,98	61,6067936	256,56	2014-08-01	165,93	79,8865766	237,85
2019-07-01	271,52	64,0739517	256,57	2014-07-01	159,63	76,9350387	238,25
2019-06-01	266,18	62,4307075	256,14	2014-06-01	161,03	79,3374275	238,34

2019-05-01	250,08	56,9132886	256,09	2014-05-01	158,53	78,2091373	237,90
2019-04-01	267,11	66,5066835	255,55	2014-04-01	154,94	76,4978888	237,07
2019-03-01	255,50	62,5058029	254,20	2014-03-01	153,19	75,6316789	236,29
2019-02-01	252,06	61,231666	252,78	2014-02-01	152,60	75,3472253	234,78
2019-01-01	244,15	58,1986423	251,71	2014-01-01	145,96	71,9220524	233,92
2018-12-01	224,74	49,130445	251,23	2013-12-01	150,47	78,8297031	233,05
2018-11-01	247,88	64,6581366	252,04	2013-11-01	147,47	77,4945992	233,07
2018-10-01	243,36	62,5089496	252,89	2013-10-01	143,22	75,4586365	233,55
2018-09-01	260,25	79,2259691	252,44	2013-09-01	136,22	71,5178779	234,15
2018-08-01	259,88	79,1123389	252,15	2013-08-01	132,68	69,1950201	233,88
2018-07-01	251,84	76,5210127	252,01	2013-07-01	136,79	75,865355	233,60
2018-06-01	241,76	72,5575482	251,99	2013-06-01	129,38	71,2208114	233,50
2018-05-01	241,46	72,4289232	251,59	2013-05-01	131,83	75,6930102	232,95
2018-04-01	235,73	69,9291734	250,55	2013-04-01	128,78	73,7905236	232,53
2018-03-01	233,58	68,9482665	249,55	2013-03-01	125,80	71,7871144	232,77
2018-02-01	241,13	77,1549998	248,99	2013-02-01	121,73	68,7585565	232,17
2018-01-01	250,22	88,9979286	247,87	2013-01-01	120,20	67,5423195	230,28
2017-12-01	235,67	85,7459493	246,52	2012-12-01	113,54	61,4811152	229,60
2017-11-01	234,03	85,2909032	246,67	2012-11-01	113,33	61,269349	230,22
2017-10-01	227,09	83,181079	246,66	2012-10-01	112,70	60,6669601	231,32
2017-09-01	220,77	80,8594818	246,82	2012-09-01	114,18	62,7975577	231,41
2017-08-01	217,48	79,4910394	245,52	2012-08-01	111,95	60,8750808	230,38
2017-07-01	216,85	79,2269611	244,79	2012-07-01	109,21	58,4237855	229,10

2017-06-01	211,45	76,8549553	244,96	2012-06-01	107,38	56,7429914	229,48
2017-05-01	211,14	76,7132101	244,73	2012-05-01	103,73	53,2420738	229,82
2017-04-01	208,20	75,3856962	244,52	2012-04-01	110,35	61,6443988	230,09
2017-03-01	205,26	74,0099047	243,80	2012-03-01	110,61	62,0012404	229,39
2017-02-01	205,90	74,8556461	243,60	2012-02-01	107,63		227,66
2017-01-01	198,11	71,1263957	242,84	2012-01-01	103,16		226,67
2016-12-01	193,49	68,5583275	241,43	2011-12-01	97,96		225,67
2016-11-01	190,76	66,9451713	241,35	2011-11-01	97,56		226,23
2016-10-01	183,98	62,5093257	241,73	2011-10-01	97,96		226,42
2016-09-01	186,29	65,2808915	241,43	2011-09-01	87,87		226,89
2016-08-01	187,22	66,381193	240,85	2011-08-01	94,91		226,55
2016-07-01	186,99	66,2505601	240,63	2011-07-01	100,43		225,92
2016-06-01	179,48	61,7433893	241,02	2011-06-01	101,98		225,72
2016-05-01	179,79	62,0610722	240,23	2011-05-01	104,24		225,96
2016-04-01	176,78	60,2154719	239,26	2011-04-01	105,42		224,91
2016-03-01	175,19	59,2429456	238,13	2011-03-01	102,01		223,47
2016-02-01	164,99	52,2966293	237,11	2011-02-01	102,44		221,31
2016-01-01	165,13	52,410474	236,92	2011-01-01	99,00		220,22

Fuente: Extraído de (Banco Mundial, 2024).

La Tabla 8 contiene indicadores financieros y técnicos del fondo SPY, donde se incluyen el cierre ajustado, el RSI (Relative Strength Index) y el IPC promedio (1982–1984=100). Estos indicadores apoyan la evaluación del desempeño del fondo y su comportamiento frente a la

inflación, así como la identificación de ciclos de sobrecompra o sobreventa en el periodo 2011–2020.

Tabla 9

Eventos históricos con impactos en el índice según el LLM

Año	Evento	Descripción	Impacto en el Fondo
2010	Inyección de liquidez (QE2)	La Fed lanza un nuevo programa de estímulo monetario	Impulso al mercado
	Crisis en Europa	Grecia, Irlanda y Portugal en crisis de deuda	Volatilidad externa
2011	Crisis de deuda europea	España e Italia bajo presión, rescate a Grecia	Alta volatilidad global
	“Fiscal cliff”	Riesgo de aumentos masivos de impuestos y recortes de gasto en EE.UU.	Inestabilidad en Q4
2012	Continuación QE3 anticipado	Estímulo sostenido de la Fed	Estabilidad de mercado
	“Taper tantrum”	Bernanke anuncia retiro de QE gradualmente	Caídas temporales en acciones y bonos

2013	Caída del petróleo	Pasa de >100 USD a <50 USD/barril	Energía cae, consumo se fortalece
	Tensión Rusia-Ucrania (Crimea)	Inestabilidad geopolítica	Leve impacto
2014	Crisis en China	Bolsa china colapsa, devaluación del yuan	Fondo cae 10%
	Caída en commodities	Petróleo, cobre, etc. en mínimos	Presión a sectores industriales
2015	Subida de tasas por la Fed	Primera alza en casi 10 años (diciembre)	Cambio de ciclo monetario
	Brexit	Reino Unido vota salir de la UE	Caída de 5% en Fondo en 2 días, luego rebote
	Elección de Trump	Sorpresa electoral → impulso a sectores cíclicos	Fondo sube fuerte desde noviembre
2016	Reforma tributaria	Rebaja de impuestos corporativos al 21%	Fondo sube con fuerza todo el año

	Baja volatilidad histórica	Prácticamente sin correcciones >5%	Subida tranquila y estable
2017	Guerra comercial EE.UU.-China	Aranceles y tensiones bilaterales	Caídas intermitentes
	Subidas agresivas de tasas por la Fed	4 alzas de tasas en el año	Fondo cae ~20% en Q4
2018	Volatilidad repunta	VIX alcanza máximos de 2 años	Inversores defensivos
	Tregua comercial parcial	EE.UU. y China firman “fase 1”	Confianza se recupera
	Bajas de tasas por la Fed	3 recortes de tasas en el año	Impulso adicional al Fondo
2019	Inversión de curva de rendimientos	Riesgo de recesión percibida	Alerta en mercados
	Pandemia COVID-19	Cierre global de economías en marzo	Fondo cae ~34% en 1 mes

	Intervención sin precedentes de la Fed y el Congreso	Estímulo monetario y fiscal masivo	Fondo se recupera y marca máximos en agosto
2020	Elecciones presidenciales	Biden gana, expectativas de más gasto fiscal	Positiva para sectores “verdes”

Fuente: (ChatGPT, 2025).

La Tabla 9 detalla los principales eventos históricos ocurridos durante el periodo de análisis que, según el modelo de lenguaje (LLM), influyeron en el fondo SPY. Se incluyen acontecimientos como la inyección de liquidez, la guerra comercial entre EE. UU. y China, y las intervenciones de la Reserva Federal, los cuales tuvieron impactos directos en el rendimiento del fondo y en la dinámica del mercado accionario.

Para complementar y apoyar el análisis del fondo SPY, se utiliza también la Tabla 5, correspondiente a los indicadores macroeconómicos trimestrales de los Estados Unidos (PIB nominal, PIB real e índice de precios) empleados previamente en el análisis del NASDAQ Composite. Estos datos permiten relacionar los movimientos del fondo con el contexto económico general de los Estados Unidos durante el mismo periodo.

6.4.3 Euro–Dólar (EUR/USD)

Tabla 10

Características generales del Fondo EUR/USD.

Origen del Fondo	Zona Euro / Estados Unidos
Nombre del Fondo	Exchange Rate
Perfil de Riesgo	Alto (alta volatilidad, sensible a tasas de interés y geopolítica)
Tipo de Fondo	Par de Divisas / Mercado Forex (Indexado)
Moneda Base	USD

Fuente: Extraído de (Bargigli, 2025)

La Tabla 10 presenta un resumen de los antecedentes básicos del par de divisas EUR/USD, (tipo de cambio entre el euro y el dólar estadounidense). Se clasifica como un activo de renta variable indexado al mercado Forex, caracterizado por una alta volatilidad debido a su sensibilidad frente a políticas monetarias (especialmente de la Fed y el BCE) y a factores geopolíticos. Se considera como moneda base el dólar (USD).

Tabla 11*Datos históricos del cambio EUR/USD.*

Fecha	Cierre Ajustado	Fecha	Cierre Ajustado	Fecha	Cierre Ajustado
1 dic 2020	1,23	1 may 2018	1,1667	1 sept 2015	1,1256
1 nov 2020	1,1971	1 abr 2018	1,2123	1 ago 2015	1,1214
1 oct 2020	1,1677	1 mar 2018	1,2332	1 jul 2015	1,0939
1 sept 2020	1,1742	1 feb 2018	1,223	1 jun 2015	1,1223
1 ago 2020	1,1918	1 ene 2018	1,241	1 may 2015	1,096
1 jul 2020	1,1872	1 dic 2017	1,2	1 abr 2015	1,1114
1 jun 2020	1,1247	1 nov 2017	1,1852	1 mar 2015	1,083
1 may 2020	1,111	1 oct 2017	1,1653	1 feb 2015	1,1198
1 abr 2020	1,0877	1 sept 2017	1,1742	1 ene 2015	1,1288
1 mar 2020	1,03	1 ago 2017	1,1893	1 dic 2014	1,2162
1 feb 2020	1,03	1 jul 2017	1,1747	1 nov 2014	1,2438
1 ene 2020	1,1029	1 jun 2017	1,1442	1 oct 2014	1,2613
1 dic 2019	1,1202	1 may 2017	1,1172	1 sept 2014	1,2691
1 nov 2019	1,102	1 abr 2017	1,0908	1 ago 2014	1,3135
1 oct 2019	1,1154	1 mar 2017	1,0687	1 jul 2014	1,3369
1 sept 2019	1,0943	1 feb 2017	1,0584	1 jun 2014	1,3644
1 ago 2019	1,1012	1 ene 2017	1,0709	1 may 2014	1,3635
1 jul 2019	1,1158	1 dic 2016	1,052	1 abr 2014	1,3814
1 jun 2019	1,1391	1 nov 2016	1,0648	1 mar 2014	1,3752
1 may 2019	1,1131	1 oct 2016	1,0985	1 feb 2014	1,3707
1 abr 2019	1,1185	1 sept 2016	1,122	1 ene 2014	1,3559
1 mar 2019	1,1233	1 ago 2016	1,1153	1 dic 2013	1,381
1 feb 2019	1,138	1 jul 2016	1,1168	1 nov 2013	1,3594
1 ene 2019	1,1488	1 jun 2016	1,1128	1 oct 2013	1,3724
1 dic 2018	1,144	1 may 2016	1,1148	1 sept 2013	1,3495
1 nov 2018	1,1393	1 abr 2016	1,1382	1 ago 2013	1,3224
1 oct 2018	1,1346	1 mar 2016	1,1335	1 jul 2013	1,3265
1 sept 2018	1,1623	1 feb 2016	1,0924	1 jun 2013	1,3013
1 ago 2018	1,1667	1 ene 2016	1,0826	1 may 2013	1,3044
1 jul 2018	1,1707	1 dic 2015	1,0934	1 abr 2013	1,3096
1 jun 2018	1,1705	1 nov 2015	1,0583	1 mar 2013	1,2808

1 may 2018	1,1667	1 oct 2015	1,1009	1 feb 2013	1,316
1 abr 2018	1,2123			1 ene 2013	1,3568

Fuente: Extraído de (Yahoo Finance, (s.f.))

Tal como se muestra en la Tabla 11, se puede apreciar la evolución mensual del tipo de cambio EUR/USD durante el período 2013 a 2020, expresada mediante el cierre ajustado. Estos datos reflejan la fluctuación relativa entre ambas monedas.

Tabla 12

Eventos históricos con impactos en el fondo según el LLM.

Año	Evento	Descripción	Impacto en el EUR/USD
2013	Crisis de deuda en la Eurozona (residual)	Persisten tensiones en países como Grecia e Italia	Presión bajista sobre el euro, fortalece al dólar
2014	Crisis en Ucrania / Sanciones a Rusia	Inestabilidad geopolítica, sanciones de UE y EE.UU.	Euro cae frente al dólar por aversión al riesgo
2014	Política monetaria expansiva del BCE	Anuncio de Mario Draghi sobre estímulos monetarios	Euro se deprecia frente al dólar
2015	Quantitative Easing (BCE)	BCE inicia programa masivo de compra de activos	EUR/USD cae hasta niveles de 1,05
2015	Crisis de Grecia (Grexit)	Riesgo de salida de Grecia del euro	Incrementa la volatilidad, euro presionado a la baja
2016	Brexit (Reino Unido vota salir de la UE)	Shock en Europa con implicancias políticas y económicas	Euro cae frente al dólar por incertidumbre
2016	Elección de Trump en EE.UU.	Apuesta por políticas fiscales expansivas y dólar fuerte	Dólar se fortalece, el EUR/USD cae
2017	Reforma tributaria de EE.UU.	Rebaja de impuestos corporativos impulsa la economía estadounidense	Dólar se fortalece, euro retrocede
2018	Guerra comercial EE.UU.-China	Tensión global, aversión al riesgo	Dólar se percibe como refugio, presión bajista sobre el euro
2019	Inversión de curva de rendimientos en EE.UU.	Riesgo de recesión percibido	Aumenta volatilidad, euro se mueve lateral pero mantiene debilidad frente al dólar

2020	Pandemia COVID-19	Crisis sanitaria y económica global	En marzo: euro cae fuerte vs. dólar; después: estímulos masivos del BCE y Fed impulsan recuperación del euro
2020	Estímulo fiscal y monetario sin precedentes	FED baja tasas a 0% y BCE refuerza estímulos	EUR/USD se aprecia en el segundo semestre
2020	Elecciones presidenciales EE.UU.	Biden gana, expectativas de más gasto fiscal	Anticipa presión a la baja en el dólar → fortalecimiento del euro
2021 (previsto desde 2020)	Brexit definitivo (salida comercial)	Fin del periodo de transición en enero 2021	Se anticipaba volatilidad en el euro por la nueva relación UE-Reino Unido

Fuente: (OpenAI, (s.f.))

La

Tabla **12** resume los principales eventos históricos y geopolíticos que impactaron significativamente la cotización del EUR/USD entre 2013 a 2020, con un echo previsto para el año 2021, de acuerdo con la interpretación del modelo LLM.

Entre estos eventos, se destacan las elecciones presidenciales en Estados Unidos (2020), las cuales generaron presión a la baja en el dólar y fortalecimiento del euro ante expectativas de estímulo fiscal, y el Brexit definitivo (2021), el cual incrementó la volatilidad en el euro debido a la redefinición de las relaciones comerciales entre la Unión Europea y el Reino Unido.

Tabla 13*Evolución histórica de la tasa de fondos federales (Fed Funds Rate)*

Observation date	FEDFUNDS	Observation date	FEDFUNDS	Observation date	FEDFUNDS
2013-01-01	0,14	2015-09-01	0,14	2018-05-01	1,70
2013-02-01	0,15	2015-10-01	0,12	2018-06-01	1,82
2013-03-01	0,14	2015-11-01	0,12	2018-07-01	1,91
2013-04-01	0,15	2015-12-01	0,24	2018-08-01	1,91
2013-05-01	0,11	2016-01-01	0,34	2018-09-01	1,95
2013-06-01	0,09	2016-02-01	0,38	2018-10-01	2,19
2013-07-01	0,09	2016-03-01	0,36	2018-11-01	2,20
2013-08-01	0,08	2016-04-01	0,37	2018-12-01	2,27
2013-09-01	0,08	2016-05-01	0,37	2019-01-01	2,40
2013-10-01	0,09	2016-06-01	0,38	2019-02-01	2,40
2013-11-01	0,08	2016-07-01	0,39	2019-03-01	2,41
2013-12-01	0,09	2016-08-01	0,40	2019-04-01	2,42
2014-01-01	0,07	2016-09-01	0,40	2019-05-01	2,39
2014-02-01	0,07	2016-10-01	0,40	2019-06-01	2,38
2014-03-01	0,08	2016-11-01	0,41	2019-07-01	2,40
2014-04-01	0,09	2016-12-01	0,54	2019-08-01	2,13
2014-05-01	0,09	2017-01-01	0,65	2019-09-01	2,04
2014-06-01	0,10	2017-02-01	0,66	2019-10-01	1,83
2014-07-01	0,09	2017-03-01	0,79	2019-11-01	1,55
2014-08-01	0,09	2017-04-01	0,90	2019-12-01	1,55
2014-09-01	0,09	2017-05-01	0,91	2020-01-01	1,55
2014-10-01	0,09	2017-06-01	1,04	2020-02-01	1,58
2014-11-01	0,09	2017-07-01	1,15	2020-03-01	0,65
2014-12-01	0,12	2017-08-01	1,16	2020-04-01	0,05
2015-01-01	0,11	2017-09-01	1,15	2020-05-01	0,05
2015-02-01	0,11	2017-10-01	1,15	2020-06-01	0,08
2015-03-01	0,11	2017-11-01	1,16	2020-07-01	0,09
2015-04-01	0,12	2017-12-01	1,30	2020-08-01	0,10
2015-05-01	0,12	2018-01-01	1,41	2020-09-01	0,09
2015-06-01	0,13	2018-02-01	1,42	2020-10-01	0,09
2015-07-01	0,13	2018-03-01	1,51	2020-11-01	0,09
2015-08-01	0,14	2018-04-01	1,69	2020-12-01	0,09

Fuente: Extraído de (FRED, 2025)

En la Tabla 13 se representa la evolución de la tasa de política monetaria de la Reserva Federal (Fed Funds Rate o FEDFUNDS) entre 2015 y 2020. Se considera que esta tasa influye directamente en el valor del dólar estadounidense, afectando al par EUR/USD.

Durante el período analizado, se observan fases de aumento gradual (2016–2018) asociadas al endurecimiento monetario de la Fed, seguidas por una reducción significativa en 2019–2020 como respuesta al debilitamiento económico y los efectos de la pandemia.

Se puede apreciar que indicador se relaciona estrechamente con los cambios en el tipo de cambio mostrados en la Tabla 11, lo que demuestra que este indicador puede ser especialmente útil en explicar el par EUR/USD.

Tabla 14*Evolución histórica de la tasa de refinanciación principal del Banco Central Europeo*

Observation date	ECBMLFR	Observation date	ECBMLFR	Observation date	ECBMLFR
2013-01-01	1,50	2015-09-01	0,30	2018-05-01	0,25
2013-02-01	1,50	2015-10-01	0,30	2018-06-01	0,25
2013-03-01	1,50	2015-11-01	0,30	2018-07-01	0,25
2013-04-01	1,50	2015-12-01	0,30	2018-08-01	0,25
2013-05-01	1,11	2016-01-01	0,30	2018-09-01	0,25
2013-06-01	1,00	2016-02-01	0,30	2018-10-01	0,25
2013-07-01	1,00	2016-03-01	0,27	2018-11-01	0,25
2013-08-01	1,00	2016-04-01	0,25	2018-12-01	0,25
2013-09-01	1,00	2016-05-01	0,25	2019-01-01	0,25
2013-10-01	1,00	2016-06-01	0,25	2019-02-01	0,25
2013-11-01	0,85	2016-07-01	0,25	2019-03-01	0,25
2013-12-01	0,75	2016-08-01	0,25	2019-04-01	0,25
2014-01-01	0,75	2016-09-01	0,25	2019-05-01	0,25
2014-02-01	0,75	2016-10-01	0,25	2019-06-01	0,25
2014-03-01	0,75	2016-11-01	0,25	2019-07-01	0,25
2014-04-01	0,75	2016-12-01	0,25	2019-08-01	0,25
2014-05-01	0,75	2017-01-01	0,25	2019-09-01	0,25
2014-06-01	0,52	2017-02-01	0,25	2019-10-01	0,25
2014-07-01	0,40	2017-03-01	0,25	2019-11-01	0,25
2014-08-01	0,40	2017-04-01	0,25	2019-12-01	0,25
2014-09-01	0,33	2017-05-01	0,25	2020-01-01	0,25
2014-10-01	0,30	2017-06-01	0,25	2020-02-01	0,25
2014-11-01	0,30	2017-07-01	0,25	2020-03-01	0,25
2014-12-01	0,30	2017-08-01	0,25	2020-04-01	0,25
2015-01-01	0,30	2017-09-01	0,25	2020-05-01	0,25
2015-02-01	0,30	2017-10-01	0,25	2020-06-01	0,25
2015-03-01	0,30	2017-11-01	0,25	2020-07-01	0,25
2015-04-01	0,30	2017-12-01	0,25	2020-08-01	0,25
2015-05-01	0,30	2018-01-01	0,25	2020-09-01	0,25
2015-06-01	0,30	2018-02-01	0,25	2020-10-01	0,25
2015-07-01	0,30	2018-03-01	0,25	2020-11-01	0,25
2015-08-01	0,30	2018-04-01	0,25	2020-12-01	0,25

Fuente: Extraído de (FRED, 2025).

La Tabla 14 detalla la evolución de la tasa de refinanciación principal del BCE (ECBMLFR), principal instrumento de política monetaria de la Eurozona, durante el período 2013–2020. Los datos reflejan un descenso progresivo de la tasa, reflejando la estrategia expansiva del BCE para incentivar el crédito y la inversión durante el periodo analizado.

Esta política monetaria flexible contribuyó a la debilitación del euro frente al dólar, especialmente en los años posteriores a 2014.

Tabla 15*Evolución histórica del CBOE Volatility Index (VIX)*

Fecha	Cierre Ajustado (VIX)	Fecha	Cierre Ajustado (VIX)	Fecha	Cierre Ajustado (VIX)
Jan 1, 2013	14,28	Sep 1, 2015	24,5	May 1, 2018	15,43
Feb 1, 2013	15,51	Oct 1, 2015	15,07	Jun 1, 2018	16,09
Mar 1, 2013	12,7	Nov 1, 2015	16,13	Jul 1, 2018	12,83
Apr 1, 2013	13,52	Dec 1, 2015	18,21	Aug 1, 2018	12,86
May 1, 2013	16,3	Jan 1, 2016	20,2	Sep 1, 2018	12,12
Jun 1, 2013	16,86	Feb 1, 2016	20,55	Oct 1, 2018	21,23
Jul 1, 2013	13,45	Mar 1, 2016	13,95	Nov 1, 2018	18,07
Aug 1, 2013	16,6	Apr 1, 2016	15,7	Dec 1, 2018	25,42
Sep 1, 2013	16,6	May 1, 2016	14,19	Jan 1, 2019	16,57
Oct 1, 2013	13,75	Jun 1, 2016	15,63	Feb 1, 2019	14,78
Nov 1, 2013	13,7	Jul 1, 2016	11,87	Mar 1, 2019	13,71
Dec 1, 2013	13,72	Aug 1, 2016	13,42	Apr 1, 2019	13,12
Jan 1, 2014	18,41	Sep 1, 2016	13,29	May 1, 2019	18,71
Feb 1, 2014	14	Oct 1, 2016	17,06	Jun 1, 2019	15,08
Mar 1, 2014	13,41	Nov 1, 2016	13,33	Jul 1, 2019	16,12
Apr 1, 2014	11,41	Dec 1, 2016	14,04	Aug 1, 2019	18,98
May 1, 2014	11,4	Jan 1, 2017	11,99	Sep 1, 2019	16,24
Jun 1, 2014	11,57	Feb 1, 2017	12,92	Oct 1, 2019	13,22
Jul 1, 2014	16,95	Mar 1, 2017	12,37	Nov 1, 2019	12,62
Aug 1, 2014	12,09	Apr 1, 2017	10,82	Dec 1, 2019	13,78
Sep 1, 2014	16,31	May 1, 2017	11,18	Jan 1, 2020	18,84
Oct 1, 2014	14,03	Jun 1, 2017	10,41	Feb 1, 2020	40,11
Nov 1, 2014	13,33	Jul 1, 2017	10,26	Mar 1, 2020	53,54
Dec 1, 2014	19,2	Aug 1, 2017	10,59	Apr 1, 2020	34,15
Jan 1, 2015	20,97	Sep 1, 2017	9,51	May 1, 2020	27,51
Feb 1, 2015	15,29	Oct 1, 2017	10,18	Jun 1, 2020	30,43
Mar 1, 2015	15,29	Nov 1, 2017	11,28	Jul 1, 2020	24,46
Apr 1, 2015	13,84	Dec 1, 2017	11,04	Aug 1, 2020	26,41
May 1, 2015	18,23	Jan 1, 2018	13,54	Sep 1, 2020	26,37
Jun 1, 2015	18,23	Feb 1, 2018	19,85	Oct 1, 2020	38,02
Jul 1, 2015	12,12	Mar 1, 2018	19,97	Nov 1, 2020	20,57
Aug 1, 2015	28,43	Apr 1, 2018	15,93	Dec 1, 2020	22,75

Fuente: Extraído de (Yahoo Finance, (s.f.))

En la Tabla 15 se presenta la evolución del índice de volatilidad del mercado estadounidense (VIX), indicador que mide la expectativa de volatilidad a 30 días en el S&P 500.

En el caso del VIX un aumento puede ser asociado con periodos de incertidumbre económica y riesgo financiero, lo que generalmente impulsa la demanda de activos refugio, como el dólar estadounidense, provocando movimientos apreciativos en el USD y depreciativos en el euro.

Por último, para el análisis de este “fondo” se puede agregar los indicadores macroeconómicos de la Tabla 5, donde se incluyen el PIB nominal, PIB real e índice de precios de Estados Unidos, complementando la comprensión del contexto económico asociado a dichos movimientos.

6.4.4 Bitcoin (BTC/USD)

Tabla 16

Características generales del Bitcoin

Origen del Activo	Global
Nombre del Activo	Bitcoin (BTC/USD)
Perfil de Riesgo	Muy alto (alta volatilidad y especulación)
Tipo de Activo	Criptomoneda / Activo digital descentralizado
Moneda Base	USD

Fuente: Elaboración propia.

La Tabla 16 contiene las características generales del activo Bitcoin (BTC/USD), detallando su origen, tipo de activo, perfil de riesgo y moneda base. Se indica que la Bitcoin está dentro de la categoría de activos digitales descentralizados, los cuales están caracterizados por una alta volatilidad y sensibilidad a factores externos como tasas de interés, percepción de riesgo y decisiones de política monetaria.

Tabla 17*Valor histórico de Bitcoin y volumen de transacciones por fecha*

Fecha	Último	Vol.	Fecha	Último	Vol.	Fecha	Último	Vol.
27.12.2020	32.193,3	962,22K	28.04.2019	5.830,9	5,56M	27.08.2017	4.573,8	622,35K
20.12.2020	26.454,4	805,84K	21.04.2019	5.265,9	6,56M	20.08.2017	4.352,3	628,02K
13.12.2020	23.844,0	1,01M	14.04.2019	5.290,2	4,90M	13.08.2017	4.150,5	997,13K
06.12.2020	18.808,9	642,93K	07.04.2019	5.051,8	5,83M	06.08.2017	3.871,6	644,93K
29.11.2020	19.146,5	883,70K	31.03.2019	5.046,2	36,99M	30.07.2017	3.262,8	675,09K
22.11.2020	17.730,7	1,15M	24.03.2019	4.111,8	19,14M	23.07.2017	2.733,5	859,86K
15.11.2020	18.687,2	985,86K	17.03.2019	4.002,5	20,06M	16.07.2017	2.836,5	1,35M
08.11.2020	16.071,0	849,61K	10.03.2019	4.006,4	19,44M	09.07.2017	1.975,1	777,01K
01.11.2020	14.828,4	969,23K	03.03.2019	3.944,3	19,19M	02.07.2017	2.564,9	526,68K
25.10.2020	13.797,3	737,16K	24.02.2019	3.823,1	12,42M	25.06.2017	2.424,6	737,13K
18.10.2020	13.117,2	649,57K	17.02.2019	4.120,4	5,61M	18.06.2017	2.590,1	623,37K
11.10.2020	11.362,1	458,66K	10.02.2019	3.616,8	3,65M	11.06.2017	2.655,1	1,07M
04.10.2020	11.298,4	415,50K	03.02.2019	3.661,4	3,78M	04.06.2017	2.900,3	710,05K
27.09.2020	10.544,2	473,68K	27.01.2019	3.502,5	3,68M	28.05.2017	2.545,4	732,63K
20.09.2020	10.727,9	521,93K	20.01.2019	3.570,9	3,16M	21.05.2017	2.052,4	1,18M
13.09.2020	11.081,8	552,84K	13.01.2019	3.677,8	3,50M	14.05.2017	2.040,2	552,75K
06.09.2020	10.441,9	24,92M	06.01.2019	3.597,2	3,80M	07.05.2017	1.763,7	689,31K
30.08.2020	10.092,2	56,56M	30.12.2018	3.785,4	3,52M	30.04.2017	1.545,3	609,50K
23.08.2020	11.468,1	3,40M	23.12.2018	3.706,8	4,18M	23.04.2017	1.336,3	364,25K
16.08.2020	11.661,3	3,65M	16.12.2018	3.964,4	4,77M	16.04.2017	1.240,9	301,86K
09.08.2020	11.845,3	3,46M	09.12.2018	3.228,7	2,82M	09.04.2017	1.177,0	309,20K
02.08.2020	11.764,3	3,74M	02.12.2018	3.430,4	2,98M	02.04.2017	1.180,8	495,23K
26.07.2020	11.803,1	4,12M	25.11.2018	4.196,2	3,46M	26.03.2017	1.086,1	542,07K
19.07.2020	9.704,1	2,56M	18.11.2018	3.920,4	2,69M	19.03.2017	966,3	691,92K
12.07.2020	9.170,2	2,76M	11.11.2018	5.621,8	1,64M	12.03.2017	971,4	700,54K
05.07.2020	9.233,3	3,03M	04.11.2018	6.427,1	1,04M	05.03.2017	1.179,2	563,14K
28.06.2020	9.134,4	2,61M	28.10.2018	6.386,2	897,36K	26.02.2017	1.264,3	352,15K
21.06.2020	9.008,3	3,24M	21.10.2018	6.494,2	685,44K	19.02.2017	1.149,1	373,70K
14.06.2020	9.358,8	3,38M	14.10.2018	6.572,2	1,21M	12.02.2017	1.052,3	219,71K
07.06.2020	9.471,3	3,94M	07.10.2018	6.321,7	907,69K	05.02.2017	1.008,3	404,97K
31.05.2020	9.669,6	4,72M	30.09.2018	6.596,3	64,74M	29.01.2017	1.031,8	282,01K
24.05.2020	9.692,5	6,17M	23.09.2018	6.603,9	59,02M	22.01.2017	918,5	256,52K
17.05.2020	9.177,0	7,89M	16.09.2018	6.729,6	33,27M	15.01.2017	919,8	346,77K

10.05.2020	9.379,5	12,52M	09.09.2018	6.519,0	22,18M	08.01.2017	819,6	641,94K
03.05.2020	9.554,6	9,63M	02.09.2018	6.184,3	26,79M	01.01.2017	888,9	1,65M
26.04.2020	8.966,3	8,77M	26.08.2018	7.189,6	26,36M	25.12.2016	963,4	367,77K
19.04.2020	7.540,4	12,22M	19.08.2018	6.734,8	20,84M	18.12.2016	891,1	358,58K
12.04.2020	7.230,8	7,48M	12.08.2018	6.379,1	17,63M	11.12.2016	787,2	181,20K
05.04.2020	6.867,8	8,36M	05.08.2018	6.231,6	1,71M	04.12.2016	774,0	209,60K
29.03.2020	6.857,4	9,18M	29.07.2018	7.014,3	1,55M	27.11.2016	764,2	283,01K
22.03.2020	6.233,7	10,15M	22.07.2018	8.234,1	1,80M	20.11.2016	734,1	250,91K
15.03.2020	6.186,2	14,45M	15.07.2018	7.408,7	1,92M	13.11.2016	747,9	322,97K
08.03.2020	5.182,7	16,09M	08.07.2018	6.254,8	1,88M	06.11.2016	704,3	253,50K
01.03.2020	8.887,8	6,44M	01.07.2018	6.765,5	1,03M	30.10.2016	702,1	351,15K
23.02.2020	8.543,7	7,28M	24.06.2018	6.398,9	1,34M	23.10.2016	715,0	279,12K
16.02.2020	9.655,7	5,93M	17.06.2018	6.167,3	988,81K	16.10.2016	655,5	186,59K
09.02.2020	9.907,7	5,39M	10.06.2018	6.505,8	1,32M	09.10.2016	637,0	190,80K
02.02.2020	9.895,5	4,78M	03.06.2018	7.515,8	868,03K	02.10.2016	617,7	154,85K
26.01.2020	9.381,6	4,89M	27.05.2018	7.646,6	984,53K	25.09.2016	613,4	151,47K
19.01.2020	8.341,6	4,60M	20.05.2018	7.361,3	1,08M	18.09.2016	602,6	158,87K
12.01.2020	8.916,3	6,33M	13.05.2018	8.245,1	1,14M	11.09.2016	607,1	176,68K
05.01.2020	8.024,1	6,53M	06.05.2018	8.459,5	1,26M	04.09.2016	624,5	190,28K
29.12.2019	7.376,8	4,70M	29.04.2018	9.853,5	1,17M	28.08.2016	598,8	177,29K
22.12.2019	7.321,5	5,29M	22.04.2018	9.352,4	1,60M	21.08.2016	570,3	180,45K
15.12.2019	7.156,2	5,22M	15.04.2018	8.923,1	1,27M	14.08.2016	582,6	216,33K
08.12.2019	7.080,8	3,88M	08.04.2018	8.004,4	1,51M	07.08.2016	584,6	211,25K
01.12.2019	7.510,9	5,17M	01.04.2018	6.905,7	1,50M	31.07.2016	586,5	444,48K
24.11.2019	7.546,6	6,29M	25.03.2018	6.938,2	1,80M	24.07.2016	654,7	217,98K
17.11.2019	7.324,1	6,19M	18.03.2018	8.547,4	1,75M	17.07.2016	655,2	285,32K
10.11.2019	8.497,3	4,02M	11.03.2018	7.874,9	1,84M	10.07.2016	660,7	309,16K
03.11.2019	8.804,5	4,63M	04.03.2018	8.762,0	1,66M	03.07.2016	651,8	590,38K
27.10.2019	9.300,6	6,08M	25.02.2018	11.402,3	1,41M	26.06.2016	698,1	593,43K
20.10.2019	9.230,6	4,23M	18.02.2018	9.704,3	1,93M	19.06.2016	663,5	1,18M
13.10.2019	7.957,3	3,38M	11.02.2018	11.073,5	1,64M	12.06.2016	753,8	1,21M
06.10.2019	8.304,4	4,00M	04.02.2018	8.559,6	3,00M	05.06.2016	591,6	398,83K
29.09.2019	8.127,3	3,23M	28.01.2018	9.241,1	1,89M	29.05.2016	572,0	663,12K
22.09.2019	8.208,5	4,23M	21.01.2018	11.467,5	1,33M	22.05.2016	524,2	459,13K
15.09.2019	9.993,0	2,51M	14.01.2018	12.858,9	1,39M	15.05.2016	443,6	255,85K
08.09.2019	10.337,3	2,74M	07.01.2018	14.292,2	691,25K	08.05.2016	456,4	277,91K
01.09.2019	10.461,1	3,62M	31.12.2017	17.172,3	770,83K	01.05.2016	458,5	326,08K
25.08.2019	9.594,4	3,29M	24.12.2017	12.531,5	1,04M	24.04.2016	448,5	476,55K
18.08.2019	10.131,0	3,57M	17.12.2017	14.396,5	1,46M	17.04.2016	450,1	333,40K

11.08.2019	10.218,1	4,62M	10.12.2017	19.345,5	1,02M	10.04.2016	430,0	269,29K
04.08.2019	11.314,5	4,55M	03.12.2017	14.843,4	1,26M	03.04.2016	418,0	242,22K
28.07.2019	10.815,7	3,89M	26.11.2017	10.912,7	919,63K	27.03.2016	418,5	328,93K
21.07.2019	9.492,1	4,02M	19.11.2017	8.754,7	551,27K	20.03.2016	416,5	264,86K
14.07.2019	10.826,7	6,29M	12.11.2017	7.780,9	1,00M	13.03.2016	408,7	324,33K
07.07.2019	11.364,9	5,64M	05.11.2017	6.339,9	1,07M	06.03.2016	410,4	405,06K
30.06.2019	11.268,0	6,41M	29.10.2017	7.363,8	976,41K	28.02.2016	399,0	528,15K
23.06.2019	11.906,5	7,21M	22.10.2017	5.726,6	722,59K	21.02.2016	431,3	466,28K
16.06.2019	10.721,7	5,15M	15.10.2017	6.006,6	670,51K	14.02.2016	440,1	559,58K
09.06.2019	8.812,5	4,24M	08.10.2017	5.824,7	805,69K	07.02.2016	390,1	420,40K
02.06.2019	7.901,4	4,88M	01.10.2017	4.435,8	443,24K	31.01.2016	376,7	465,80K
26.05.2019	8.545,7	20,69M	24.09.2017	4.360,6	588,23K	24.01.2016	377,8	484,64K
19.05.2019	8.027,4	6,20M	17.09.2017	3.788,0	781,52K	17.01.2016	388,6	688,23K
12.05.2019	7.262,6	9,03M	10.09.2017	3.698,9	1,43M	10.01.2016	385,0	735,95K
05.05.2019	7.190,3	5,78M	03.09.2017	4.335,1	870,55K	03.01.2016	448,3	457,61K

Fuente: Extraído de (Investing, (s.f.))

En la Tabla 17 se indican los valores históricos del Bitcoin, incluyendo el precio de cierre diario y el volumen total de transacciones entre el 2016 y el 2020.

Tabla 18

Evolución histórica del índice del dólar estadounidense (DXY)

Date	Price (DXY)	Date	Price (DXY)	Date	Price (DXY)
12/27/2020	89,94	04/28/2019	97,52	08/27/2017	92,81
12/20/2020	90,32	04/21/2019	98,01	08/20/2017	92,74
12/13/2020	90,02	04/14/2019	97,38	08/13/2017	93,43
12/06/2020	90,98	04/07/2019	96,97	08/06/2017	93,07
11/29/2020	90,7	03/31/2019	97,39	07/30/2017	93,54
11/22/2020	91,79	03/24/2019	97,28	07/23/2017	93,26
11/15/2020	92,39	03/17/2019	96,65	07/16/2017	93,86
11/08/2020	92,75	03/10/2019	96,6	07/09/2017	95,15

11/01/2020	92,23	03/03/2019	97,31	07/02/2017	96,01
10/25/2020	94,04	02/24/2019	96,53	06/25/2017	95,63
10/18/2020	92,77	02/17/2019	96,51	06/18/2017	97,26
10/11/2020	93,68	02/10/2019	96,9	06/11/2017	97,16
10/04/2020	93,06	02/03/2019	96,64	06/04/2017	97,27
09/27/2020	93,84	01/27/2019	95,58	05/28/2017	96,71
09/20/2020	94,64	01/20/2019	95,79	05/21/2017	97,44
09/13/2020	92,93	01/13/2019	96,34	05/14/2017	97,14
09/06/2020	93,33	01/06/2019	95,67	05/07/2017	99,25
08/30/2020	92,72	12/30/2018	96,18	04/30/2017	98,65
08/23/2020	92,37	12/23/2018	96,4	04/23/2017	99,05
08/16/2020	93,25	12/16/2018	96,96	04/16/2017	99,98
08/09/2020	93,1	12/09/2018	97,44	04/09/2017	100,56
08/02/2020	93,43	12/02/2018	96,51	04/02/2017	101,18
07/26/2020	93,35	11/25/2018	97,27	03/26/2017	100,35
07/19/2020	94,43	11/18/2018	96,92	03/19/2017	99,63
07/12/2020	95,94	11/11/2018	96,46	03/12/2017	100,3
07/05/2020	96,65	11/04/2018	96,9	03/05/2017	101,25
06/28/2020	97,17	10/28/2018	96,54	02/26/2017	101,54
06/21/2020	97,43	10/21/2018	96,36	02/19/2017	101,09
06/14/2020	97,62	10/14/2018	95,71	02/12/2017	100,95
06/07/2020	97,32	10/07/2018	95,22	02/05/2017	100,8
05/31/2020	96,94	09/30/2018	95,62	01/29/2017	99,87
05/24/2020	98,34	09/23/2018	95,13	01/22/2017	100,53
05/17/2020	99,86	09/16/2018	94,22	01/15/2017	100,74
05/10/2020	100,4	09/09/2018	94,93	01/08/2017	101,18
05/03/2020	99,73	09/02/2018	95,36	01/01/2017	102,22
04/26/2020	99,08	08/26/2018	95,14	12/25/2016	102,21
04/19/2020	100,38	08/19/2018	95,15	12/18/2016	103,01
04/12/2020	99,78	08/12/2018	96,1	12/11/2016	102,95
04/05/2020	99,52	08/05/2018	96,36	12/04/2016	101,59
03/29/2020	100,58	07/29/2018	95,14	11/27/2016	100,77
03/22/2020	98,36	07/22/2018	94,68	11/20/2016	101,49
03/15/2020	102,82	07/15/2018	94,45	11/13/2016	101,21
03/08/2020	98,75	07/08/2018	94,75	11/06/2016	99,06
03/01/2020	95,95	07/01/2018	94,04	10/30/2016	97,06
02/23/2020	98,13	06/24/2018	94,64	10/23/2016	98,35
02/16/2020	99,26	06/17/2018	94,52	10/16/2016	98,69
02/09/2020	99,12	06/10/2018	94,79	10/09/2016	98,02

02/02/2020	98,68	06/03/2018	93,55	10/02/2016	96,63
01/26/2020	97,39	05/27/2018	94,19	09/25/2016	95,46
01/19/2020	97,85	05/20/2018	94,19	09/18/2016	95,48
01/12/2020	97,64	05/13/2018	93,64	09/11/2016	96,11
01/05/2020	97,36	05/06/2018	92,54	09/04/2016	95,34
12/29/2019	96,84	04/29/2018	92,57	08/28/2016	95,84
12/22/2019	96,92	04/22/2018	91,54	08/21/2016	95,57
12/15/2019	97,69	04/15/2018	90,32	08/14/2016	94,51
12/08/2019	97,17	04/08/2018	89,8	08/07/2016	95,72
12/01/2019	97,7	04/01/2018	90,11	07/31/2016	96,19
11/24/2019	98,27	03/25/2018	89,97	07/24/2016	95,53
11/17/2019	98,27	03/18/2018	89,48	07/17/2016	97,47
11/10/2019	98	03/11/2018	90,23	07/10/2016	96,58
11/03/2019	98,35	03/04/2018	90,09	07/03/2016	96,3
10/27/2019	97,24	02/25/2018	89,93	06/26/2016	95,65
10/20/2019	97,83	02/18/2018	89,88	06/19/2016	95,45
10/13/2019	97,28	02/11/2018	89,1	06/12/2016	94,21
10/06/2019	98,3	02/04/2018	90,44	06/05/2016	94,57
09/29/2019	98,81	01/28/2018	89,19	05/29/2016	94,03
09/22/2019	99,11	01/21/2018	89,07	05/22/2016	95,52
09/15/2019	98,51	01/14/2018	90,57	05/15/2016	95,33
09/08/2019	98,26	01/07/2018	90,97	05/08/2016	94,61
09/01/2019	98,39	12/31/2017	91,95	05/01/2016	93,89
08/25/2019	98,92	12/24/2017	92,12	04/24/2016	93,08
08/18/2019	97,64	12/17/2017	93,35	04/17/2016	95,12
08/11/2019	98,14	12/10/2017	93,93	04/10/2016	94,7
08/04/2019	97,49	12/03/2017	93,9	04/03/2016	94,23
07/28/2019	98,07	11/26/2017	92,89	03/27/2016	94,62
07/21/2019	98,01	11/19/2017	92,78	03/20/2016	96,14
07/14/2019	97,15	11/12/2017	93,66	03/13/2016	95,09
07/07/2019	96,81	11/05/2017	94,39	03/06/2016	96,17
06/30/2019	97,29	10/29/2017	94,94	02/28/2016	97,34
06/23/2019	96,13	10/22/2017	94,92	02/21/2016	98,15
06/16/2019	96,22	10/15/2017	93,7	02/14/2016	96,6
06/09/2019	97,57	10/08/2017	93,09	02/07/2016	95,94
06/02/2019	96,54	10/01/2017	93,8	01/31/2016	97,03
05/26/2019	97,75	09/24/2017	93,08	01/24/2016	99,61
05/19/2019	97,61	09/17/2017	92,17	01/17/2016	99,57
05/12/2019	98	09/10/2017	91,87	01/10/2016	98,96

05/05/2019	97,33	09/03/2017	91,35	01/03/2016	98,54
------------	-------	------------	-------	------------	-------

Fuente: Extraído de (Investing, (s.f.))

La Tabla 18 muestra la evolución del índice del dólar estadounidense (DXY), el cual mide la fortaleza del dólar frente a una canasta de monedas internacionales. Este indicador resulta esencial para interpretar los movimientos del Bitcoin dado que según lo que mencionan Aysu Ahmadova, Taghi Guliyev, Khatai Aliyev (The Relationship between Bitcoin and Nasdaq, U.S. Dollar Index and Commodities, 2024), “El Índice del Dólar de EE. UU. muestra un impacto negativo y significativo sobre Bitcoin”, por lo que podemos decir que ambos activos han mostrado una relación inversa: cuando el DXY se fortalece, el precio del Bitcoin tiende a debilitarse, y viceversa.

Además de las tablas ya mencionadas para el Bitcoin, se consideran la información presentada en la Tabla 5 y la Tabla 13. Debido a que estas variables permiten contextualizar el entorno macroeconómico durante el período de análisis, considerando su impacto directo en los movimientos del dólar estadounidense y en la dinámica de los mercados financieros globales.

6.4.5 Oro (XAU/USD)

Tabla 19

Características generales del Oro (XAU/USD)

Origen del Activo	Global
Nombre del Activo	Oro (XAU/USD)
Perfil de Riesgo	Bajo – Medio (activo refugio)
Tipo de Activo	Materia prima / Commodity financiero (Indexado)
Moneda Base	USD

Fuente: Elaboración propia.

La Tabla 19 presenta las características generales del activo Oro (XAU/USD), en donde se indica su origen global, su clasificación como materia prima/commodity financiero indexado y que su moneda base para esta consideración es en USD. El activo tiene un perfil de riesgo bajo–medio debido a lo mencionado anteriormente en la sección Selección de fondos/activos.

Tabla 20

Valores históricos mensuales del precio del oro (XAU/USD)

Fecha	Último Valor	Fecha	Último Valor
01.12.2020	1.896,49	01.06.2019	1.409,10
01.11.2020	1.777,02	01.05.2019	1.305,25
01.10.2020	1.877,95	01.04.2019	1.283,35
01.09.2020	1.885,44	01.03.2019	1.291,90
01.08.2020	1.969,75	01.02.2019	1.312,66
01.07.2020	1.974,69	01.01.2019	1.320,56
01.06.2020	1.780,67	01.12.2018	1.282,73
01.05.2020	1.726,30	01.11.2018	1.221,88
01.04.2020	1.680,09	01.10.2018	1.214,14
01.03.2020	1.571,05	01.09.2018	1.191,69
01.02.2020	1.584,74	01.08.2018	1.200,71
01.01.2020	1.589,81	01.07.2018	1.223,41
01.12.2019	1.517,01	01.06.2018	1.252,25
01.11.2019	1.463,90	01.05.2018	1.297,92
01.10.2019	1.513,16	01.04.2018	1.314,95
01.09.2019	1.472,00	01.03.2018	1.324,00
01.08.2019	1.519,85	01.02.2018	1.317,66
01.07.2019	1.413,55	01.01.2018	1.344,70

Fuente: Extraído de (Investing, (s.f.)).

En la Tabla 20 se presenta la evolución mensual del precio del oro durante el período comprendido entre enero de 2018 y diciembre de 2020, expresado en dólares estadounidenses por onza troy (XAU/USD).

Tabla 21*PIB Mundial*

Entidad	Código	Año	GDP en Billones de dólares
World	OWID_WRL	2010	111,634
World	OWID_WRL	2011	116,041
World	OWID_WRL	2012	119,666
World	OWID_WRL	2013	123,564
World	OWID_WRL	2014	127,815
World	OWID_WRL	2015	132,068
World	OWID_WRL	2016	136,355
World	OWID_WRL	2017	141,55
World	OWID_WRL	2018	146,737
World	OWID_WRL	2019	151,09
World	OWID_WRL	2020	146,875

Fuente: Extraído de (OurWorldInData, 2024).

La Tabla 21 presenta la evolución del Producto Interno Bruto (PIB) mundial durante el período 2010–2020, expresado en dólares.

Además de las tablas ya mencionadas para este activo, se consideraran tablas indicadas en otros activos, como la Tabla 5, que muestra los principales indicadores macroeconómicos de los Estados Unidos, la Tabla 13 que presenta la evolución de la tasa de fondos federales (FEDFUNDS), también la Tabla 15, la cual corresponde al índice de volatilidad (VIX), indicador que refleja el nivel de incertidumbre en los mercados financieros y que guarda una relación directa con el comportamiento del oro como activo refugio.

6.4.6 Petróleo Brent (BRENT Crude Oil)

Tabla 22

Características generales del Petróleo Brent (BRENT Crude Oil)

Origen del Activo	Global / Referente del mercado energético internacional
Nombre del Activo	Petróleo Brent (BRENT Crude Oil USD)
Perfil de Riesgo	Alto (alto nivel de volatilidad asociada a fluctuaciones de la demanda y tensión geopolítica)
Tipo de Activo	Materia prima / Commodity energético
Moneda Base	USD

Fuente: Extraído de (Zavadska, Morales, & Coughlan, 2020).

En la Tabla 22 se presentan las características generales del Petróleo Brent (BRENT Crude Oil USD). Este activo, de origen global, se clasifica como una materia prima energética cuyo valor refleja el equilibrio entre la oferta y la demanda mundial de crudo, este activo se cotiza en dólares estadounidenses (USD), además tiene un perfil de riesgo alto, debido a su elevada volatilidad ante factores geopolíticos, decisiones de la OPEP y variaciones en la demanda global.

Tabla 23

Precios históricos del petróleo Brent

Periodo	Precio del petróleo Brent (dólares/barril)	Periodo	Precio del petróleo Brent (dólares/barril)
mar.2014	107,88	sept.2017	51,74
jun.2014	109,78	dic.2017	61,47
sept.2014	102,08	mar.2018	66,95
dic.2014	76,01	jun.2018	74,49
mar.2015	53,93	sept.2018	75,48
jun.2015	62,10	dic.2018	67,37
sept.2015	50,03	mar.2019	63,27
dic.2015	43,42	jun.2019	68,34
mar.2016	34,36	sept.2019	61,86
jun.2016	45,95	dic.2019	62,65
sept.2016	45,80	mar.2020	50,53
dic.2016	50,08	jun.2020	31,43
mar.2017	54,12	sept.2020	42,72
jun.2017	50,25	dic.2020	44,52

Fuente: Extraído de (Base de Datos Estadísticos (BDE), (s.f.)).

La Tabla 23 presenta los precios históricos del Petróleo Brent expresados en dólares por barril de petróleo, en el período comprendido entre 2014 y 2020. Con esto se puede observar la evolución del valor del crudo a lo largo del tiempo, permitiendo el análisis de su comportamiento.

Tabla 24*Eventos históricos y su impacto en el mercado del Petróleo Brent*

Año	Evento principal	Descripción y efectos en el mercado del Brent
2014	Aumento de la producción de shale oil en EE.UU.	El rápido incremento de la oferta de petróleo no convencional generó un exceso en el mercado global.
2014	Decisión de la OPEP de mantener niveles de producción	La negativa a reducir la producción acentuó la sobreoferta y provocó una caída de más del 50% en el precio del Brent.
2014	Desaceleración del crecimiento en China	La menor demanda asiática amplificó la presión bajista sobre los precios internacionales del crudo.
2015	Persistencia de la sobreoferta global	Los precios continuaron en niveles bajos debido al exceso de producción y la lenta recuperación de la demanda.
2015	Aumento de inventarios en EE.UU.	El incremento de reservas petroleras generó preocupación sobre un nuevo colapso de precios.
2015	Acuerdo nuclear con Irán	La perspectiva de un retorno del crudo iraní al mercado acentuó la presión sobre la oferta mundial.
2016	Acuerdo OPEP–No OPEP para recortar producción	La cooperación entre productores permitió estabilizar parcialmente los precios cerca de 55 USD/barril.
2016	Recuperación de la demanda en Asia	Un mayor consumo energético en India y China contribuyó a un leve repunte del Brent.
2016	Devaluación del dólar estadounidense	El debilitamiento del dólar favoreció una mejora en los precios de las materias primas.
2017	Reducción de inventarios globales	La disminución de las reservas impulsó una recuperación sostenida del Brent.
2017	Inestabilidad política en Venezuela	La caída de la producción venezolana tensionó el mercado, elevando los precios.

2017	Conflictos en Oriente Medio	Las tensiones en Siria e Irak aumentaron la prima de riesgo geopolítico.
2018	Guerra comercial entre EE.UU. y China	Las tensiones comerciales generaron alta volatilidad y menor expectativa de crecimiento.
2018	Sanciones de EE.UU. a Irán	La reducción del suministro iraní impulsó temporalmente los precios por sobre los 80 USD/barril.
2018	Incremento de la producción de Arabia Saudita	La mayor producción saudí compensó el déficit iraní, corrigiendo los precios a la baja.
2019	Ataques a instalaciones de Aramco en Arabia Saudita	La interrupción de la producción elevó bruscamente los precios en septiembre.
2019	Desaceleración económica global	La menor expansión económica mundial redujo la demanda energética.
2019	Avances en negociaciones comerciales EE.UU.–China	La expectativa de un acuerdo parcial contribuyó a una leve estabilización del mercado.
2020	Guerra de precios entre Arabia Saudita y Rusia	El desacuerdo en los recortes de producción provocó un colapso de los precios a comienzos de marzo.
2020	Pandemia de COVID-19 y confinamientos globales	La caída sin precedentes en la demanda redujo el precio del Brent a mínimos cercanos a 20 USD/barril.
2020	Acuerdos OPEP+ de reducción y previsiones de recuperación 2021	A fines de 2020 se proyectó una lenta recuperación del consumo impulsada por los programas de vacunación y los ajustes de producción.

Fuente: (OpenAI, (s.f.))

En la Tabla 24 se indican los principales eventos históricos que según el LLM afectaron el mercado del Petróleo Brent durante el período 2014–2020, además acompañado con una breve

descripción de sus efectos. Entre los eventos se destacan cambios en la producción petrolera, tensiones geopolíticas, conflictos comerciales y crisis sanitarias.

Además de las tablas presentadas en esta sección, se consideran las variables macroeconómicas incluidas en tablas anteriores, como la Tasa de política monetaria de la Reserva Federal (Tabla 13), la Fortaleza del dólar estadounidense (Tabla 18) y el índice de volatilidad financiera, VIX (Tabla 15). Estas variables permiten contextualizar el comportamiento del precio del petróleo Brent dentro de un entorno económico y financiero global, al reflejar factores determinantes como la política monetaria, el valor relativo del dólar y el nivel de incertidumbre en los mercados.

6.5 Procesamiento y enmascaramiento de datos

En el proceso de preparación de la información se contempló una etapa de enmascaramiento de los datos indicados desde la Tabla 1 a la tabla Tabla 24. En primer lugar, se realizó un enmascaramiento de los períodos de tiempo utilizados, ocultándose los años, dicho de otra manera, se reemplazó 2020 por “(Año base)”, 2019 por “(Año base – 1)”, 2018 por “(Año base – 2)” y así para los años anteriores y en caso de los años posteriores a 2020 (ya que se consideran “predicciones”) se reemplazó 2021 por “(Año base + 1)”, 2022 por “(Año base + 2)” y así para los futuros años.

Posteriormente, se procedió al enmascaramiento de los activos, ajustando nombres y descripciones para resguardar la confidencialidad de la información y asegurar la neutralidad de los resultados, este proceso consistió principalmente en la sustitución de nombres reales por nombres ficticios de fondos o instrumentos financieros, además de ocultar información que describía de que activo o fondo se trataba.

Finalmente se consideró el enmascaramiento de los eventos históricos, con el fin de evitar que el LLM pudiera identificar cual realmente era el Año base. Asimismo, se reemplazaron términos y referencias asociadas a entidades, países o eventos concretos por expresiones genéricas, manteniendo el sentido analítico del contenido sin comprometer su validez.

El fin de este procedimiento es evitar que los modelos de inteligencia artificial reconozca los activos originales. Cabe destacar que el proceso de enmascaramiento no alteró las relaciones temporales ni la estructura lógica de las series de datos, debido a que lo más importante es preservar

la coherencia entre las variables, sus tendencias y sus variaciones relativas a lo largo del período de estudio.

Las tablas resultantes del proceso de enmascaramiento se presentan en la sección

Anexo, comprendiendo desde la Tabla 38 a la Tabla 61, las cuales contienen los resultados del proceso de enmascaramiento de los datos presentados en la sección Datos recolectados.

Tabla 25*Resumen equivalencia de Tablas*

Tablas Originales	Tablas con Enmascaramiento de Datos
Tabla 1	Tabla 38
Tabla 2	Tabla 39
Tabla 3	Tabla 40
Tabla 4	Tabla 41
Tabla 5	Tabla 42
Tabla 6	Tabla 43
Tabla 7	Tabla 44
Tabla 8	Tabla 45
Tabla 9	Tabla 46
Tabla 10	Tabla 47
Tabla 11	Tabla 48
Tabla 12	Tabla 49
Tabla 13	Tabla 50
Tabla 14	Tabla 51
Tabla 15	Tabla 52
Tabla 16	Tabla 53
Tabla 17	Tabla 54
Tabla 18	Tabla 55
Tabla 19	Tabla 56
Tabla 20	Tabla 57
Tabla 21	Tabla 58
Tabla 22	Tabla 59
Tabla 23	Tabla 60
Tabla 24	Tabla 61

La

Tabla 25 presenta la correspondencia entre las tablas originales y las versiones generadas tras el proceso de enmascaramiento de datos.

6.6 Procedimiento experimental

El procedimiento experimental se estructura en seis etapas principales, la identificación de los datos necesarios, la recopilación de dichos datos, la preparación de la información, la construcción del prompt, la consulta al modelo de lenguaje (LLM), y por último la presentación y análisis de los datos arrojados del LLM. Cabe señalar que este procedimiento se aplicó de manera individual para cada fondo o activo analizado.

6.6.1 Identificación de los datos relevantes

El proceso de identificación de los datos necesarios se realizó mediante una consulta directa al modelo de lenguaje (LLM). Para cada fondo o activo analizado, se formuló un prompt en el que se solicitó al modelo que indicara qué variables o indicadores eran relevantes para evaluar el comportamiento del fondo o activo y que permitan realizar proyecciones sobre su rentabilidad futura en base a estos.

El LLM, en base a la información solicitada, respondió indicando un conjunto de variables que consideró pertinentes. Estas variables fueron: precios históricos, indicadores macroeconómicos, tasas de interés, índices de volatilidad, entre otros (véase en la sección 6.4), dependiendo del activo en cuestión. Este enfoque permitió adaptar la selección de datos a las características de cada fondo, evitando una selección arbitraria o genérica, y privilegiando la perspectiva del modelo de lenguaje.

No obstante, en algunos casos se incorporaron variables adicionales que el investigador estimó relevantes para realizar adecuadamente el análisis. Estas decisiones se fundamentaron en conocimientos previos del comportamiento de los mercados financieros y en la necesidad de

asegurar una cobertura suficiente de los factores que pudieran influir en la dinámica de los activos evaluados.

6.6.2 Recopilación de los Datos

Una vez identificadas las variables necesarias para el análisis, se procedió a la recolección de datos históricos correspondientes a cada una de ellas. La obtención de estos datos se realizó mediante fuentes públicas, abiertas y de acceso libre, con el fin de garantizar la transparencia del proceso y la posibilidad de replicación del estudio (véase la sección 6.2). Estas fuentes permitieron recopilar series temporales de precios, tasas de interés, indicadores de volatilidad y demás variables macroeconómicas solicitadas por el modelo o consideradas relevantes por el investigador.

En cuanto a la periodicidad de los datos, esta varió según el activo. Algunos fondos presentaban información con frecuencia semanal, otros mensual o trimestral. Asimismo, se consideró un horizonte temporal amplio, cubriendo períodos anteriores al año base y en algunos casos se contemplaron predicciones futuras.

Toda la información recolectada fue estructurada en tablas organizadas (véase sección 6.4), permitiendo su uso posterior en los prompts y en la aplicación de los procedimientos experimentales. Esta organización también facilitó el proceso de enmascaramiento de los datos, preservando la lógica de las series sin comprometer su trazabilidad.

6.6.3 Preparación y preprocesamiento de los datos

Como parte del proceso de preparación de los datos para su uso en el modelo de lenguaje, se aplicó un procedimiento de enmascaramiento (véase la sección 6.5) cuyo objetivo principal fue proteger la identidad de los activos analizados y prevenir cualquier sesgo o reconocimiento por parte del modelo.

El preprocesamiento no alteró la estructura lógica de las series ni las relaciones temporales entre las variables, resguardando así la coherencia y validez del análisis. Las tablas enmascaradas resultantes se encuentran en la sección 0, desde la Tabla 38 hasta la Tabla 61.

Este enfoque permitió entregar al modelo información coherente, neutra y libre de referencias directas, asegurando así la imparcialidad de los resultados generados por el sistema de inteligencia artificial.

6.6.4 Construcción del prompt

Una vez seleccionados y enmascarados los datos, se procede a la construcción del prompt que sería entregado al modelo de lenguaje. Este prompt consistió en un conjunto estructurado de instrucciones e información (véase la sección 5.8), incluyendo las tablas de datos correspondientes a cada activo o fondo, junto con una pregunta orientada a evaluar la conveniencia de invertir en el activo, considerando distintos horizontes temporales.

En términos generales, se solicitó al modelo que, con base en los datos presentados, indicara si era recomendable invertir en el activo en cuestión y en qué horizonte de tiempo (1, 3, 6 o 12 meses) era conveniente invertir. El modelo debía justificar su respuesta y entregar el valor estimado del activo para cada uno de los plazos.

Este enfoque permitió evaluar las capacidades predictivas del modelo de lenguaje frente a datos estructurados (en este caso en formato de tablas) y controlados, simulando una situación de análisis financiero realista y ajustada al contexto del estudio.

6.6.5 Consulta al modelo de lenguaje (LLM)

Con el prompt estructurado y los datos preparados, se procede a consultar al modelo de lenguaje (LLM). Para cada fondo o activo, se entregan las tabla con los datos enmascarados junto a una instrucción orientada a determinar si resultaba conveniente invertir y cuál era el horizonte temporal óptimo (1, 3, 6 o 12 meses).

El modelo respondió indicando recomendaciones de inversión, valores proyectados y una justificación basada en los datos entregados. Este procedimiento se aplicó individualmente a cada activo.

6.6.6 Presentación y análisis de los resultados

Una vez obtenidas las respuestas del modelo de lenguaje (LLM), se procede a organizar y analizar los resultados obtenidos. Cada recomendación es ordenada en función del fondo o activo correspondiente, permitiendo evaluar el comportamiento proyectado en distintos horizontes temporales (1, 3, 6 y 12 meses).

El análisis incluyó tanto la interpretación cuantitativa, es decir, los valores entregados por el modelo, además de un análisis cualitativo, considerando la coherencia interna de las recomendaciones. Se compararon las proyecciones con los valores reales observados, permitiendo calcular el error porcentual y clasificar las respuestas como acertadas o erróneas en función de un umbral de tolerancia del 5 % (véase sección 6.7).

Esta etapa permitió contrastar la capacidad predictiva del modelo en un entorno controlado, aportando evidencia sobre la utilidad del LLM en contextos de análisis financiero estructurado.

6.7 Evaluación de resultados

Con el propósito de evaluar el desempeño, se implementó un proceso de análisis dividido en dos enfoques complementarios: uno cuantitativo, basado en la precisión numérica de las proyecciones, utilizando un rango aceptable en base a un error porcentual de un 5%, y un análisis cualitativo, centrado en la validez lógica y contextual de las respuestas generadas.

6.7.1 Análisis Cuantitativo

Para el análisis Cuantitativo se utiliza como métrica principal el error porcentual relativo, calculado mediante la siguiente fórmula:

$$\text{Error porcentual} = \left| \left(\frac{\text{Valor estimado} - \text{Valor real}}{\text{Valor real}} \right) \right| \times 100$$

Se establece un umbral del 5 % como margen de tolerancia. Si el error porcentual se encuentra dentro de este rango, se considera que la predicción del LLM es acertada, y en caso contrario, entiéndase que el error porcentual sea mayor a 5%, se clasifica como errónea.

Además del cálculo individual del error porcentual relativo del 5% para cada predicción generada, se implementa un análisis agregado de desempeño. Teniendo como objetivo evaluar de forma global la efectividad del modelo en distintos contextos y horizontes temporales.

El primero de estos, es una clasificación binaria de resultados, en donde cada predicción es clasificada como acertada o errónea de acuerdo con el umbral del 5 % establecido previamente. Con base en esta clasificación binaria, se contabilizó el número total de aciertos y errores para cada horizonte de predicción (1, 3, 6 y 12 meses), permitiendo construir una matriz de desempeño

por horizonte. Con este análisis se puede comparar la precisión relativa del modelo según el plazo de inversión sugerido.

El segundo es la agrupación por tipo de fondo, en donde se segmenta el análisis por tipo de fondo o activo, permitiendo observar si existen diferencias en el rendimiento del modelo según la naturaleza del instrumento financiero.

El tercer enfoque de análisis considera el rendimiento del modelo por fondo o activo de manera individual. Esta perspectiva permite identificar cuáles fondos obtuvieron una mayor proporción de predicciones acertadas y analizar las características particulares de los datos entregados en cada caso. Entre los factores considerados se encuentran la frecuencia temporal de los datos (semanal, mensual o trimestral), la cantidad total de observaciones disponibles y el período de tiempo cubierto. Este análisis permite explorar si la extensión del historial entregado, la granularidad temporal o la calidad de la información influyen en la capacidad del modelo para entregar recomendaciones precisas. Con esto se busca comprender en qué condiciones de entrada el desempeño del modelo mejora o se ve limitado.

6.7.2 Análisis Cualitativo

En el análisis cualitativo de las respuestas generadas por el modelo de lenguaje, se busca evaluar la coherencia, relevancia y fundamentación de las recomendaciones emitidas, además de buscar patrones generales de razonamiento y consistencia en la argumentación entregada por el LLM.

En primer lugar, se realiza un análisis de la coherencia lógica de las respuestas, analizando si el modelo de lenguaje entrega una argumentación estructurada y sin contradicciones o sin

sentidos, además de revisar si mantiene un hilo narrativo consistente frente a la información entregada o en caso de no mantener este hilo, analizar el por qué. Asimismo, se incluye en este análisis si el razonamiento del modelo de lenguaje se adapta adecuadamente ante distintos contextos o tipos de activos.

En segundo lugar, se incluye un análisis sobre la correspondencia entre los datos entregados en el prompt y las respuestas entregadas por el LLM, observando en qué medida el modelo reconoce tendencias, rupturas o patrones en las series históricas, y si estos se encuentran reflejados de manera explícita en la justificación de sus sugerencias.

En tercer lugar, se analiza si el modelo tiene la capacidad de identificar fenómenos financieros complejos como burbujas especulativas, ajustes abruptos o etapas de estabilización del mercado. Se evaluará si el LLM reconoce y señala una burbuja especulativa, identificando las características de esta, que son los momentos en los que el precio del activo muestra un crecimiento acelerado y poco sostenible, además de si logra anticipar o interpretar adecuadamente los eventos de corrección de mercado posteriores a la burbuja. La detección y argumentación respecto de estos procesos es fundamental para determinar si el modelo es capaz de interpretar algunas dinámicas financieras no lineales, cosa que llevaría a añadir un grado de profundidad al análisis, además de representar una mayor utilidad en escenarios de toma de decisiones.

Finalmente, se buscarán patrones generales de razonamiento en las respuestas, con el objetivo de identificar fortalezas recurrentes (como el uso adecuado de conceptos financieros) o debilidades comunes (como recomendaciones demasiado genéricas o falta de precisión cuantitativa).

Este enfoque cualitativo complementa la evaluación cuantitativa anteriormente señalada, ofreciendo una visión integral del desempeño del modelo y de su capacidad para razonar de forma pertinente en contextos financieros complejos.

6.8 Limitaciones

A pesar de la rigurosidad metodológica aplicada durante cada etapa del estudio, es necesario reconocer que existen una serie de limitaciones que podrían afectar los resultados entregados por el LLM.

En primer lugar, existe la posibilidad de tener un sesgo presente en los datos utilizados, debido a tanto como su procedencia, como por la forma en que fueron seleccionados y presentados al modelo. Este mismo sesgo se encuentra también en la naturaleza del experimento, ya que al ser el investigador quien proporciona la información al modelo, se limita deliberadamente el volumen y alcance de los datos (por ejemplo, al entregar entre cinco y siete tablas por activo), en contraste con un escenario donde el modelo tuviera la capacidad de consultar libremente fuentes externas, y escoger la cantidad de tablas que considere necesarias sin limitarse por quien le entrega la información. Dicho de otra manera, el LLM podría acceder a una cantidad mayor de información, de distintas fuentes y con una mayor profundidad temporal (sin tener que limitarse a los años que entrega el investigador), cosa que podría alterar el análisis y las conclusiones generadas.

En conjunto con el punto planteado anteriormente, en el procedimiento de enmascaramiento de datos, implica una ocultación y modificación parcial de los datos reales, lo cual podría limitar la interpretación del modelo. Al eliminar identificadores (como años o países) y referencias específicas (ejemplo: Pandemia Covid – 19), se restringe la posibilidad del LLM de

asociar ciertos comportamientos con eventos o condiciones históricas concretas, lo que podría conllevar a reducir su capacidad de inferencia contextual y análisis causal.

En segundo lugar, existe una variabilidad en las respuestas entregadas por el modelo de lenguaje. Esto es debido a que este tipo de modelos puede generar distintas salidas o respuestas ante consultas similares, por lo que se considera que existe un margen de aleatoriedad que debe ser considerado en esta situación. Con el fin de intentar minimizar en lo posible este efecto, se utiliza un método estandarizado para el diseño de los prompts tal como se menciona en la sección 5.8. No obstante, debido a la naturaleza estocástica de los LLM, se tiene una incertidumbre que no puede ser eliminada por completo.

7 Resultados

En esta sección se presentan los resultados obtenidos a partir de entregar un prompt (input) al modelo de lenguaje (LLM) sobre los distintos activos considerados en el estudio, acompañado de una explicación por parte del LLM.

Tabla 26

Correspondencia entre los activos reales y sus equivalentes enmascarados

Nombre Real	Nombre Ficticio	Tablas de Datos Reales Para Utilizar	Tablas de Datos Enmascarados a Utilizar
NASDAQ Composite (^IXIC)	Andes Global Equity Fund	1; 2; 3; 4; 5	38; 39; 40; 41; 42
SPDR S&P 500 ETF (SPY)	Oceanis Global Tech	6; 7; 8; 9; 5	43; 44; 45; 46; 42
Euro-Dólar (EUR/USD)	Atlas Macro Opportunities	10; 11; 12; 13; 14; 15; 5	47; 48; 49; 50; 51; 52; 42
Bitcoin (BTC/USD)	Altair Strategic Bond	16; 17; 18; 5; 13	53; 54; 55; 42; 50
Oro (XAU/USD)	Delta Currency Asset	19; 20; 21; 5; 13; 15	56; 57; 58; 42; 50; 52
Petróleo Brent (BRENT Crude Oil)	Arkan Strategic Fund	22; 23; 24; 13; 18; 15	59; 60; 61; 50; 55; 52

Fuente: Elaboración propia

En la

Tabla 26 se resume la correspondencia entre el nombre los activos financieros reales y sus equivalentes enmascarados, junto con las tablas de datos utilizadas en cada caso y sus respectivas enmascaradas.

A partir de los datos descritos, se aplicó un único prompt estandarizado al modelo para obtener las proyecciones de cierre ajustado y las recomendaciones de inversión en horizontes de 1, 3, 6 y 12 meses. Dicho prompt se mantuvo idéntico para todos los fondos, con el fin de garantizar comparabilidad entre los resultados y reducir posibles sesgos derivados de la formulación.

A continuación, se presenta el texto utilizado a modo de prompt en el proceso de consulta al modelo:

Prompt:

Actúa como un experto en inversiones y análisis financiero. Analiza la conveniencia de mantener o vender una inversión ya realizada en el siguiente fondo o activo financiero, considerando que la compra se realizaría en la fecha X (correspondiente a la última fecha entregada en los datos proporcionados, también denominada Año Base). El objetivo es evaluar si conviene mantener o vender la inversión al cabo de 1, 3, 6 y 12 meses después de la compra (no se debe interpretar como comprar en esos plazos).

Realiza un análisis totalmente independiente para cada horizonte de tiempo, considerando cada plazo como un escenario aislado del otro, en el que la decisión de mantener o vender se evalúa como si la inversión se liquidara exclusivamente en ese punto temporal, sin influencia de los otros plazos, evitando transferir conclusiones o supuestos entre plazos y utiliza un enfoque cuantitativo y cualitativo basado en tendencias históricas y contexto macroeconómico general. Devuelve tu análisis en una tabla con las siguientes columnas:

1. Plazo evaluado (1 mes, 3 meses, 6 meses, 12 meses)
 2. Recomendación (mantener/ vender / vender con precaución)
 3. Valor de cierre ajustado predicho para ese plazo (en la moneda base)
 4. Justificación (proporciona un razonamiento completo, manteniendo coherencia y claridad en la exposición).
 5. Principales riesgos
 6. Factores clave que podrían modificar el resultado
- No uses tecnicismos financieros complejos; explica en lenguaje accesible para una persona sin conocimientos previos en inversiones.
 - Si falta información necesaria, pídelas antes de responder.
 - Basa el análisis en principios y criterios de inversión sólidos, considerando el contexto económico, el perfil del inversionista, tendencia de mercado, riesgo potencial y otros factores relevantes que consideres pertinentes.
 - Justifica la recomendación usando el valor de cierre ajustado predicho y su relación con el precio de compra.
 - Interpreta “mantener” como la decisión de no vender en ese horizonte temporal debido a que la venta implicaría pérdida o ganancia insuficiente, y no como una expectativa de mayor rentabilidad en plazos posteriores.

Soy una persona natural cuya moneda base es el USD, con tolerancia moderada al riesgo y conocimientos limitados en finanzas. No consideres factores geográficos o regionales en el

análisis, a menos que sean intrínsecos al activo evaluado. Busco una recomendación clara y razonada para decidir si invertir en el fondo descrito, considerando tanto la situación actual del mercado como mi perfil. El análisis no debe considerar el impacto de la variación del tipo de cambio entre el dólar estadounidense y otras monedas.

- Horizonte de inversión (1, 3, 6 y 12 meses)
- Tolerancia al riesgo (conservador, moderado, agresivo)

Si no cuentas con algún dato necesario, solicítalo antes de responder.

7.1 Andes Global Equity Fund (NASDAQ Composite)

Tabla 27

Resultados obtenidos para el fondo Andes Global Equity Fund

Plazo evaluado	Recomendación	Valor de cierre ajustado predicho (USD)	Justificación	Principales riesgos	Factores clave que podrían modificar el resultado
1 mes	Mantener	12 950 USD	Históricamente, el mes siguiente al cierre anual muestra estabilidad o leve alza por efecto del “rebote post-cierre”. Los datos del año base indican fuerte recuperación tras estímulos monetarios y apoyo fiscal. Se prevé leve apreciación, pero insuficiente para justificar venta inmediata.	Volatilidad de corto plazo ante publicaciones de resultados trimestrales y noticias económicas.	Decisiones de tasas de la Fed y variaciones en indicadores de inflación.
3 meses	Vender con precaución	13 350 USD	La tendencia de los últimos años refleja subidas durante el primer trimestre (entre +3 % y +5 %), pero con retrocesos posteriores. Si el mercado mantiene momentum alcista, la ganancia rondaría +3,5 %. Conviene vender solo si se confirma consolidación y evitar exposición prolongada.	Corrección técnica tras rally de cierre de año; repunte de volatilidad global.	Cambios en expectativas de tasas o resultados corporativos negativos.

6 meses	Vender	12 400 USD	En la serie histórica, los semestres posteriores a estímulos o recuperación tienden a corregir parte de las alzas previas. El año base muestra rendimientos superiores al promedio, lo que sugiere riesgo de sobrecompra. Probable caída moderada (~-4 %) hacia mitad de año.	Enfriamiento del crecimiento global; ajustes monetarios más agresivos; caída de commodities.	Evolución del PIB real y tono de política monetaria de la Fed.
12 meses	Vender	11 800 USD	En horizontes anuales, el fondo ha mostrado fuerte sensibilidad a cambios en tasas y crisis globales. Dado el alto perfil de riesgo y la magnitud del alza del año base (+43,6 %), se anticipa toma de utilidades y posible corrección de -8 % a -9 %. Para un inversor moderado, mantener un año implicaría asumir más riesgo que retorno potencial.	Recesión global o desaceleración de EE. UU.; tensiones geopolíticas; deterioro del apetito por riesgo.	Política fiscal y monetaria estadounidense; evolución del dólar frente a otras monedas; confianza empresarial.

Justificación del modelo:

El análisis combina la evolución histórica del fondo, el contexto económico del año base y el perfil de riesgo moderado del inversionista.

El precio de compra (12.888,28 USD) corresponde a un máximo histórico, tras un año de rentabilidad excepcional (+43,6 %). Este tipo de alzas suele preceder fases de corrección o estabilización.

Cuantitativamente, los datos muestran ciclos donde los años de alto crecimiento son seguidos por períodos de ajustes. Cualitativamente, el contexto del año base —caracterizado por políticas monetarias expansivas, estímulos fiscales y señales de sobrecalentamiento— indica que el mercado podría moderarse una vez se normalicen las tasas y el crecimiento.

Dado el perfil de riesgo alto del fondo y la tolerancia moderada del inversionista, se prioriza preservar capital antes que buscar retornos marginales.

Por ello:

A 1 mes, se recomienda mantener, pues el mercado suele estabilizarse tras el cierre anual.

A 3 meses, vender con precaución, aprovechando posibles subidas moderadas.

A 6 y 12 meses, vender, ya que el riesgo de corrección supera el beneficio esperado.

En síntesis, las decisiones equilibran la relación riesgo-retorno, sugiriendo una estrategia conservadora tras un año de máximos históricos.

7.2 Oceanis Global Tech (SPDR S&P 500 ETF)

Tabla 28

Resultados obtenidos para el fondo Oceanis Global Tech

Plazo evaluado	Recomendación	Valor de cierre ajustado predicho (USD)	Justificación (clara y corta)	Principales riesgos	Factores clave que podrían modificar el resultado
1 mes	Mantener	342,53	El RSI cercano a 70 sugiere mercado “cansado” a muy corto plazo. Proyecto -2% vs. compra (349,52 → 342,53). Vender aquí fijaría una pérdida ; por eso conviene no vender en este punto.	Retroceso más profundo de corto plazo; noticias regulatorias sobre tecnológicas; sorpresas negativas en resultados; repunte inesperado de tasas.	Resultados trimestrales mejores a lo esperado; anuncios/contratos relevantes en IA; señales claras de recortes de tasas; mejora del sentimiento del mercado.
3 meses	Mantener	356,51	Tras una posible toma de ganancias inicial, estimo rebote leve (+2%). La ganancia sería pequeña e incierta , insuficiente para justificar la venta para un perfil moderado .	Alta volatilidad del sector; rotación hacia sectores defensivos; guía débil de grandes tecnológicas.	Guías de ingresos sólidas; inflación cediendo y expectativas de tasas más bajas; flujo de noticias positivo en IA/semis.

6 meses	Vender con precaución	369,44	Con el tiempo suficiente para digerir noticias y resultados, proyecto +5% a +6% . Para riesgo moderado , capturar esa ganancia intermedia es razonable. “Con precaución” = estar atento a la trayectoria: si el avance se da antes, puede adelantarse la venta.	Quedarse corto si el rally continúa; shocks macro; regulación adversa; márgenes presionados por CAPEX en IA.	Señales firmes de recortes de tasas y crecimiento estable; sorpresas de beneficios; mejoras de productividad ligadas a IA.
12 meses	Vender	391,46	Escenario base prudente (+12%) alineado con el historial del fondo (promedio de largo plazo ~14%). Para un inversor moderado , una ganancia de dos dígitos justifica materializar beneficios al cumplirse el año.	Recesión o caída fuerte del apetito por riesgo; valuaciones exigentes; evento regulatorio grande.	Ciclo de tasas más benigno de lo previsto; adopción de IA impactando ingresos; crecimiento global mejor al esperado.

Justificación del modelo:

El análisis se basó en una combinación de criterios cuantitativos y cualitativos, considerando el comportamiento histórico del fondo, su valor de cierre ajustado (USD 349,52) en el año base, el RSI de 68,7 (indicando sobrecompra), y la tendencia general del mercado tecnológico en contextos de estabilización monetaria.

Para el plazo de 1 mes, el RSI alto sugiere una corrección técnica leve, por lo que proyecté una caída cercana al 2 %. En este escenario, mantener era más razonable que vender con pérdida.

A 3 meses, se estimó una recuperación moderada posterior a esa corrección, con un aumento cercano al 2 %. La ganancia proyectada era pequeña, por lo que mantener seguía siendo la mejor opción.

En el horizonte de 6 meses, la combinación de factores macroeconómicos (posible recorte de tasas, estabilización de utilidades tecnológicas y menor volatilidad) permitió proyectar una rentabilidad de entre 5 % y 6 %. Aquí recomendé vender con precaución, ya que el retorno comenzaba a ser atractivo sin aumentar significativamente el riesgo.

Finalmente, a 12 meses, la proyección se basó en la rentabilidad promedio histórica del fondo (~14 %), ajustada a un escenario prudente del 12 %. Esto justificó una recomendación de venta, pues representaba un rendimiento adecuado para un perfil moderado y coincidía con los patrones de recuperación observados en los datos de rentabilidad anual.

En conjunto, el análisis cuantitativo (precios, RSI, rentabilidades históricas) y el contexto cualitativo (ciclo económico, comportamiento del sector tecnológico y política monetaria) sustentaron las predicciones y recomendaciones presentadas en la tabla.

7.3 Atlas Macro Opportunities (Euro- Dólar)

Tabla 29

Resultados obtenidos para el fondo Atlas Macro Opportunities

Plazo evaluado	Recomendación	Valor de cierre ajustado estimado (USD)	Justificación	Principales riesgos	Factores clave que podrían modificar el resultado
1 mes	Mantener	≈ 1,22 USD	En el corto plazo el fondo muestra una leve corrección desde 1,23 a 1,22 USD, consistente con la pausa monetaria de la FED y un euro relativamente estable. La volatilidad sigue contenida, por lo que vender ahora implicaría realizar una pérdida menor sin justificación fuerte.	Movimientos inesperados en tasas de interés de la FED o noticias geopolíticas que fortalezcan abruptamente al dólar.	Un repunte de inflación en EE.UU. o señales de mayor endurecimiento monetario.
3 meses	Vender con precaución	≈ 1,18 USD	El patrón histórico indica debilitamiento del fondo a 3 meses en ciclos donde el dólar gana tracción y la FED mantiene postura restrictiva. La pérdida estimada ronda 4-5 %. No hay señales de recuperación inmediata, por lo que una salida parcial podría ser prudente.	Cambios bruscos de expectativas inflacionarias, tensiones en Europa o valorización del dólar como refugio.	Disminución inesperada de inflación o flexibilización anticipada de tasas que favorezcan activos globales.

6 meses	Vender	≈ 1,14 USD	En horizontes semestrales el fondo históricamente se deprecia cuando persisten diferenciales de tasas amplios entre EE.UU. y la Eurozona. El entorno de menor crecimiento global y política monetaria aún restrictiva favorece al dólar, lo que presiona el valor del fondo. Mantener implicaría asumir riesgo de pérdida superior al 7 %.	Recesión moderada o shock geopolítico que impulse el dólar; política del BCE más lenta en normalizar tasas.	Cambio de tono de la FED hacia recortes o estímulos fiscales en EE.UU.
12 meses	Mantener	≈ 1,25 USD	A un año, los datos históricos muestran una recuperación moderada tras los ciclos de ajuste: al estabilizarse las tasas y mejorar las perspectivas globales, el fondo tiende a recuperar valor. El rendimiento proyectado es leve (+1-2 %), pero suficiente para compensar volatilidad previa.	Nueva crisis global o extensión de la política monetaria restrictiva en EE.UU.	Reducción sostenida de inflación y convergencia de políticas FED-BCE que debilite al dólar.

Justificación del modelo:

El fondo Atlas Macro Opportunities, denominado en USD, muestra un comportamiento estrechamente ligado a la evolución de las tasas de interés internacionales y a la fortaleza del dólar frente a otras divisas. Con un valor de compra de 1,23 USD, los datos históricos evidencian que, tras alcanzar niveles similares, el fondo suele experimentar una leve corrección antes de estabilizarse. En el corto plazo (1 mes), la variación esperada es mínima, por lo que se recomienda

mantener la inversión, ya que vender ahora implicaría una pérdida marginal sin justificación suficiente.

A tres meses, el comportamiento proyectado indica una caída moderada hacia los 1,18 USD, consecuencia de un posible fortalecimiento temporal del dólar y de la continuidad de políticas monetarias restrictivas. En este escenario, se sugiere vender con precaución, especialmente si el fondo confirma una tendencia bajista. A seis meses, la probabilidad de depreciación aumenta, con estimaciones cercanas a 1,14 USD, lo que hace aconsejable vender la posición para evitar pérdidas mayores, dado que el entorno económico seguiría desfavorable para activos sensibles a las tasas de interés.

Finalmente, a un horizonte de doce meses, el fondo tiende a recuperar parte de su valor, alcanzando aproximadamente 1,25 USD, impulsado por la estabilización monetaria y un eventual repunte del apetito por riesgo. En este plazo, resulta razonable mantener la inversión, ya que el potencial de recuperación compensa la volatilidad intermedia. En síntesis, para un inversionista con tolerancia moderada al riesgo, la estrategia óptima sería conservar la posición en el corto y largo plazo, pero considerar una venta parcial entre los tres y seis meses si persiste la presión bajista sobre el valor del fondo.

7.4 Altair Strategic Bond (Bitcoin)

Tabla 30

Resultados obtenidos para el fondo Altair Strategic Bond

Plazo evaluado	Recomendación	Valor de cierre ajustado predicho (USD)	Justificación	Principales riesgos	Factores clave que podrían modificar el resultado
1 mes	Vender con precaución	30 800 USD	Tras un salto abrupto desde 17 k a 32 k en apenas un mes, es probable un ajuste técnico de corto plazo. Los activos volátiles suelen corregir entre -5% y -10% tras subidas tan rápidas. Mantener podría implicar pérdida temporal; vender parcialmente reduce exposición.	Corrección técnica; toma de ganancias masiva; anuncios negativos en criptomercado.	Si el sentimiento del mercado se mantiene optimista y el dólar (DXY) sigue débil, el precio podría sostenerse sobre 31 000 USD.
3 meses	Mantener	33 600 USD	Proyecciones apuntan a leve recuperación tras la corrección inicial. En 3 meses el activo podría estabilizarse en torno a $+4\%$ sobre el nivel actual. Para un inversor moderado, mantener permite capturar posible rebote sin asumir gran riesgo adicional.	Repunte de la inflación o subidas inesperadas de tasas FED.	Avances regulatorios favorables o adopción institucional de activos digitales.

6 meses	Mantener	35 900 USD	La historia del activo muestra ciclos de 4-6 meses entre picos y valles. Si la FED reduce tasas gradualmente y el dólar se debilita, el flujo hacia activos especulativos aumenta. Un alza moderada (+10 %) sería coherente.	Cambios bruscos en la política monetaria; crisis de liquidez global.	Bajadas efectivas de tasas o mejora en confianza de inversionistas.
12 meses	Vender	28 000 USD	A largo plazo, activos muy volátiles tienden a sufrir fases de corrección prolongada tras ciclos de euforia. La rentabilidad esperada no compensa el riesgo para un perfil moderado. Mejor realizar ganancias antes de un eventual retroceso mayor.	Caídas amplias en mercados cripto o alza fuerte del DXY; endurecimiento monetario.	Si la inflación se mantiene baja y la política monetaria se torna expansiva, podría sostenerse por encima de 30 k USD.

Justificación del Modelo:

En el corto plazo (1 mes), el activo muestra una subida muy rápida, pasando de 17.730 a 32.193 USD en pocas semanas. Ese salto es insostenible y suele generar una corrección. Por eso se proyecta una leve baja hacia 30.800 USD y se recomienda vender con precaución, protegiendo parte de las ganancias sin salir completamente de la posición.

A tres meses, el precio podría estabilizarse en torno a 33.600 USD. La presión por toma de ganancias disminuye y, si la inflación en EE. UU. sigue controlada y la Reserva Federal mantiene

tasas estables, los activos de riesgo podrían repuntar. En ese escenario, mantener resulta razonable para un inversionista moderado.

A seis meses, se estima un valor cercano a 35.900 USD. Si la política monetaria se flexibiliza y el dólar se mantiene débil, el activo podría beneficiarse. Mantener sigue siendo la mejor opción, siempre que el mercado conserve estabilidad.

En un horizonte de doce meses, es probable que el ciclo alcista pierda fuerza y el precio retroceda hacia 28.000 USD. Los activos volátiles tienden a corregir después de un año de impulsos fuertes, por lo que conviene vender y asegurar beneficios antes de una eventual caída.

En síntesis, el activo ofrece buenas oportunidades a corto y mediano plazo, pero su perfil altamente especulativo hace recomendable retirarse antes del año si se busca un equilibrio entre rentabilidad y riesgo.

7.5 Delta Currency Asset (Oro)

Tabla 31

Resultados obtenidos para el fondo Delta Currency Asset

Plazo evaluado	Recomendación	Valor de cierre ajustado predicho	Justificación (resumen claro)	Principales riesgos	Factores clave que podrían modificar el resultado
1 mes	Mantener	1.840 USD	Diciembre suele marcar “pico” tras el rebote; enero tiende a retroceder en tus datos (p. ej., este año enero estuvo bastante por debajo de diciembre). Con el impulso reciente aún frágil, estimo un retroceso de ~3% desde 1.896,49. Vender ahora arriesga materializar una pérdida pequeña sin una señal clara de cambio de tendencia.	Volatilidad de corto plazo; toma de utilidades estacional; noticias macro puntuales.	Que el activo muestre continuación alcista inmediata (quiebre claro por sobre ~1.900–1.920 con volumen) o que aparezca un shock de “flight to quality” que lo impulse.

3 meses	Mantener	1.720 USD	Históricamente el 1T se ve más débil en tu tabla (oct-dic fuertes, ene-mar más bajos). Proyecto un ajuste acumulado de ~9% vs. compra. Vender a 3 meses significaría cerrar cerca de mínimos estacionales; mantener evita cristianizar la baja en un punto estadísticamente flojo.	Profundización de la corrección; noticias de tasas que presionen a la baja los activos refugio; decepción en datos de crecimiento.	Señales tempranas de recuperación en febrero-marzo (mínimos crecientes) o giro de política monetaria que sostenga activos indexados.
---------	----------	--------------	---	---	---

6 meses	Vender con precaución	1.930 USD	A mediados de año tus datos muestran recuperaciones (jun-jul fuertes). Estimo vuelta a zona de breakeven / ligera ganancia ($\sim +1,8\%$). Dado tu perfil moderado, una utilidad menor al 3% en 6 meses es modesta; si el precio alcanza la zona 1.920–1.950, tiene sentido salir y asegurar resultado, dejando un margen si el impulso pierde fuerza.	Falsos rebotes; lateralidad prolongada; noticias que cambien el apetito por refugio.	Confirmación de máximos y mínimos crecientes hacia mayo-junio; si supera sostenidamente ~ 1.975 , podrías replantear mantener más tiempo.
---------	-----------------------	-----------	---	--	--

12 meses	Vender	2.020 USD	La serie muestra tendencia de fondo positiva entre años (dic de años anteriores fue crecientemente mayor). Con un año completo, proyecto $\sim +6,5\%$ sobre la compra. Para un inversor moderado, es una ganancia razonable a 12 meses con riesgos manejables; vender consolida el avance y evita depender de ciclos posteriores.	Giro brusco de política monetaria; caída global del apetito por refugio; cambios en la metodología del índice.	Si el activo entra en rally sostenido (ruptura clara y mantenida sobre 2.000–2.050 con volumen y sin deterioro macro), el potencial podría ampliarse; en ese caso, valdría replantear objetivos.
----------	--------	-----------	--	--	--

Justificación del Modelo:

El análisis del fondo se basa en la observación de una tendencia lateral-alcista débil, evidenciada por un máximo cercano a 1.975 USD a mitad del año base, una corrección progresiva hasta noviembre con valores alrededor de 1.777 USD y un rebote en diciembre hasta los 1.896 USD, correspondiente al precio de compra. Este comportamiento sugiere un proceso de recuperación moderada tras una fase de ajuste, sin una señal sólida de nuevo impulso alcista. En el contexto macroeconómico actual, caracterizado por tasas de interés aún elevadas, inflación controlada y crecimiento global limitado, es razonable anticipar una volatilidad leve en el corto plazo y una recuperación gradual a mediano y largo plazo, especialmente si la Reserva Federal inicia un ciclo de recortes de tasas. Las proyecciones estimadas, obtenidas a partir de variaciones

mensuales históricas y patrones estacionales, apuntan a una leve baja al primer mes (1.840 USD), una caída más acentuada a los tres meses (1.720 USD), una recuperación hacia el equilibrio a los seis meses (1.930 USD) y una tendencia positiva moderada al cabo de doce meses (2.020 USD). En conjunto, el análisis combina la evolución histórica del precio, las condiciones macroeconómicas y una gestión del riesgo coherente con un perfil moderado, concluyendo que conviene mantener la inversión en el corto plazo, vender con precaución a seis meses y consolidar ganancias a los doce meses.

7.6 Arkan Strategic Fund (Petróleo Brent)

Tabla 32

Resultados obtenidos para el fondo Arkan Strategic Fund

Plazo evaluado	Recomendación	Valor de cierre ajustado predicho (USD)	Justificación	Principales riesgos	Factores clave que podrían modificar el resultado
1 mes	Mantener	≈ 46,8 USD	El repunte técnico esperado tras una caída prolongada sugiere un pequeño rebote (≈ +5 %). Los indicadores de volatilidad (VIX ~ 20) y tasas estables de la FED respaldan una leve recuperación a corto plazo. Vender ahora implicaría perder ese posible repunte sin reducir riesgo significativamente.	Corrección súbita del crudo o tensiones en Oriente Medio que eleven el riesgo y depriman precios.	Evolución del VIX, anuncios de la OPEP+ y datos de inflación de EE. UU.
3 meses	Vender con precaución	≈ 48,9 USD	El rebote podría sostenerse unos meses, pero se prevé una estabilización por exceso de oferta y un DXY al alza que limita avances. La ganancia sería moderada (+10 %), adecuada para reducir exposición si tu perfil es moderado.	Subida inesperada de tasas o desaceleración global.	Decisiones de la FED y demanda industrial china.

6 meses	Vender	≈ 43,1 USD	La historia muestra que tras repuntes breves, los fondos energéticos suelen corregir en el semestre siguiente. Si el dólar se fortalece y la economía se enfría, el precio podría caer cerca del valor de compra. Vender antes del semestre evitaría una pérdida potencial.	Persistencia de inflación o recesión técnica en EE. UU.	Política monetaria restrictiva o caída en la demanda de petróleo.
12 meses	Vender	≈ 38,5 USD	Proyección de tendencia bajista moderada a largo plazo: mayores tasas reales, desaceleración del crecimiento y ajuste del mercado energético. Mantener un año implicaría asumir alta volatilidad y probable pérdida (~ -13 %). No es coherente con perfil de riesgo moderado.	Shock geopolítico que dispare temporalmente los precios energéticos.	Relación entre DXY, inflación global y decisiones de la OPEP+.

Justificación del Modelo:

El fondo Arkan Strategic Fund, vinculado al mercado energético global, ha mostrado una evolución marcada por la alta volatilidad, influida por los ciclos de oferta y demanda, las decisiones de la OPEP+, la fortaleza del dólar y las variaciones en las tasas de interés internacionales. En diciembre del Año Base su precio fue de 44,52 USD, un nivel bajo dentro de su rango histórico, lo que refleja un mercado presionado pero con cierto margen para una recuperación temporal.

A corto plazo, durante el primer mes, es probable un leve repunte hasta cerca de 46,8 USD, impulsado por la estabilidad de las tasas de la Reserva Federal y una menor volatilidad general. En este escenario, mantener la inversión es razonable para capturar esa pequeña alza sin asumir mayores riesgos. En un horizonte de tres meses, el valor podría alcanzar 48,9 USD, favorecido por factores estacionales y cierta cooperación en los recortes de producción, aunque la fortaleza del dólar limitaría el crecimiento. En este punto conviene vender con precaución, asegurando una ganancia moderada.

A seis meses, la tendencia apunta a una corrección hacia 43,1 USD, ya que el mercado tiende a ajustarse tras los rebotes, afectado por la desaceleración económica global y la caída de la demanda energética. Por eso, mantener más allá de este plazo aumentaría el riesgo sin una compensación adecuada. Finalmente, a doce meses, el escenario proyecta un descenso hasta alrededor de 38,5 USD, debido al endurecimiento monetario, la fortaleza del dólar y el menor dinamismo industrial, lo que justifica una venta definitiva.

En síntesis, mantener la posición solo sería prudente a muy corto plazo, mientras que en horizontes de seis meses o más se recomienda vender, ya que el riesgo de pérdida supera las expectativas de rentabilidad para un perfil de riesgo moderado.

8 Análisis y Discusión

8.1 Análisis Cuantitativo

El propósito del análisis cuantitativo es evaluar con qué nivel de precisión el modelo de lenguaje (LLM) fue capaz de proyectar los valores de distintos activos financieros en comparación con los datos reales del mercado.

Siguiendo la metodología descrita en la sección 6.7, se realizaron proyecciones a cuatro horizontes temporales, 1, 3, 6 y 12 meses, tomando como punto de partida Diciembre de 2020, según las tablas de la sección 6.4.

Una vez obtenidas cada una de las proyecciones, estas se compararon con los valores reales observados durante los meses de Enero, Marzo, Junio y Diciembre del año 2021, lo que permitió cuantificar su grado de exactitud y establecer una base clara para el análisis que se desarrolla en las subsecciones siguientes.

Tabla 33

Comparación entre valores reales y proyecciones LLM por activo y horizonte temporal.

Nombre del Fondo	Periodo	Valor Real	Resultado LLM (USD)
NASDAQ Composite (^IXIC)	1 Mes	13.070	12.950
	3 Meses	13.246	13.350
	6 Meses	14.503	12.400
	12 Meses	15.254	11.800
SPDR S&P 500 ETF (SPY)	1 Mes	346,47	342,53
	3 Meses	371,06	356,51
	6 Meses	402,08	369,44
	12 Meses	449,02	391,46
Euro-Dólar (EUR/USD)	1 Mes	1,21	1,22
	3 Meses	1,17	1,18
	6 Meses	1,19	1,14
	12 Meses	1,13	1,25
Bitcoin (BTC/USD)	1 Mes	33.108	30.800
	3 Meses	58.764	33.600
	6 Meses	35.027	35.900
	12 Meses	46.220	28.000
Oro (XAU/USD)	1 Mes	1.846	1.840
	3 Meses	1.707	1.720
	6 Meses	1.769	1.930
	12 Meses	1.828	2.020
Petróleo Brent (BRENT Crude Oil)	1 Mes	54,55	46,80
	3 Meses	65,19	48,90
	6 Meses	73,07	43,10
	12 Meses	74,31	38,50

Fuente: Información extraída de (Yahoo Finance, (s.f.)), (Yahoo Finance, (s.f.)), (Yahoo Finance, (s.f.)), (Investing, (s.f.)), (Investing, (s.f.)), (Base de Datos Estadísticos (BDE), (s.f.)).

Los valores expuestos en la Tabla 33 constituyen la base de cálculo para el análisis cuantitativo, donde se exponen los valores entregados por el LLM y los valores reales de cada fondo o activo, acompañados de su respectivo periodo.

8.1.1 Cálculo del error porcentual relativo

En esta subsección se presenta el cálculo del error porcentual relativo correspondiente a los resultados entregados por el LLM. El propósito de este cálculo es poder cuantificar la diferencia existente entre los valores reales y las estimaciones entregadas por el modelo en cada horizonte temporal.

Como se menciona en la sección 1086.7.1, la fórmula de error porcentual relativo utilizada es:

$$\text{Error porcentual} = \left| \frac{(\text{Valor estimado} - \text{Valor real})}{\text{Valor real}} \right| \times 100\%$$

Posterior al cálculo del error porcentual, se aplicó el criterio de aceptación del 5 % tal como se detalla en la sección 6.7.1, de modo que aquellas predicciones cuyo error porcentual fuese igual o inferior a dicho umbral se consideraron correctas, mientras que las que tuvieran un error porcentual mayor al 5% fueron clasificadas como incorrectas.

Tabla 34

Error porcentual relativo y precisión de las predicciones del modelo

Nombre del Fondo	Periodo	Error Porcentual	Predicción correcta
NASDAQ Composite (^IXIC)	1 Mes	0,9%	Correcta
	3 Meses	0,8%	Correcta
	6 Meses	14,5%	Incorrecta
	12 Meses	22,6%	Incorrecta
SPDR S&P 500 ETF (SPY)	1 Mes	1,1%	Correcta
	3 Meses	3,9%	Correcta
	6 Meses	8,1%	Incorrecta
	12 Meses	12,8%	Incorrecta
Euro–Dólar (EUR/USD)	1 Mes	0,5%	Correcta
	3 Meses	0,6%	Correcta
	6 Meses	4,2%	Correcta
	12 Meses	10,4%	Incorrecta
Bitcoin (BTC/USD)	1 Mes	7,0%	Incorrecta
	3 Meses	42,8%	Incorrecta
	6 Meses	2,5%	Correcta
	12 Meses	39,4%	Incorrecta
Oro (XAU/USD)	1 Mes	0,3%	Correcta
	3 Meses	0,8%	Correcta
	6 Meses	9,1%	Incorrecta
	12 Meses	10,5%	Incorrecta
Petróleo Brent (BRENT Crude Oil)	1 Mes	14,2%	Incorrecta
	3 Meses	25,0%	Incorrecta
	6 Meses	41,0%	Incorrecta
	12 Meses	48,2%	Incorrecta

Los valores presentados en la Tabla 34 muestran el resultado del cálculo del error porcentual relativo para cada horizonte de predicción y cada fondo o activo analizado, además de la clasificación de si cada una de las estimaciones fue correcta o incorrecta. De esta manera, se

resume el nivel de exactitud alcanzado por el modelo en cada activo y servirá como base para el análisis del desempeño por horizonte de tiempo y tipo de fondo que se desarrolla a continuación.

8.1.2 Evaluación de desempeño por horizonte de tiempo

En esta subsección se analiza el desempeño del modelo en base al horizonte temporal de proyección, con el fin de observar cómo varía la fiabilidad del mismo conforme se amplía el período de estimación.

Para ello, se contabiliza el número de predicciones clasificadas como correctas (aquellas cuyo error porcentual fue igual o inferior al 5%) en cada horizonte de tiempo, además de calcular el porcentaje de aciertos, sabiendo que en total se proyectaron seis fondos.

Con este análisis se logra identificar en qué plazos el modelo mantiene mayor exactitud, en cuáles presenta un deterioro en su capacidad predictiva, además de si en cierto lapso de tiempo en adelante disminuye la capacidad de predicción, o se vuelve nula.

Tabla 35

Desempeño del modelo según horizonte temporal de predicción

Periodo	N° de Aciertos	Porcentaje de aciertos
1 Mes	4	67%
3 Meses	4	67%
6 Meses	2	33%
12 Meses	0	0%

Los valores presentados en la Tabla 35 resume la cantidad total de aciertos alcanzados por el modelo en cada horizonte de predicción, junto con un porcentaje de aciertos de cada periodo.

En los períodos proyectados de uno y tres meses se obtuvieron cuatro aciertos en cada uno. No obstante, a partir de los 6 meses, el número de aciertos disminuye a la mitad, y en el horizonte

de 12 meses el modelo no logra hacer predicciones correctas, en base al umbral de tolerancia definido previamente.

Por ende, se puede concluir que a partir del cuarto mes en adelante, el rendimiento del LLM para la predicción de valores futuros de los fondos disminuye o se vuelve nulo, lo que se traduce en que no es útil para fechas mayores a tres meses.

8.1.3 Desempeño por tipo de fondo o activo

En esta subsección se analiza el desempeño del modelo de lenguaje según el tipo de activo financiero considerado. El objetivo es determinar en qué categorías el modelo logra un mayor porcentaje de predicciones correctas. Para ello, se contabilizó la proporción de aciertos obtenidos por cada fondo o activo a lo largo de los cuatro horizontes temporales analizados, aplicando el mismo criterio de aceptación del 5 % de error porcentual relativo.

Tabla 36

Desempeño del modelo según tipo de fondo o activo financiero.

Nombre del Fondo	Tipo de Fondo o Activo	Periodo	Predicción correcta	Porcentaje de predicciones correctas
NASDAQ Composite (^IXIC)	Índice de Renta Variable (Indexado)	1 Mes	Correcta	50%
		3 Meses	Correcta	
		6 Meses	Incorrecta	
		12 Meses	Incorrecta	
SPDR S&P 500 ETF (SPY)	ETF Renta Variable (Indexado)	1 Mes	Correcta	50%
		3 Meses	Correcta	
		6 Meses	Incorrecta	
		12 Meses	Incorrecta	
Euro-Dólar (EUR/USD)	Par de Divisas / Mercado Forex (Indexado)	1 Mes	Correcta	75%
		3 Meses	Correcta	
		6 Meses	Correcta	
		12 Meses	Incorrecta	
Bitcoin (BTC/USD)	Criptomoneda / Activo digital descentralizado	1 Mes	Incorrecta	25%
		3 Meses	Incorrecta	
		6 Meses	Correcta	
		12 Meses	Incorrecta	
Oro (XAU/USD)	Materia prima / Commodity financiero (Indexado)	1 Mes	Correcta	50%
		3 Meses	Correcta	
		6 Meses	Incorrecta	
		12 Meses	Incorrecta	
Petróleo Brent		1 Mes	Incorrecta	0%
		3 Meses	Incorrecta	

(BRENT Crude Oil)	Materia prima / Commodity energético	6 Meses	Incorrecta	
		12 Meses	Incorrecta	

La Tabla 36 refleja, un comportamiento heterogéneo del modelo, debido a que el porcentaje de predicciones se mueve entre un 0% y un 75%.

Para los instrumentos de renta variable, tales como NASDAQ Composite y SPDR S&P 500 ETF, el LLM alcanza un 50% para ambos casos, demostrando un nivel de precisión intermedio.

En el caso de las materias primas, el desempeño es más dispar, debido a que el oro (XAU/USD) obtiene también un 50 % de aciertos, reflejando una respuesta poco favorable para el modelo. El oro es considerado activo de refugio, con un comportamiento que suele ser más predecible, por lo que se esperaría obtener un mayor porcentaje de aciertos.

Por otro lado, el petróleo Brent (BRENT Crude Oil) no presenta predicciones correctas, lo que indica que el modelo no logra reproducir las variaciones de este mercado, esto se puede deber a su alta sensibilidad a factores geopolíticos y a eventos exógenos difíciles de anticipar.

En definitiva para las materias primas el LLM no presenta buenos resultados, descartándolo en la predicción para este tipo de activo financiero.

En cuanto a los activos de tipo divisa, como el par Euro–Dólar (EUR/USD), se destaca con un 75 % de aciertos, constituyendo el mejor desempeño general entre todos los activos analizados.

Por último, la categoría de criptomoneda, representada por el Bitcoin (BTC/USD), presenta el peor desempeño junto con las materias primas, debido a que esta tiene apenas un 25% de aciertos, reflejando la alta volatilidad de este tipo de activo financiero.

En síntesis, los resultados muestran que el modelo LLM logra un mejor desempeño en activos de tipo divisa, donde alcanza el mayor porcentaje de aciertos y una menor variabilidad en los errores. Le siguen los instrumentos de renta variable, que presentan un nivel de precisión intermedio (50%). En contraste, el modelo exhibe un rendimiento deficiente en las materias primas y las criptomonedas, categorías donde las predicciones resultaron poco confiables o nulas.

Estos resultados permiten concluir que la capacidad predictiva del modelo depende en gran medida del comportamiento intrínseco de cada mercado, mostrando una mayor coherencia en activos con fluctuaciones moderadas, y un desempeño limitado en aquellos afectados por alta volatilidad o por factores exógenos difíciles de modelar.

8.1.4 Desempeño individual por fondo o activo

El propósito de este análisis es determinar si existen diferencias significativas en los resultados del modelo en función de la periodicidad de los datos (mensual o semanal) y del volumen de información proporcionado para cada activo.

La periodicidad de los datos entregados corresponde a la frecuencia de los valores de cierre del fondo o activo, es decir, los precios observados en cada intervalo temporal que conforman la tabla de datos históricos. Por otro lado, la cantidad de tablas de información entregadas representa el número de conjuntos de datos que fueron suministrados al LLM para generar sus proyecciones. De esta manera, el análisis busca identificar si la frecuencia o el volumen de información tienen alguna relación con el nivel de exactitud obtenido.

Tabla 37

Desempeño del modelo según la periodicidad y cantidad de información entregada por fondo o activo

Nombre del Fondo	Tipo de Fondo o Activo	Periodicidad de los datos entregados	Cantidad de Tablas de información entregadas	Porcentaje de predicciones correctas
NASDAQ Composite (^IXIC)	Índice de Renta Variable (Indexado)	Mensual	5	50%
SPDR S&P 500 ETF (SPY)	ETF Renta Variable (Indexado)	Mensual	5	50%
Euro-Dólar (EUR/USD)	Par de Divisas / Mercado Forex (Indexado)	Mensual	7	75%
Bitcoin (BTC/USD)		Semanal	5	25%

	Criptomoneda / Activo digital descentralizado			
Oro (XAU/USD)	Materia prima / Commodity financiero (Indexado)	Mensual	6	50%
Petróleo Brent (BRENT Crude Oil)	Materia prima / Commodity energético	Mensual	6	0%

A partir de los resultados de la Tabla 37, se observa que no existe una relación directa entre la frecuencia de los datos y la precisión de las predicciones. Esto debido a que el único activo con periodicidad semanal, Bitcoin (BTC/USD), alcanzó un 25 % de aciertos, lo cual no es un resultado mejor, ni tampoco peor al de los activos con datos mensuales, lo que sugiere que una mayor frecuencia de actualización no necesariamente mejora el desempeño del modelo.

En cuanto a la cantidad de información entregada, el par Euro–Dólar (EUR/USD), el cual tiene siete tablas de datos (tablas 5, 10, 11, 12, 13, 14, 15) logró el mayor porcentaje de aciertos (75%), lo que podría indicar que una mayor cantidad de información entregada al modelo genera mejores resultados. Sin embargo, el petróleo Brent, que tiene seis tablas de información, lo cual es mayor al promedio, no registró predicciones correctas, lo que indica que no necesariamente, más información signifique mejores resultados, o dicho de otra manera, evidencia que el efecto del volumen de datos no es determinante por sí mismo, y que otros factores pueden influir en los resultados.

Entre estos factores, se debe destacar el propio comportamiento interno del modelo LLM, debido a que el hecho de proporcionar información no garantiza que sea procesada de manera

completa, efectiva o coherente por el LLM. El modelo puede no considerar ciertos datos entregados, debido a que puede priorizar otros según su interpretación contextual, o simplemente considerar que no son útiles en el análisis, a esto se le puede agregar la naturaleza estocástica del modelo, lo que puede generar variaciones en como analiza los datos, generando variaciones en los resultados finales. Por lo tanto, las diferencias observadas podrían estar relacionadas no solo con la calidad y estabilidad de los datos históricos, sino también con la forma en que el modelo interpreta y utiliza dicha información durante el proceso de predicción.

En síntesis, el análisis individual muestra que los resultados entregados por el LLM no dependen solamente de la frecuencia ni del volumen de información entregada, sino de una combinación de factores, entre los que se pueden destacar, la naturaleza del activo, la coherencia de sus datos históricos, y la manera en que el modelo procesa la información disponible.

8.2 Análisis Cualitativo

Este capítulo desarrolla el análisis cualitativo de los resultados obtenidos por el modelo de lenguaje, esto con el propósito de evaluar la coherencia, la consistencia argumentativa, la solidez conceptual, de las respuestas entregadas en las proyecciones de los distintos activos financieros, además de analizar la forma en que el modelo interpretó los datos durante el proceso de estimación.

A diferencia del análisis cuantitativo, el cual midió la precisión numérica de las predicciones, y como distintos factores podían afectar al resultado, este análisis se centra en la forma en que el modelo construye y justifica sus estimaciones, considerando la calidad de su razonamiento y su relación con la información proporcionada.

De acuerdo con lo establecido en la metodología, el análisis se centra en cuatro dimensiones principales, la coherencia argumentativa del razonamiento, la correspondencia entre las respuestas y los datos entregados, si se usa y como se usa lenguaje técnico y los conceptos financieros, y, por último, la identificación de sesgos o patrones discursivos presentes en las proyecciones.

A partir de estas dimensiones, se busca determinar si el modelo demuestra capacidad interpretativa y fundamentación lógica en su proceso de predicción, o si sus respuestas se limitan a enunciados genéricos carentes de sustento empírico.

8.2.1 Coherencia argumentativa y estructura del razonamiento

En términos generales, el modelo mantiene una coherencia formal adecuada en sus respuestas, estructurando sus proyecciones bajo una lógica comprensible y ordenada. Sin embargo, se logra notar que el grado de profundidad de las justificaciones puede variar según el tipo de activo y el horizonte de análisis.

En el caso del NASDAQ Composite y del SPDR S&P 500 (SPY), el modelo presenta una argumentación consistente, con argumentos prudentes y razonamientos que tienen coherencia con el comportamiento general del mercado.

En ambos fondos, las recomendaciones están bien justificadas, en el caso del SPY se destaca el uso de la terminología técnica, como el RSI, el cual es un indicador técnico que ayuda a identificar si un activo está sobrecomprado o sobrevendido, lo que demuestra que el modelo es capaz de integrar conceptos financieros básicos dentro de su argumentación.

Para las divisas Euro-Dólar, el modelo de lenguaje realiza una argumentación con cierta apariencia de coherencia, pero con falta de rigor lógico en algunas justificaciones. Si bien logra reconocer tendencias y utiliza conceptos como “corrección” y “riesgo asumido”, sus recomendaciones no están alineadas con los valores proyectados, lo que evidencia un razonamiento superficial. De todas formas, se aprecia una intención de mantener consistencia y de incorporar terminología financiera apropiada, lo cual no es malo, pero lleva a malas recomendaciones, que puedes generar pérdidas por parte del inversionista.

En el caso de Bitcoin (BTC/USD), la coherencia argumentativa se debilita de forma notoria. Las justificaciones tienden a ser ambiguas o poco detalladas, recurriendo a frases neutras ante escenarios volátiles. Aunque el modelo demuestra cierto entendimiento conceptual al

mencionar fenómenos como ciclos de euforia o corrección, la justificación poco detallada reduce la solidez de su razonamiento.

Por otro lado, para el oro (XAU/USD) el modelo entrega una argumentación más equilibrada y coherente. Describe una tendencia de crecimiento, pero de manera suave, lo que concuerda con la definición de un activo refugio, manteniendo una relación lógica entre su interpretación y la recomendación final. Este caso demuestra que el modelo logra adaptarse de mejor forma a mercados estables, donde las existe menor variabilidad de condiciones.

En conjunto, se concluye que el modelo tiene una argumentación coherente y formalmente consistente, aunque con una profundidad analítica limitada. El modelo tiene un desempeño más sólido en activos estables o de comportamiento tendencial, mientras que en los mercados de alta volatilidad (Bitcoin) sus justificaciones pierden precisión y sustento. En todos los casos, el modelo conserva la forma del discurso coherente, pero no alcanza un razonamiento suficientemente analítico como para reflejar comprensión total de los factores financieros que influyen en cada activo.

8.2.2 Correspondencia con la información entregada

En base a lo planteado anteriormente en la sección 4.7.2, esta subsección evalúa el grado de correspondencia entre las justificaciones del modelo de lenguaje y la información entregada en las tablas de datos, esto con el fin de determinar si las proyecciones se sustentan efectivamente con los datos entregados o si se limitan a argumentaciones generales sin un mayor fundamento numérico.

En términos generales, el modelo muestra una relación con los datos entregados, en donde logra reconocer las tendencias generales de cada activo, pero no logra incorporar de forma explícita los valores o variaciones reales. Esto demuestra que el modelo utiliza la información como referencia contextual, más que como una base analítica concreta.

En los activos de renta variable, como el NASDAQ Composite y el SPY, la correspondencia con los datos es moderadamente alta, ya que las justificaciones reflejan movimientos coherentes con los valores históricos, especialmente en el caso del SPY, donde el modelo emplea indicadores técnicos como el RSI.

Por otro lado, si vemos el par Euro-Dólar (EUR/USD) y los activos de que tienen una mayor volatilidad, como es el caso del Bitcoin (BTC/USD) y el petróleo Brent, la correspondencia con los datos es baja, debido a que las recomendaciones y explicaciones se alinean del todo con los datos entregados, recurriendo a argumentos genéricos o poco precisos.

En el caso del oro (XAU/USD), este representa un nivel de correspondencia intermedio, debido a que el modelo logra mantener coherencia con la tendencia lateral-alcista observada en los datos del precio del oro, pero, no profundiza mayormente en los datos.

De manera resumida, el modelo logra interpretar las tendencias de manera general, pero su razonamiento no se apoya del todo en los datos que son distintos al valor de cierre del fondo, lo que reduce la solidez empírica de sus justificaciones. Por ende, la correspondencia es aceptable en activos estables, pero decae a un nivel deficiente en aquellos con un mayor grado de volatilidad o comportamientos menos predecibles.

8.2.3 Uso del lenguaje técnico y comprensión conceptual

De acuerdo con la sección 4.7.2, esta subsección analiza el uso de terminología técnica y conceptos financieros en las justificaciones del LLM, evaluando si estos se usan, y si están aplicados de una forma coherente y contextualizada.

En general, el modelo si emplea un lenguaje financiero, pero de manera superficial. Utiliza términos como “corrección”, “volatilidad” o “tendencia alcista”, los cuales usa de manera coherente para sustentar sus recomendaciones. Sin embargo, en la mayoría de los activos el modelo menciona estos conceptos, pero no los analiza en profundidad, limitándose a un uso descriptivo más que interpretativo, lo que puede generar confusión en alguien con poco conocimiento financiero.

En activos más estables, el lenguaje técnico es correcto y consistente, mientras que en activos volátiles, las justificaciones son más genéricas, y poco fundamentadas, lo que conlleva a no tener una buena justificación.

En síntesis, el modelo demuestra conocimiento básico de la terminología financiera, pero no evidencia una comprensión profunda sobre cómo estos conceptos influyen realmente en las proyecciones.

8.2.4 Sesgos discursivos y patrones de comportamiento

De acuerdo con lo establecido en la sección 4.7.2, esta subsección busca identificar la presencia de sesgos o patrones en las respuestas del modelo, analizando si existe una tendencia constante en la forma de justificar los resultados, independientemente del tipo de activo o del contexto de los datos.

A modo general, se observa una tendencia a la prudencia y neutralidad en el discurso del modelo. El LLM evita emitir afirmaciones categóricas o riesgosas, optando por justificaciones equilibradas o moderadas, como “mantener la posición” o “esperar confirmación de tendencia”, manteniéndose adverso al riesgo, incluso en casos donde los datos permitirían decisiones más definidas.

Este comportamiento demuestra que el modelo tiene un sesgo conservador (que evita el riesgo), el cual es posiblemente derivado del entrenamiento previo del modelo, el cual prioriza respuestas seguras y evita recomendaciones extremas. Además, se logra identificar una repetición en la estructura de la argumentación, en donde el modelo suele presentar primero una descripción general del mercado, seguida de una justificación prudente y una recomendación final. Si bien esta secuencia aporta orden, también evidencia una falta de adaptabilidad contextual, ya que constantemente replica con escasas variaciones entre activos de distinta naturaleza.

En síntesis, el modelo presenta un sesgo orientado hacia la cautela y la moderación, lo que le permite mantener coherencia formal pero limita su capacidad de adaptación y análisis diferenciado entre tipos de activos, también, se logra notar que a pesar de mencionar que el inversionista es una persona que busca un nivel de riesgo moderado, el modelo no toma consideración, buscando constantemente el menor nivel de riesgo posible.

Este comportamiento indica que el modelo privilegia la seguridad argumentativa por sobre la interpretación específica de los datos, lo cual afecta su profundidad analítica.

9 Conclusión

A partir de lo expuesto en el marco teórico, y en el análisis desarrollado, se concluye que, si bien la inteligencia artificial o IA y, en este caso en específico, los modelos de lenguaje de gran escala (LLM) han logrado un avance significativo, lo que los lleva a una integración en múltiples sectores, aún no poseen la madurez necesaria para desempeñar un rol autónomo en la toma de decisiones, y más específicos en decisiones financieras. Tal como se describe en el marco teórico, la IA ha demostrado su utilidad en una gran gamma de ámbitos como la salud, la educación, el análisis de datos empresariales y la automatización de procesos, pero en todos estos casos opera principalmente como herramienta de apoyo y no como reemplazo del juicio humano.

Diversos autores mencionados en el marco teórico mencionan que la IA funciona eficazmente cuando complementa la labor de un profesional experto. Por ejemplo, dentro de lo que se menciona sobre la literatura en minería de texto y análisis de sentimiento, se menciona que la IA destaca debido a que puede procesar grandes volúmenes de información en tiempo real, pero también advierte que su rendimiento depende en gran medida de la calidad y estructura de los datos, así como del criterio humano para interpretar los resultados. Asimismo, la Unesco (Reflexiones sobre el uso Ético de la Inteligencia Artificial, 2025) plantea que la información generada por los modelos de lenguaje debe pasar un proceso de revisión, ya que estos no garantizan exactitud total y pueden incurrir en errores significativos.

Estos antecedentes teóricos, crean una sospecha de las limitaciones de estos modelos, que luego se logran evidenciar de manera empírica en el experimento desarrollado en esta memoria. Tal como se observó, el modelo fue capaz de elaborar argumentaciones coherentes, bien estructuradas y con un uso adecuado del lenguaje técnico; sin embargo, su desempeño cuantitativo mostró importantes deficiencias. Aunque en ocasiones fue capaz de identificar tendencias

generales y ofrecer justificaciones razonables, sus predicciones no lograron niveles de precisión satisfactorios, especialmente en horizontes superiores a tres meses. De todas maneras, en períodos de corto plazo, las desviaciones respecto de los valores reales superaron ampliamente los márgenes que podrían considerarse aceptables para un inversor con tolerancia al riesgo de nivel medio.

Esto confirma que, los LLM presentan dificultades para capturar la dinámica compleja de mercados financieros, caracterizados por un grado no menor de volatilidad, múltiples periodicidades, sensibilidades a factores externos y dependencia de variables macroeconómicas que el modelo no es capaz de integrar en su totalidad. De igual forma, la literatura revisada muestra que la IA tiende a otorgar más peso a datos recientes, lo que coincide con los resultados obtenidos, en donde al variar la extensión del período histórico entregado, más datos no implicaran mejores resultados.

Desde esta perspectiva, los hallazgos del experimento no solo corroboran lo ya concluido en el marco teórico, sino que además refuerzan la idea central de este, el uso de IA sin el criterio de un experto puede conducir a conclusiones equívocas y decisiones inadecuadas, especialmente en contextos donde la precisión es tan importante. Un usuario sin conocimientos financieros o con poco conocimiento financiero, que confíe ciegamente en la herramienta podría interpretar sus resultados como certezas o recomendaciones totalmente válidas, cuando en realidad presentan márgenes de error demasiado altos, como para sustentar una decisión de inversión.

En contraste, para un usuario con conocimientos de finanzas, los LLM sí pueden ofrecer un aporte significativo. Pueden facilitar el análisis de datos, sintetizar información extensa y explicar contextos económicos complejos. Este rol complementario, es coherente con las advertencias que diversos autores plantean sobre la necesidad de que la IA sea supervisada, interpretada y validada por humanos con conocimiento del área.

En resumen, esta investigación demuestra que los modelos de lenguaje de gran escala, como ChatGPT, aún no poseen la capacidad necesaria para tomar decisiones financieras con precisión. Su valor reside principalmente en apoyar el proceso análisis, ayudar con la contextualización informativa y asistir en la comprensión del mercado, siempre bajo la guía de un usuario informado. El trabajo confirma así que las expectativas iniciales no son del todo correctas, pues la IA, en su estado actual, es una herramienta útil pero no autónoma, y su efectividad depende en gran medida del criterio y experiencia del usuario que la emplea.

10 Perspectivas futuras

Aunque la investigación permitiera evaluar el desempeño de un modelo de lenguaje de gran escala (LLM) en la predicción de distintos activos financieros, se pueden identificar múltiples opciones para continuar con el análisis que podrían enriquecer significativamente futuros estudios.

En primer lugar, resulta relevante estudiar la sensibilidad del modelo ante variaciones en la formulación del prompt. Futuras investigaciones podrían estudiar y analizar esto, un buen método, es evaluar cómo se comporta el LLM cuando no se le solicita de manera explícita una recomendación de inversión (mantener, vender o comprar), esto es con el fin de determinar si el modelo infiere algún tipo de sesgo con estas recomendaciones. También se puede analizar si permitir que el modelo genere predicciones sin segmentación por horizonte temporal, permitiría mejores resultados o sugerencias, ejemplo, si al mes 1, se está rentando un 2%, lo cual ya sería útil para retirar, debido a que se perciben ganancias, pero al mes 3 renta a un 10%, no convendría vender al mes 1, si no mantener hasta el mes 3.

Otro punto útil por examinar es el desempeño del modelo bajo condiciones más cercanas al uso cotidiano, que le da una persona común. Esto incluye el empleo de prompts con menos información, sin roles definidos ni instrucciones estructuradas, para evaluar como la ingeniería de prompts puede afectar la calidad de los resultados, tanto de manera cualitativa, como de manera cuantitativa. Esto es especialmente relevante considerando que usuarios sin conocimientos financieros o tecnológicos podrían no formular consultas con precisión metodológica. Comprender esta brecha permitiría anticipar riesgos y diseñar recomendaciones para disminuir los riesgos.

Asimismo, comparar el comportamiento de ChatGPT con otros modelos de lenguaje permitiría distinguir si las limitaciones observadas son propias de los LLM en general o específicas de un modelo particular. Este análisis entre distintos modelos de lenguaje, puede ofrecer información importante de como varia la calidad de respuestas entre distintos modelos, ayudando a ver cómo podría mejorar los resultados dependiendo de la potencia de los modelos.

Otra proyección valiosa es estudiar como varían los resultados ante una repetibilidad del experimento. Dado que los LLM poseen un componente estocástico, ejecutar nuevamente el procedimiento completo con los mismos datos y prompts permitiría evaluar el nivel de variabilidad entre respuestas. Este análisis es fundamental para determinar si la tecnología puede ser considerada confiable un ambiente, en donde la estabilidad de resultados es crucial.

Finalmente, una extensión importante para este estudio, consiste en incorporar un análisis en tiempo real, que permita evaluar la capacidad predictiva del LLM sin recurrir al enmascaramiento de datos históricos. En este enfoque, en lugar de entregar al modelo información pasada cuidadosamente seleccionada y enmascarada, se podría solicitar directamente al LLM que formule una predicción sobre un activo financiero en la fecha actual, permitiéndole al modelo decidir qué datos utilizar como base para su análisis, eliminando restricciones. Luego, una vez transcurrido el horizonte temporal elegido, se evaluaría el valor real del activo y se compararía con la proyección generada. Este método permitiría validar el desempeño del LLM en condiciones reales, dinámicas y sin intervención “humana”, lo que otorgaría una medición más precisa del potencial predictivo de los LLM en escenarios auténticos.

En conjunto, todos estos análisis abren un amplio campo para investigaciones más profundas que pueden complementar este estudio. Explorar estas líneas extras permitiría evaluar

no solo la precisión cuantitativa de los LLM, sino también su estabilidad, sus sesgos, la influencia del diseño del prompt y su desempeño real en entornos financieros. Estos análisis contribuyen de gran manera en comprender si los modelos de lenguaje en algún punto tendrán autonomía total en lo toma de decisiones, ya sea en finanzas o en otros campos de estudios.

11 Referencias

- A. M., & Raahemi, B. (2023). *News-based intelligent prediction of financial markets using text mining and machine learning: A systematic literature review*. Expert Systems with Applications.
- Ahmadova, A., Guliyev, T., & Aliyev, K. (5 de Junio de 2024). *The Relationship between Bitcoin and Nasdaq, U.S. Dollar Index and Commodities*. Recuperado el 13 de Octubre de 2025, de SSRN / International Journal of Energy Economics and Policy: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4812798
- Alonso, R. (17 de Septiembre de 2024). *Hardzone*. Obtenido de <https://hardzone.es/tutoriales/rendimiento/diferencias-ia-deep-machine-learning/>
- AppsRunTheWorld. (s.f.). *List of Microsoft 365 Copilot Customers*. Recuperado el 11 de Septiembre de 2025, de AppsRunTheWorld: <https://www.appsruntheworld.com/customers-database/products/view/microsoft-365-copilot>
- Aravena, N. (5 de Febrero de 2023). *UC*. Obtenido de Núcleo Milenio FAIR en Ciencias Sociales: <https://www.uc.cl/noticias/header-que-impactos-socioculturales-tienen-los-usos-de-la-inteligencia-artificial/>
- AWS. (s.f.). *Amazon*. Recuperado el 16 de Noviembre de 2024, de [https://aws.amazon.com/es/q/?trk=32312894-8d5e-4446-8b62-81bdec3cb880&sc_channel=ps&ef_id=Cj0KCQiAouG5BhDBARIsAOc08RTbKOzsfkB5bQDYgpfC-DIU7HkJ8MYTw3YPJAr5Y4zzj3ZVM_hlPeEaAqouEALw_wcB:G:s&s_kwid=AL!4422!3!706690556814!p!!g!!"asistente%20de%20inteligencia%](https://aws.amazon.com/es/q/?trk=32312894-8d5e-4446-8b62-81bdec3cb880&sc_channel=ps&ef_id=Cj0KCQiAouG5BhDBARIsAOc08RTbKOzsfkB5bQDYgpfC-DIU7HkJ8MYTw3YPJAr5Y4zzj3ZVM_hlPeEaAqouEALw_wcB:G:s&s_kwid=AL!4422!3!706690556814!p!!g!!)
- Babiloni, J. (31 de Enero de 2024). *29 ejemplos de cómo ChatGPT nos puede ayudar en nuestra rutina diaria desde el móvil*. Obtenido de Xataka Android: <https://www.xatakandroid.com/listas/29-ejemplos-como-chatgpt-nos-puede-ayudar-nuestra-rutina-diaria-movil>
- Banco Mundial. ((s.f.) de 2024). *Inflación, precios al consumidor (% anual) - United States*. Recuperado el 5 de Octubre de 2025, de Datos del Banco Mundial: <https://datos.bancomundial.org/indicador/FP.CPI.TOTL.ZG?end=2024&locations=US&start=2024&view=bar>
- Bank for International Settlements. (30 de Septiembre de 2025). *OTC foreign exchange turnover in April 2025; Triennial Central Bank Survey*. Obtenido de Bank for International Settlements: https://www.bis.org/statistics/rpfx25_fx.htm
- Bargigli, L. (26 de Agosto de 2025). *How Large is Excess Volatility of the Eur/Usd Exchange Rate? Evidence from a Gas Approach*. doi:<https://dx.doi.org/10.2139/ssrn.5405508>
- Base de Datos Estadísticos (BDE). ((s.f.)). *Canasta*. Recuperado el 6 de Noviembre de 2025, de Base de Datos Estadísticos (BDE):

- https://si3.bcentral.cl/siete/ES/Siete/Canasta?cbFechaInicio=2021&cbFechaTermino=2022&cbFrecuencia=MONTHLY&cbCalculo=SIN_SELECCION&cbFechaBase=
- Base de Datos Estadísticos (BDE). ((s.f.)). *Precio del petróleo Brent (dólares/barril)(valores referenciales, obtenidas de fuentes internacionales para apoyo al análisis económico)*. Recuperado el 13 de Octubre de 2025, de Base de Datos Estadísticos (BDE): https://si3.bcentral.cl/siete/ES/Siete/Canasta?cbFechaInicio=2014&cbFechaTermino=2020&cbFrecuencia=QUARTERLY&cbCalculo=SIN_SELECCION&cbFechaBase=
- Bi, S., Xiao, J., & Deng, T. (2 de Abril de 2025). The Role of AI in Financial Forecasting: ChatGPT's Potential and Challenges. *AIBDF '24: Proceedings of the 4th Asia-Pacific Artificial Intelligence and Big Data Forum*, 1064 - 1070.
doi:<https://dl.acm.org/doi/10.1145/3718491.3718663>
- BlackRock. ((s.f.)). *iShares NASDAQ 100 UCITS ETF*. Recuperado el 5 de Octubre de 2025, de BlackRock: <https://www.blackrock.com/es/profesionales/productos/253741/ishares-nasdaq-100-ucits-etf>
- Brockman, G. (12 de Enero de 2025). *o1 is a different kind of model. great performance requires using it in a new way relative to standard chat models*. Recuperado el 21 de Septiembre de 2025, de X: <https://x.com/gdb/status/1878489681702310392>
- ChatGPT. (20 de Agosto de 2025). *Respuesta generada por ChatGPT sobre eventos históricos relevantes en la evolución de activos financieros*. Obtenido de OpenAI: <https://chat.openai.com/>
- ChatGPT. (14 de Agosto de 2025). *Respuesta generada sobre datos históricos del fondo SPDR S&P 500 ETF (SPY)*. Obtenido de OpenAI: <https://chat.openai.com/>
- CMF Chile. (s.f.). *CMF Chile*. Recuperado el 13 de Septiembre de 2025, de CMF Educa: <https://www.cmfchile.cl/educa/621/w3-article-511.html>
- Congresional Budget Office (CBO). ((s.f.) de 2025). *Budget and Economic Data*. Recuperado el 30 de Agosto de 2025, de Congressional Budget Office (CBO): <https://www.cbo.gov/data/budget-economic-data>
- Corinna Ghirelli, A. A.-G. (29 de Julio de 2024). *Banco de España*. Obtenido de BDE: <https://www.bde.es/wbe/es/noticias-eventos/blog/midiendo-la-incertidumbre-economica-el-papel-de-la-inteligencia-artificial.html>
- Duarte, F. (18 de Agosto de 2025). *Número de usuarios de ChatGPT (julio de 2025)*. Obtenido de Exploding Topics: <https://explodingtopics.com/blog/chatgpt-users>
- Ekundayo, O. S., & Ezugwu, A. E. (Septiembre de 2025). Deep learning: Historical overview from inception to actualization, models, applications and future trends. *Applied Soft Computing*. doi:<https://doi.org/10.1016/j.asoc.2025.113378>
- Estrategias de Inversión. (3 de Octubre de 2025). *Razones de Goldman Sachs por las que el oro rompe a diario máximos históricos*. Obtenido de Yahoo Finanzas:

<https://es.finance.yahoo.com/noticias/razones-goldman-sachs-oro-rompe-045000267.html>

Fernandez, R. (12 de Julio de 2024). *Staista*. Obtenido de <https://es.statista.com/temas/6692/inteligencia-artificial-ia/#topicOverview>

Fernández, R. (22 de Mayo de 2024). *Statista*. Obtenido de <https://es.statista.com/estadisticas/996151/inteligencia-artificial-empresas-con-mayor-numero-de-patentes-en-el-mundo/>

Fernández, Y. (9 de Julio de 2025). *Qué es un prompt y por qué son tan importantes para usar la Inteligencia Artificial*. Obtenido de Xataka: <https://www.xataka.com/basics/que-prompt-que-importantes-para-usar-inteligencia-artificial>

FRED. (7 de Octubre de 2025). *ECB Marginal Lending Facility Rate for Euro Area (ECBMLFR)*. Recuperado el 7 de Octubre de 2025, de FRED: <https://fred.stlouisfed.org/series/ECBMLFR>

FRED. (1 de Octubre de 2025). *Federal Funds Effective Rate (FEDFUNDS)*. Recuperado el 5 de Octubre de 2025, de FRED: <https://fred.stlouisfed.org/series/FEDFUNDS>

González, C. (18 de Junio de 2025). *Yahoo Finance*. Recuperado el 23 de Septiembre de 2025, de Inteligencia artificial aplicada al análisis financiero: https://es.finance.yahoo.com/noticias/inteligencia-artificial-aplicada-an%C3%A1lisis-financiero-150244284.html?guccounter=1&guce_referrer=aHR0cHM6Ly93d3cuZ29vZ2xLmNvbS8&guce_referrer_sig=AQAAAGMx8StwvlnwBCL4wVXXwAQE0wAHmqtYSrgBHwHszNtZaAhUbfP3UgjjeESVsmX

Google Cloud. (s.f.). *Google Cloud*. Recuperado el 14 de Noviembre de 2024, de <https://cloud.google.com/discover/finance-ai?hl=es-419#how-is-ai-used-in-finance>

Google Cloud. (s.f.). *What is prompt engineering?* Recuperado el 21 de Septiembre de 2025, de Google: <https://cloud.google.com/discover/what-is-prompt-engineering?hl=es-419>

Hill, K. (27 de Agosto de 2025). *Un adolescente tenía tendencias suicidas. ChatGPT fue el amigo en quien confió*. Obtenido de The New York Times: <https://www.nytimes.com/es/2025/08/27/espanol/negocios/ia-chatgpt-suicidio.html>

IBM. ((s.f.)). *IBM*. Recuperado el 11 de Noviembre de 2024, de <https://www.ibm.com/mx-es/topics/artificial-intelligence-medicine>

IBM. (2 de Noviembre de 2023). *¿Qué son los grandes modelos de lenguaje (LLM)?* Obtenido de IBM Think: <https://www.ibm.com/es-es/think/topics/large-language-models>

INESDI. (6 de Septiembre de 2023). *INESDI*. Obtenido de <https://www.inesdi.com/blog/Inteligencia-artificial-en-educacion/>

Investing. ((s.f.)). *Bitcoin*. Recuperado el 7 de Octubre de 2025, de Investing: <https://es.investing.com/crypto/bitcoin/historical-data>

- Investing. ((s.f.)). *Datos históricos del Bitcoin*. Recuperado el 6 de Noviembre de 2025, de Investing: <https://es.investing.com/crypto/bitcoin/historical-data>
- Investing. ((s.f.)). *Datos históricos XAU/USD*. Recuperado el 6 de Noviembre de 2025, de Investing: <https://es.investing.com/currencies/xau-usd-historical-data>
- Investing. ((s.f.)). *US Dollar Index (DXY)*. Recuperado el 7 de Octubre de 2025, de Investing: <https://www.investing.com/indices/usdollar-historical-data>
- Investing. ((s.f.)). *XAU/USD - Oro al contado Dólar*. Recuperado el 13 de Octubre de 2025, de Investing.com: <https://es.investing.com/currencies/xau-usd-historical-data>
- Julliet. (25 de Abril de 2024). <https://www.julliet.ai>. Obtenido de <https://www.julliet.ai/blog/que-tan-confiable-es-la-informacion-obtenida-a-traves-de-la-inteligencia-artificial-cldezy06n799911jkdwbr6ib4p#:~:text=Por%20un%20lado%2C%20la%20IA,el%20sesgo%20de%20los%20datos>
- Junco, M., & Julieth, M. (2013). Business intelligence y la toma de decisiones financieras: una aproximación teórica. *Redalyc*, 3.
- Liu, Y., & Wang, J. (5 de Mayo de 2024). *Analysis of Financial Market using Generative Artificial Intelligence*. doi:<http://dx.doi.org/10.54097/y17mrj84>
- Matin N. Ashtiani, B. R. (2023). *News-based intelligent prediction of financial markets using text mining and machine learning: A systematic literature review*. ELSEVIER.
- Mucci, T. (21 de Octubre de 2024). *IBM*. Obtenido de The history of AI: <https://www.ibm.com/think/topics/history-of-artificial-intelligence>
- OpenAI. ((s.f.)). *ChatGPT*. Recuperado el 13 de Octubre de 2025, de OpenAI: <https://chat.openai.com/>
- OpenAI. ((s.f.)). *Eventos históricos con impactos en el fondo EUR/USD según el LLM [Generado con ChatGPT (versión GPT-5)]*. Recuperado el 1 de Septiembre de 2025, de OpenAI: <https://chat.openai.com/>
- OpenAI. (s.f.). *Pricing*. Recuperado el 07 de Septiembre de 2025, de ChatGPT: <https://chatgpt.com/es-ES/pricing>
- OurWorldInData. (16 de Mayo de 2024). *PIB mundial a largo plazo*. Recuperado el 13 de Octubre de 2025, de OurWorldInData: <https://ourworldindata.org/grapher/global-gdp-over-the-long-run>
- Padilla, R. D. (2019). *La llegada de la inteligencia artificial a la educación*. Universidad Tecnológica de Pereira. doi:<https://doi.org/10.36825/RITI.07.14.022>
- Parlamento Europeo. (26 de Marzo de 2021). *Parlamneto Europeo*. Obtenido de <https://www.europarl.europa.eu/topics/es/article/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa>
- Pastor, F. G. (19 de Febrero de 2022). *LinkedIn*. Obtenido de <https://www.linkedin.com/pulse/es-fiabile-la-inteligencia-artificial-fabian-garcia-pastor/>

- Peter, S. (5 de Septiembre de 2024). Obtenido de International Science Council:
<https://es.council.science/blog/ai-was-born-at-a-us-summer-camp-68-years-ago-heres-why-that-event-still-matters-today/>
- Picazo-Sanchez, P. O.-M. (2024). Analysing the impact of ChatGPT in research. *Springer Nature*.
 doi:<https://doi.org/10.1007/s10489-024-05298-0>
- Prieto, M. V. (Junio de 2022). <https://repositorio.comillas.edu>. Madrid: ICADE BUSINESS SCHOOL.
 Obtenido de <http://hdl.handle.net/11531/67831>
- Quiroga, E. (1 de Abril de 2017). EFICIENCIA EN LOS MERCADOS FINANCIEROS Y PREDICCIÓN DE PRECIOS DE LOS ACTIVOS. *Ciencias Administrativas*, 47-53. Obtenido de
<https://www.redalyc.org/journal/5116/511653854005/html/>
- Rhinehart, C. (25 de Noviembre de 2024). *Nasdaq Composite vs. S&P 500 vs. Dow: What's the Difference?* Obtenido de Investopedia: <https://www.investopedia.com/nasdaq-vs-sp500-vs-dow-5213252>
- Sacie, M. (5 de Noviembre de 2024). 'Deep learning' y 'machine learning': en qué se diferencian los dos grandes cerebros de la era digital. Obtenido de BBVA:
<https://www.bbva.com/es/innovacion/deep-learning-y-machine-learning-en-que-se-diferencian-los-dos-grandes-cerebros-de-la-era-digital/>
- Santander. (22 de Mayo de 2023). <https://www.santander.com>. Obtenido de
<https://www.santander.com/es/stories/consejos-invertir-bolsa>
- SAP. (s.f.). ¿Qué es business intelligence (BI)? Recuperado el 8 de Septiembre de 2025, de SAP:
<https://www.sap.com/spain/products/data-cloud/cloud-analytics/what-is-business-intelligence.html>
- Services, A. W. (s.f.). *What is LLM (Large Language Model)?* Obtenido de Amazon Web Services (AWS): <https://aws.amazon.com/es/what-is/large-language-model/>
- Tang, H., Jin, M., Zang, C., & Yu, Q. (s.f. de Febrero de 2024). *ResearchGate*. Obtenido de ResearchGate:
https://www.researchgate.net/publication/378372713_Time_Series_Forecasting_with_LLMs_Understanding_and_Enhancing_Model_Capabilities
- TechJury. (2 de Enero de 2024). *Business Intelligence Statistics: Usage, Market, and Future Trends*. Obtenido de TechJury: https://techjury.net/industry-analysis/business-intelligence-statistics/?utm_source=chatgpt.com
- Tironi, M. (5 de Febrero de 2023). ¿Qué impactos socioculturales tienen los usos de la inteligencia artificial? . Obtenido de UC: <https://www.uc.cl/noticias/header-que-impactos-socioculturales-tienen-los-usos-de-la-inteligencia-artificial/>
- Unesco. (4 de Agosto de 2025). *Reflexiones sobre el uso Ético de la Inteligencia Artificial*. Obtenido de Unesco: <https://www.unesco.org/es/articles/reflexiones-sobre-el-uso-etico-de-la-inteligencia-artificial>

- Uribe, J., & Fernández, J. (1 de Abril de 2014). Burbujas financieras y comportamiento reciente de los mercados de acciones en América Latina. *Lecturas de Economía*. Obtenido de http://www.scielo.org.co/scielo.php?pid=S0120-25962014000200003&script=sci_arttext
- Valora Analitik. (7 de Octubre de 2024). *¿Qué es el S&P 500 y por qué es tan importante para el mercado?* Recuperado el 3 de Octubre de 2025, de Yahoo Finanzas: <https://es-us.finanzas.yahoo.com/noticias/s-p-500-importante-mercado-182000605.html>
- Viáfara, J. M., Gómez, A. O., & Mejía, E. L. (23 de Octubre de 2023). Macroeconomía y mercado bursátil el impacto y la transmisión de volatilidad de las variables macroeconómicas al mercado bursátil colombiano. *Revista Facultad de Ciencias Económicas*. doi:<https://doi.org/10.18359/rfce.6413>
- Wikipedia. (28 de Septiembre de 2025). *Nasdaq Composite*. Recuperado el 5 de Octubre de 2025, de Wikipedia: https://en.wikipedia.org/wiki/Nasdaq_Composite
- Yahoo Finance. ((s.f.)). *^VIX (^VIX)*. Recuperado el 5 de Octubre de 2025, de Yahoo Finance: <https://finance.yahoo.com/quote/%5EVIX/history/?period1=1356998400&period2=1609372800&frequency=1mo>
- Yahoo Finance. ((s.f.)). *Datos Históricos EUR/USD (EURUSD=X)*. Recuperado el 6 de Noviembre de 2025, de Yahoo Finance: <https://es.finance.yahoo.com/quote/EURUSD%3DX/history/?period1=1609459200&period2=1638403200&frequency=1mo>
- Yahoo Finance. ((s.f.)). *Datos históricos NASDAQ Composite (^IXIC)*. Recuperado el 6 de Noviembre de 2025, de Yahoo Finance: <https://es.finance.yahoo.com/quote/%5EIXIC/history/?guccounter=1&period1=1609459200&period2=1638403200&frequency=1mo>
- Yahoo Finance. ((s.f.)). *Datos Históricos SPDR S&P 500 ETF (SPY)*. Recuperado el 6 de Noviembre de 2025, de Yahoo Finance: <https://es.finance.yahoo.com/quote/SPY/history/?period1=1609459200&period2=1638403200&frequency=1mo>
- Yahoo Finance. ((s.f.)). *EUR/USD (EURUSD=X)*. Recuperado el 1 de Septiembre de 2025, de Yahoo Finance: <https://es.finance.yahoo.com/quote/EURUSD%3DX/>
- Yahoo Finance. (3 de Octubre de 2025). *NASDAQ Composite (^IXIC)*. Recuperado el 5 de Octubre de 2025, de Yahoo Finance: <https://es.finance.yahoo.com/quote/%5EIXIC/history/>
- Yahoo Finance. (4 de Septiembre de 2025). *SPDR S&P 500 ETF (SPY)*. Obtenido de Yahoo Finance: <https://es.finance.yahoo.com/quote/SPY/performance/>
- Zavadzka, M., Morales, L., & Coughlan, J. ((s.f.) de Enero de 2020). *Brent crude oil prices volatility during major crises*. doi:<https://doi.org/10.1016/j.frl.2018.12.026>

12 Anexo

Tabla 38

Resultados del Proceso de Ocultación de Datos de la Tabla 1

Origen del Índice	Estados Unidos
Nombre del Índice	Andes Global Equity Fund
Perfil de Riesgo	Alto
Tipo de Fondo	Índice de Renta Variable (Indexado)
Moneda Base	USD

Tabla 39

Resultados del Proceso de Ocultación de Datos de la Tabla 2

Año	Rentabilidad total (%)	Índice de Referencia (%)
(año base - 5)	5,73	9,3
(año base - 4)	7,5	6,8
(año base - 3)	28,24	32,5
(año base - 2)	-3,88	-0,3
(año base - 1)	35,23	39
(año base)	43,64	48,5

Tabla 40*Resultados del Proceso de Ocultación de Datos de la Tabla 3*

Fecha	Cierre Ajustado	Fecha	Cierre Ajustado	Fecha	Cierre Ajustado
01-12-(año base)	12888,28	01-05-(año base - 2)	7442,12	01-08-(año base - 5)	4776,51
01-11-(año base)	12198,74	01-04-(año base - 2)	7066,27	01-07-(año base - 5)	5128,28
01-10-(año base)	10911,59	01-03-(año base - 2)	7063,01	01-06-(año base - 5)	4986,87
01-09-(año base)	11167,51	01-02-(año base - 2)	7273,01	01-05-(año base - 5)	5070,03
01-08-(año base)	11775,46	01-01-(año base - 2)	7411,48	01-04-(año base - 5)	4941,42
01-07-(año base)	10745,27	01-12-(año base - 3)	6903,39	01-03-(año base - 5)	4900,88
01-06-(año base)	10058,77	01-11-(año base - 3)	6873,97	01-02-(año base - 5)	4963,53
01-05-(año base)	9489,87	01-10-(año base - 3)	6727,67	01-01-(año base - 5)	4635,24
01-04-(año base)	8889,55	01-09-(año base - 3)	6495,96	01-12-(año base - 6)	4736,05
01-03-(año base)	7700,1	01-08-(año base - 3)	6428,66	01-11-(año base - 6)	4791,63
01-02-(año base)	8567,37	01-07-(año base - 3)	6348,12	01-10-(año base - 6)	4630,74
01-01-(año base)	9150,94	01-06-(año base - 3)	6140,42	01-09-(año base - 6)	4493,39
01-12-(año base - 1)	8972,6	01-05-(año base - 3)	6198,52	01-08-(año base - 6)	4580,27
01-11-(año base - 1)	8665,47	01-04-(año base - 3)	6047,61	01-07-(año base - 6)	4369,77
01-10-(año base - 1)	8292,36	01-03-(año base - 3)	5911,74	01-06-(año base - 6)	4408,18
01-09-(año base - 1)	7999,34	01-02-(año base - 3)	5825,44	01-05-(año base - 6)	4242,62
01-08-(año base - 1)	7962,88	01-01-(año base - 3)	5614,79	01-04-(año base - 6)	4114,56
01-07-(año base - 1)	8175,42	01-12-(año base - 4)	5383,12	01-03-(año base - 6)	4198,99
01-06-(año base - 1)	8006,24	01-11-(año base - 4)	5323,68	01-02-(año base - 6)	4308,12
01-05-(año base - 1)	7453,15	01-10-(año base - 4)	5189,14	01-01-(año base - 6)	4103,88
01-04-(año base - 1)	8095,39	01-09-(año base - 4)	5312	01-12-(año base - 7)	4176,59
01-03-(año base - 1)	7729,32	01-08-(año base - 4)	5213,22	01-11-(año base - 7)	4059,89
01-02-(año base - 1)	7532,53	01-07-(año base - 4)	5162,13	01-10-(año base - 7)	3919,71
01-01-(año base - 1)	7281,74	01-06-(año base - 4)	4842,67	01-09-(año base - 7)	3771,48
01-12-(año base - 2)	6635,28	01-05-(año base - 4)	4948,05	01-08-(año base - 7)	3589,87
01-11-(año base - 2)	7330,54	01-04-(año base - 4)	4869,36	01-07-(año base - 7)	3626,37
01-10-(año base - 2)	7305,9	01-03-(año base - 4)	4775,36	01-06-(año base - 7)	3403,25
01-09-(año base - 2)	8046,35	01-02-(año base - 4)	4557,95	01-05-(año base - 7)	3455,91

01-08-(año base - 2)	8109,54	01-01-(año base - 4)	4613,95	01-04-(año base - 7)	3328,79
01-07-(año base - 2)	7671,79	01-12-(año base - 5)	5007,41	01-03-(año base - 7)	3267,52
01-06-(año base - 2)	7510,3	01-11-(año base - 5)	5108,67	01-02-(año base - 7)	3160,19
		01-10-(año base - 5)	5053,75		
		01-09-(año base - 5)	4620,16		

Tabla 41

Resultados del Proceso de Ocultación de Datos de la Tabla 4

Año	Evento	Descripción	Impacto en el Fondo
(año base - 7)	Caída de recurso energético	Pasa de >100 USD a <50 USD/la unidad	Energía cae, consumo se fortalece
(año base - 6)	Tensión Europa del Este	Inestabilidad geopolítica	Leve impacto
(año base - 5)	Crisis en China	Bolsa china colapsa, devaluación del yuan	Fondo cae 10%
(año base - 5)	Caída en commodities	Petróleo, cobre, etc. en mínimos	Presión a sectores industriales
(año base - 5)	Subida de tasas por la Fed	Primera alza en casi 10 años (diciembre)	Cambio de ciclo monetario
(año base - 4)	Brexit	Reino Unido vota salir de la UE	Caída de 5% en Fondo en 2 días, luego rebote
(año base - 4)	Elección presidencial EEUU	Sorpresa electoral → impulso a sectores cíclicos	Fondo sube fuerte desde noviembre
(año base - 3)	Reforma tributaria	Rebaja de impuestos corporativos al 21%	Fondo sube con fuerza todo el año

(año base - 3)	Baja volatilidad histórica	Prácticamente sin correcciones >5%	Subida tranquila y estable
(año base - 2)	Guerra comercial entre 2 potencias	Aranceles y tensiones bilaterales	Caídas intermitentes
(año base - 2)	Subidas agresivas de tasas por la Fed	4 alzas de tasas en el año	Fondo cae ~20% en Q4
(año base - 2)	Volatilidad repunta	VIX alcanza máximos de 2 años	Inversores defensivos
(año base - 1)	Tregua comercial parcial	Potencias comerciales firman acuerdo	Confianza se recupera
(año base - 1)	Bajas de tasas por la Fed	3 recortes de tasas en el año	Impulso adicional al Fondo
(año base - 1)	Inversión de curva de rendimientos	Riesgo de recesión percibida	Alerta en mercados
(año base)	Crisis sanitaria Global	Cierre global de economías en marzo	Fondo cae ~34% en 1 mes
(año base)	Intervención sin precedentes Fed y Congreso	Estímulo monetario y fiscal masivo	Fondo se recupera y marca máximos en agosto
(año base)	Elecciones presidenciales	Partido demócrata gana, expectativas de más gasto fiscal	Positiva para sectores “verdes”

Tabla 42*Resultados del Proceso de Ocultación de Datos de la Tabla 5*

date_fmt	PIB nominal	PIB real	Índice de precios	date_fmt	PIB nominal	PIB real	Índice de precios
(año base - 7)-01	16569,6	16383	100,982	(año base - 1)-07	21542,5	19121,1	109,928
(año base - 7)-04	16637,9	16403,2	101,057	(año base - 1)-10	21729,1	19222	110,301
(año base - 7)-07	16848,7	16531,7	101,466	(año base)-01	21539,7	18977,4	110,661
(año base - 7)-10	17083,1	16663,6	101,88	(año base)-04	19245,81	17062,72	110,1118
(año base - 6)-01	17104,6	16616,5	102,357	(año base)-07	20082,37	17744,89	110,5537
(año base - 6)-04	17432,9	16841,5	102,846	(año base)-10	20488,53	18087,13	110,7384
(año base - 6)-07	17721,7	17047,1	103,123	(año base + 1)-01	20828,27	18352,14	110,9793
(año base - 6)-10	17849,9	17143	102,992	(año base + 1)-04	21159,47	18582,49	111,3599
(año base - 5)-01	17984,2	17277,6	102,542	(año base + 1)-07	21513,47	18822,71	111,7851
(año base - 5)-04	18219,4	17405,7	103,048	(año base + 1)-10	21750,64	18959,97	112,1681
(año base - 5)-07	18344,7	17463,2	103,339	(año base + 2)-01	21967,63	19069,86	112,61
(año base - 5)-10	18350,8	17468,9	103,253	(año base + 2)-04	22182,42	19169,12	113,1043
(año base - 4)-01	18424,3	17556,8	103,297	(año base + 2)-07	22406,99	19272,03	113,6176
(año base - 4)-04	18637,3	17639,4	103,91	(año base + 2)-10	22634,91	19377,15	114,1142
(año base - 4)-07	18806,7	17735,1	104,344	(año base + 3)-01	22863,99	19482,57	114,6137
(año base - 4)-10	18991,9	17824,2	104,812	(año base + 3)-04	23083,63	19574,97	115,137
(año base - 3)-01	19190,4	17925,3	105,355	(año base + 3)-07	23318,92	19677,69	115,6672
(año base - 3)-04	19356,6	18021	105,596	(año base + 3)-10	23567,58	19790,17	116,1967
(año base - 3)-07	19611,7	18163,6	106,033	(año base + 4)-01	23828,95	19908,3	116,7516
(año base - 3)-10	19918,9	18322,5	106,733	(año base + 4)-04	24085,79	20019,89	117,316
(año base - 2)-01	20163,2	18438,3	107,401	(año base + 4)-07	24340,44	20128,7	117,8821

(año base - 2)-04	20510,2	18598,1	107,988	(año base + 4)- 10	24599,65	20239,54	118,4537
(año base - 2)-07	20749,8	18732,7	108,413	(año base + 5)- 01	24871,54	20360,01	119,0217
(año base - 2)-10	20897,8	18783,5	108,772	(año base + 5)- 04	25146,49	20480,2	119,5996
(año base - 1)-01	21098,8	18927,3	108,879	(año base + 5)- 07	25424,23	20600,73	120,1821
(año base - 1)-04	21340,3	19021,9	109,522	(año base + 5)- 10	25704,31	20721,63	120,7663

Tabla 43

Resultados del Proceso de Ocultación de Datos de la Tabla 6

Origen del Fondo	Estados Unidos
Nombre del Fondo	Oceanis Global Tech
Perfil de Riesgo	Medio - Alto
Tipo de Fondo	ETF Renta Variable (Indexado)
Moneda Base	USD

Tabla 44

Resultados del Proceso de Ocultación de Datos de la Tabla 7

Rentabilidad Anual		
Año	Fondo	Categoría
(año base)	18,37%	15,83%
(año base - 1)	31,22%	28,78%
(año base - 2)	-4,56%	-6,27%
(año base - 3)	21,70%	20,44%
(año base - 4)	12,00%	10,37%
(año base - 5)	1,25%	-1,07%
(año base - 6)	13,46%	10,96%
(año base - 7)	32,31%	31,50%
(año base - 8)	15,99%	14,96%
(año base - 9)	1,89%	-1,27%
(año base - 10)	15,06%	14,01%

Tabla 45*Resultados del Proceso de Ocultación de Datos de la Tabla 8*

Fecha	Cierre ajustado	RSI 14	IPC Todos los ítemes	Fecha	Cierre ajustado	RSI 14	IPC Todos los ítemes
01-12- (año base)	349,52	68,736351	260,47	01-12- (año base - 5)	172,75	58,889663	236,53
01-11- (año base)	338,47	66,814101	260,23	01-11- (año base - 5)	176,83	62,746323	237,34
01-10- (año base)	305,26	59,940244	260,39	01-10- (año base - 5)	176,19	62,387534	237,84
01-09- (año base)	311,82	62,307456	260,28	01-09- (año base - 5)	161,54	52,705862	237,95
01-08- (año base)	325,25	67,365011	259,92	01-08- (año base - 5)	166,63	57,479231	238,32
01-07- (año base)	304,03	62,95298	259,1	01-07- (año base - 5)	177,45	69,991503	238,65
01-06- (año base)	285,86	58,491063	257,8	01-06- (año base - 5)	172,69	67,062566	238,64
01-05- (año base)	282,12	57,513024	256,39	01-05- (año base - 5)	177,12	73,240281	237,81
01-04- (año base)	269,29	54,065359	256,39	01-04- (año base - 5)	174,88	72,030543	236,6
01-03- (año base)	237,55	43,540927	258,12	01-03- (año base - 5)	172,4	70,667275	236,12

01-02- (año base)	273,04	57,131934	258,68	01-02- (año base - 5)	175,94	75,548032	234,72
01-01- (año base)	296,51	70,67983	257,97	01-01- (año base - 5)	166,57	70,54852	233,71
01-12- (año base - 1)	295,18	70,309348	256,97	01-12- (año base - 6)	170,72	77,025493	234,81
01-11- (año base - 1)	288,26	68,378954	257,21	01-11- (año base - 6)	172,1	79,272759	236,15
01-10- (año base - 1)	278,19	65,333323	257,35	01-10- (año base - 6)	167,49	77,210246	237,43
01-09- (año base - 1)	270,92	62,94044	256,76	01-09- (año base - 6)	162,88	74,890098	238,03
01-08- (año base - 1)	266,98	61,606794	256,56	01-08- (año base - 6)	165,93	79,886577	237,85
01-07- (año base - 1)	271,52	64,073952	256,57	01-07- (año base - 6)	159,63	76,935039	238,25
01-06- (año base - 1)	266,18	62,430708	256,14	01-06- (año base - 6)	161,03	79,337428	238,34
01-05- (año base - 1)	250,08	56,913289	256,09	01-05- (año base - 6)	158,53	78,209137	237,9
01-04- (año base - 1)	267,11	66,506684	255,55	01-04- (año base - 6)	154,94	76,497889	237,07
01-03- (año base - 1)	255,5	62,505803	254,2	01-03- (año base - 6)	153,19	75,631679	236,29

01-02- (año base - 1)	252,06	61,231666	252,78	01-02- (año base - 6)	152,6	75,347225	234,78
01-01- (año base - 1)	244,15	58,198642	251,71	01-01- (año base - 6)	145,96	71,922052	233,92
01-12- (año base - 2)	224,74	49,130445	251,23	01-12- (año base - 7)	150,47	78,829703	233,05
01-11- (año base - 2)	247,88	64,658137	252,04	01-11- (año base - 7)	147,47	77,494599	233,07
01-10- (año base - 2)	243,36	62,50895	252,89	01-10- (año base - 7)	143,22	75,458637	233,55
01-09- (año base - 2)	260,25	79,225969	252,44	01-09- (año base - 7)	136,22	71,517878	234,15
01-08- (año base - 2)	259,88	79,112339	252,15	01-08- (año base - 7)	132,68	69,19502	233,88
01-07- (año base - 2)	251,84	76,521013	252,01	01-07- (año base - 7)	136,79	75,865355	233,6
01-06- (año base - 2)	241,76	72,557548	251,99	01-06- (año base - 7)	129,38	71,220811	233,5
01-05- (año base - 2)	241,46	72,428923	251,59	01-05- (año base - 7)	131,83	75,69301	232,95
01-04- (año base - 2)	235,73	69,929173	250,55	01-04- (año base - 7)	128,78	73,790524	232,53
01-03- (año base - 2)	233,58	68,948267	249,55	01-03- (año base - 7)	125,8	71,787114	232,77

01-02- (año base - 2)	241,13	77,155	248,99	01-02- (año base - 7)	121,73	68,758557	232,17
01-01- (año base - 2)	250,22	88,997929	247,87	01-01- (año base - 7)	120,2	67,54232	230,28
01-12- (año base - 3)	235,67	85,745949	246,52	01-12- (año base - 8)	113,54	61,481115	229,6
01-11- (año base - 3)	234,03	85,290903	246,67	01-11- (año base - 8)	113,33	61,269349	230,22
01-10- (año base - 3)	227,09	83,181079	246,66	01-10- (año base - 8)	112,7	60,66696	231,32
01-09- (año base - 3)	220,77	80,859482	246,82	01-09- (año base - 8)	114,18	62,797558	231,41
01-08- (año base - 3)	217,48	79,491039	245,52	01-08- (año base - 8)	111,95	60,875081	230,38
01-07- (año base - 3)	216,85	79,226961	244,79	01-07- (año base - 8)	109,21	58,423786	229,1
01-06- (año base - 3)	211,45	76,854955	244,96	01-06- (año base - 8)	107,38	56,742991	229,48
01-05- (año base - 3)	211,14	76,71321	244,73	01-05- (año base - 8)	103,73	53,242074	229,82
01-04- (año base - 3)	208,2	75,385696	244,52	01-04- (año base - 8)	110,35	61,644399	230,09
01-03- (año base - 3)	205,26	74,009905	243,8	01-03- (año base - 8)	110,61	62,00124	229,39

01-02- (año base - 3)	205,9	74,855646	243,6	01-02- (año base - 8)	107,63		227,66
01-01- (año base - 3)	198,11	71,126396	242,84	01-01- (año base - 8)	103,16		226,67
01-12- (año base - 4)	193,49	68,558328	241,43	01-12- (año base - 9)	97,96		225,67
01-11- (año base - 4)	190,76	66,945171	241,35	01-11- (año base - 9)	97,56		226,23
01-10- (año base - 4)	183,98	62,509326	241,73	01-10- (año base - 9)	97,96		226,42
01-09- (año base - 4)	186,29	65,280892	241,43	01-09- (año base - 9)	87,87		226,89
01-08- (año base - 4)	187,22	66,381193	240,85	01-08- (año base - 9)	94,91		226,55
01-07- (año base - 4)	186,99	66,25056	240,63	01-07- (año base - 9)	100,43		225,92
01-06- (año base - 4)	179,48	61,743389	241,02	01-06- (año base - 9)	101,98		225,72
01-05- (año base - 4)	179,79	62,061072	240,23	01-05- (año base - 9)	104,24		225,96
01-04- (año base - 4)	176,78	60,215472	239,26	01-04- (año base - 9)	105,42		224,91
01-03- (año base - 4)	175,19	59,242946	238,13	01-03- (año base - 9)	102,01		223,47

01-02- (año base - 4)	164,99	52,296629	237,11	01-02- (año base - 9)	102,44		221,31
01-01- (año base - 4)	165,13	52,410474	236,92	01-01- (año base - 9)	99		220,22

Tabla 46*Resultados del Proceso de Ocultación de Datos de la Tabla 9*

Año	Evento	Descripción	Impacto en el Fondo
(año base - 10)	Inyección de liquidez (QE2)	La Fed lanza un nuevo programa de estímulo monetario	Impulso al mercado
	Crisis en Europa	Grecia, Irlanda y Portugal en crisis de deuda	Volatilidad externa
(año base - 9)	Crisis de deuda europea	España e Italia bajo presión, rescate a Grecia	Alta volatilidad global
	“Fiscal cliff”	Riesgo de aumentos masivos de impuestos y recortes de gasto en EE.UU.	Inestabilidad en Q4
(año base - 8)	Continuación QE3 anticipado	Estímulo sostenido de la Fed	Estabilidad de mercado
	“Taper tantrum”	Bernanke anuncia retiro de QE gradualmente	Caídas temporales en acciones y bonos

(año base - 7)	Caída del petróleo	Pasa de >100 USD a <50 USD/barril	Energía cae, consumo se fortalece
	Tensión en Europa del Este	Inestabilidad geopolítica	Leve impacto
(año base - 6)	Crisis en China	Bolsa china colapsa, devaluación del yuan	Fondo cae 10%
	Caída en commodities	Petróleo, cobre, etc. en mínimos	Presión a sectores industriales
(año base - 5)	Subida de tasas por la Fed	Primera alza en casi 10 años (diciembre)	Cambio de ciclo monetario
	Brexit	Reino Unido vota salir de la UE	Caída de 5% en Fondo en 2 días, luego rebote
	Elección presidenciales EEUU	Sorpresa electoral → impulso a sectores cíclicos	Fondo sube fuerte desde noviembre

(año base - 4)	Reforma tributaria	Rebaja de impuestos corporativos al 21%	Fondo sube con fuerza todo el año
	Baja volatilidad histórica	Prácticamente sin correcciones >5%	Subida tranquila y estable
(año base - 3)	Guerra comercial entre 2 potencias	Aranceles y tensiones bilaterales	Caídas intermitentes
	Subidas agresivas de tasas por la Fed	4 alzas de tasas en el año	Fondo cae ~20% en Q4
(año base - 2)	Volatilidad repunta	VIX alcanza máximos de 2 años	Inversores defensivos
	Tregua comercial parcial	EE.UU. y China firman “fase 1”	Confianza se recupera
	Bajas de tasas por la Fed	3 recortes de tasas en el año	Impulso adicional al Fondo
(año base - 1)	Inversión de curva de rendimientos	Riesgo de recesión percibida	Alerta en mercados
	Crisis sanitaria	Cierre global de economías en marzo	Fondo cae ~34% en 1 mes
	Intervención sin precedentes de la Fed y el Congreso	Estímulo monetario y fiscal masivo	Fondo se recupera y marca máximos en agosto
(año base)	Elecciones presidenciales EEUU	Expectativas de más gasto fiscal	Positiva para sectores “verdes”

Tabla 47

Resultados del Proceso de Ocultación de Datos de la Tabla 10

Origen del Fondo	Global
Nombre del Fondo	Atlas Macro Opportunities
Perfil de Riesgo	Alto (alta volatilidad, sensible a tasas de interés y geopolítica)
Tipo de Fondo	Instrumento financiero indexado
Moneda Base	USD

Tabla 48*Resultados del Proceso de Ocultación de Datos de la Tabla 11*

Fecha	Cierre Ajustado	Fecha	Cierre Ajustado	Fecha	Cierre Ajustado
01-12-(año base)	1,23	01-05-(año base - 2)	1,1667	01-09-(año base - 5)	1,1256
01-11-(año base)	1,1971	01-04-(año base - 2)	1,2123	01-08-(año base - 5)	1,1214
01-10-(año base)	1,1677	01-03-(año base - 2)	1,2332	01-07-(año base - 5)	1,0939
01-09-(año base)	1,1742	01-02-(año base - 2)	1,223	01-06-(año base - 5)	1,1223
01-08-(año base)	1,1918	01-01-(año base - 2)	1,241	01-05-(año base - 5)	1,096
01-07-(año base)	1,1872	01-12-(año base - 3)	1,2	01-04-(año base - 5)	1,1114
01-06-(año base)	1,1247	01-11-(año base - 3)	1,1852	01-03-(año base - 5)	1,083
01-05-(año base)	1,111	01-10-(año base - 3)	1,1653	01-02-(año base - 5)	1,1198
01-04-(año base)	1,0877	01-09-(año base - 3)	1,1742	01-01-(año base - 5)	1,1288
01-03-(año base)	1,03	01-08-(año base - 3)	1,1893	01-12-(año base - 6)	1,2162
01-02-(año base)	1,03	01-07-(año base - 3)	1,1747	01-11-(año base - 6)	1,2438
01-01-(año base)	1,1029	01-06-(año base - 3)	1,1442	01-10-(año base - 6)	1,2613
01-12-(año base - 1)	1,1202	01-05-(año base - 3)	1,1172	01-09-(año base - 6)	1,2691
01-11-(año base - 1)	1,102	01-04-(año base - 3)	1,0908	01-08-(año base - 6)	1,3135
01-10-(año base - 1)	1,1154	01-03-(año base - 3)	1,0687	01-07-(año base - 6)	1,3369
01-09-(año base - 1)	1,0943	01-02-(año base - 3)	1,0584	01-06-(año base - 6)	1,3644
01-08-(año base - 1)	1,1012	01-01-(año base - 3)	1,0709	01-05-(año base - 6)	1,3635
01-07-(año base - 1)	1,1158	01-12-(año base - 4)	1,052	01-04-(año base - 6)	1,3814

01-06-(año base - 1)	1,1391	01-11-(año base - 4)	1,0648	01-03-(año base - 6)	1,3752
01-05-(año base - 1)	1,1131	01-10-(año base - 4)	1,0985	01-02-(año base - 6)	1,3707
01-04-(año base - 1)	1,1185	01-09-(año base - 4)	1,122	01-01-(año base - 6)	1,3559
01-03-(año base - 1)	1,1233	01-08-(año base - 4)	1,1153	01-12-(año base - 7)	1,381
01-02-(año base - 1)	1,138	01-07-(año base - 4)	1,1168	01-11-(año base - 7)	1,3594
01-01-(año base - 1)	1,1488	01-06-(año base - 4)	1,1128	01-10-(año base - 7)	1,3724
01-12-(año base - 2)	1,144	01-05-(año base - 4)	1,1148	01-09-(año base - 7)	1,3495
01-11-(año base - 2)	1,1393	01-04-(año base - 4)	1,1382	01-08-(año base - 7)	1,3224
01-10-(año base - 2)	1,1346	01-03-(año base - 4)	1,1335	01-07-(año base - 7)	1,3265
01-09-(año base - 2)	1,1623	01-02-(año base - 4)	1,0924	01-06-(año base - 7)	1,3013
01-08-(año base - 2)	1,1667	01-01-(año base - 4)	1,0826	01-05-(año base - 7)	1,3044
01-07-(año base - 2)	1,1707	01-12-(año base - 5)	1,0934	01-04-(año base - 7)	1,3096
01-06-(año base - 2)	1,1705	01-11-(año base - 5)	1,0583	01-03-(año base - 7)	1,2808
01-05-(año base - 2)	1,1667	01-10-(año base - 5)	1,1009	01-02-(año base - 7)	1,316
01-04-(año base - 2)	1,2123			01-01-(año base - 7)	1,3568

Tabla 49*Resultados del Proceso de Ocultación de Datos de la Tabla 12*

Año	Evento	Descripción	Impacto en el Fondo
(año base - 7)	Crisis de deuda en la Eurozona (residual)	Persisten tensiones en países Europeos	Presión bajista sobre el euro, fortalece al dólar
(año base - 6)	Crisis en Europa del Este.	Inestabilidad geopolítica, sanciones de UE y EE.UU.	Euro cae frente al dólar por aversión al riesgo
(año base - 6)	Política monetaria expansiva del BCE	Anuncio de Mario Draghi sobre estímulos monetarios	Fondo se deprecia
(año base - 5)	Quantitative Easing (BCE)	BCE inicia programa masivo de compra de activos	Fondo cae hasta niveles de 1,05
(año base - 5)	Crisis de Grecia (Grexit)	Riesgo de salida de Grecia del euro	Incrementa la volatilidad, euro presionado a la baja
(año base - 4)	Brexit (Reino Unido vota salir de la UE)	Shock en Europa con implicancias políticas y económicas	Fondo cae por incertidumbre

(año base - 4)	Elecciones en EE.UU.	Apuesta por políticas fiscales expansivas y dólar fuerte	Dólar se fortalece, el Fondo cae
(año base - 3)	Reforma tributaria de EE.UU.	Rebaja de impuestos corporativos impulsa la economía estadounidense	Dólar se fortalece, euro retrocede
(año base - 2)	Guerra comercial entre 2 potencias	Tensión global, aversión al riesgo	Dólar se percibe como refugio, presión bajista sobre el euro
(año base - 1)	Inversión de curva de rendimientos en EE.UU.	Riesgo de recesión percibido	Aumenta volatilidad, euro se mueve lateral pero mantiene debilidad frente al dólar
(año base)	Crisis sanitaria	Crisis sanitaria y económica global	En marzo: euro cae fuerte vs. dólar; después: estímulos masivos del BCE y Fed impulsan recuperación del euro
(año base)	Estímulo fiscal y monetario sin precedentes	FED baja tasas a 0% y BCE refuerza estímulos	Fondo se aprecia en el segundo semestre
(año base)	Elecciones presidenciales EE.UU.	Expectativas de más gasto fiscal	Anticipa presión a la baja en el dólar → fortalecimiento del euro

(año base + 1) (previsto desde (año base))	Brexit definitivo (salida comercial)	Fin del periodo de transición en enero 2021	Se anticipaba volatilidad en el euro por la nueva relación UE- Reino Unido
--	---	---	--

Tabla 50

Resultados del Proceso de Ocultación de Datos de la Tabla 13

Observation date	FEDFUNDS	Observation date	FEDFUNDS	Observation date	FEDFUNDS
01-01-(año base - 7)	0,14	01-09-(año base - 5)	0,14	01-05-(año base - 2)	1,7
01-02-(año base - 7)	0,15	01-10-(año base - 5)	0,12	01-06-(año base - 2)	1,82
01-03-(año base - 7)	0,14	01-11-(año base - 5)	0,12	01-07-(año base - 2)	1,91
01-04-(año base - 7)	0,15	01-12-(año base - 5)	0,24	01-08-(año base - 2)	1,91

01-05-(año base - 7)	0,11	01-01-(año base - 4)	0,34	01-09-(año base - 2)	1,95
01-06-(año base - 7)	0,09	01-02-(año base - 4)	0,38	01-10-(año base - 2)	2,19
01-07-(año base - 7)	0,09	01-03-(año base - 4)	0,36	01-11-(año base - 2)	2,2
01-08-(año base - 7)	0,08	01-04-(año base - 4)	0,37	01-12-(año base - 2)	2,27
01-09-(año base - 7)	0,08	01-05-(año base - 4)	0,37	01-01-(año base - 1)	2,4
01-10-(año base - 7)	0,09	01-06-(año base - 4)	0,38	01-02-(año base - 1)	2,4
01-11-(año base - 7)	0,08	01-07-(año base - 4)	0,39	01-03-(año base - 1)	2,41
01-12-(año base - 7)	0,09	01-08-(año base - 4)	0,4	01-04-(año base - 1)	2,42
01-01-(año base - 6)	0,07	01-09-(año base - 4)	0,4	01-05-(año base - 1)	2,39

01-02-(año base - 6)	0,07	01-10-(año base - 4)	0,4	01-06-(año base - 1)	2,38
01-03-(año base - 6)	0,08	01-11-(año base - 4)	0,41	01-07-(año base - 1)	2,4
01-04-(año base - 6)	0,09	01-12-(año base - 4)	0,54	01-08-(año base - 1)	2,13
01-05-(año base - 6)	0,09	01-01-(año base - 3)	0,65	01-09-(año base - 1)	2,04
01-06-(año base - 6)	0,1	01-02-(año base - 3)	0,66	01-10-(año base - 1)	1,83
01-07-(año base - 6)	0,09	01-03-(año base - 3)	0,79	01-11-(año base - 1)	1,55
01-08-(año base - 6)	0,09	01-04-(año base - 3)	0,9	01-12-(año base - 1)	1,55
01-09-(año base - 6)	0,09	01-05-(año base - 3)	0,91	01-01-(año base)	1,55
01-10-(año base - 6)	0,09	01-06-(año base - 3)	1,04	01-02-(año base)	1,58

01-11-(año base - 6)	0,09	01-07-(año base - 3)	1,15	01-03-(año base)	0,65
01-12-(año base - 6)	0,12	01-08-(año base - 3)	1,16	01-04-(año base)	0,05
01-01-(año base - 5)	0,11	01-09-(año base - 3)	1,15	01-05-(año base)	0,05
01-02-(año base - 5)	0,11	01-10-(año base - 3)	1,15	01-06-(año base)	0,08
01-03-(año base - 5)	0,11	01-11-(año base - 3)	1,16	01-07-(año base)	0,09
01-04-(año base - 5)	0,12	01-12-(año base - 3)	1,3	01-08-(año base)	0,1
01-05-(año base - 5)	0,12	01-01-(año base - 2)	1,41	01-09-(año base)	0,09
01-06-(año base - 5)	0,13	01-02-(año base - 2)	1,42	01-10-(año base)	0,09
01-07-(año base - 5)	0,13	01-03-(año base - 2)	1,51	01-11-(año base)	0,09
01-08-(año base - 5)	0,14	01-04-(año base - 2)	1,69	01-12-(año base)	0,09

Tabla 51*Resultados del Proceso de Ocultación de Datos de la Tabla 14*

Observation date	ECBMLFR	Observation date	ECBMLFR	Observation date	ECBMLFR
01-01-(Año base - 7)	1,5	01-09-(Año base - 5)	0,3	01-05-(Año base - 2)	0,25
01-02-(Año base - 7)	1,5	01-10-(Año base - 5)	0,3	01-06-(Año base - 2)	0,25
01-03-(Año base - 7)	1,5	01-11-(Año base - 5)	0,3	01-07-(Año base - 2)	0,25
01-04-(Año base - 7)	1,5	01-12-(Año base - 5)	0,3	01-08-(Año base - 2)	0,25
01-05-(Año base - 7)	1,11	01-01-(Año base - 4)	0,3	01-09-(Año base - 2)	0,25
01-06-(Año base - 7)	1	01-02-(Año base - 4)	0,3	01-10-(Año base - 2)	0,25
01-07-(Año base - 7)	1	01-03-(Año base - 4)	0,27	01-11-(Año base - 2)	0,25
01-08-(Año base - 7)	1	01-04-(Año base - 4)	0,25	01-12-(Año base - 2)	0,25
01-09-(Año base - 7)	1	01-05-(Año base - 4)	0,25	01-01-(Año base - 1)	0,25
01-10-(Año base - 7)	1	01-06-(Año base - 4)	0,25	01-02-(Año base - 1)	0,25
01-11-(Año base - 7)	0,85	01-07-(Año base - 4)	0,25	01-03-(Año base - 1)	0,25
01-12-(Año base - 7)	0,75	01-08-(Año base - 4)	0,25	01-04-(Año base - 1)	0,25
01-01-(Año base - 6)	0,75	01-09-(Año base - 4)	0,25	01-05-(Año base - 1)	0,25
01-02-(Año base - 6)	0,75	01-10-(Año base - 4)	0,25	01-06-(Año base - 1)	0,25
01-03-(Año base - 6)	0,75	01-11-(Año base - 4)	0,25	01-07-(Año base - 1)	0,25
01-04-(Año base - 6)	0,75	01-12-(Año base - 4)	0,25	01-08-(Año base - 1)	0,25
01-05-(Año base - 6)	0,75	01-01-(Año base - 3)	0,25	01-09-(Año base - 1)	0,25
01-06-(Año base - 6)	0,52	01-02-(Año base - 3)	0,25	01-10-(Año base - 1)	0,25
01-07-(Año base - 6)	0,4	01-03-(Año base - 3)	0,25	01-11-(Año base - 1)	0,25
01-08-(Año base - 6)	0,4	01-04-(Año base - 3)	0,25	01-12-(Año base - 1)	0,25
01-09-(Año base - 6)	0,33	01-05-(Año base - 3)	0,25	01-01-(Año base)	0,25
01-10-(Año base - 6)	0,3	01-06-(Año base - 3)	0,25	01-02-(Año base)	0,25
01-11-(Año base - 6)	0,3	01-07-(Año base - 3)	0,25	01-03-(Año base)	0,25
01-12-(Año base - 6)	0,3	01-08-(Año base - 3)	0,25	01-04-(Año base)	0,25
01-01-(Año base - 5)	0,3	01-09-(Año base - 3)	0,25	01-05-(Año base)	0,25
01-02-(Año base - 5)	0,3	01-10-(Año base - 3)	0,25	01-06-(Año base)	0,25
01-03-(Año base - 5)	0,3	01-11-(Año base - 3)	0,25	01-07-(Año base)	0,25
01-04-(Año base - 5)	0,3	01-12-(Año base - 3)	0,25	01-08-(Año base)	0,25

01-05-(Año base - 5)	0,3	01-01-(Año base - 2)	0,25	01-09-(Año base)	0,25
01-06-(Año base - 5)	0,3	01-02-(Año base - 2)	0,25	01-10-(Año base)	0,25
01-07-(Año base - 5)	0,3	01-03-(Año base - 2)	0,25	01-11-(Año base)	0,25
01-08-(Año base - 5)	0,3	01-04-(Año base - 2)	0,25	01-12-(Año base)	0,25

Tabla 52*Resultados del Proceso de Ocultación de Datos de la Tabla 15*

Fecha	Cierre Ajustado (VIX)	Fecha	Cierre Ajustado (VIX)	Fecha	Cierre Ajustado (VIX)
Jan 1, (Año base - 7)	14,28	Sep 1, (Año base - 5)	24,5	May 1, (Año base - 2)	15,43
Feb 1, (Año base - 7)	15,51	Oct 1, (Año base - 5)	15,07	Jun 1, (Año base - 2)	16,09
Mar 1, (Año base - 7)	12,7	Nov 1, (Año base - 5)	16,13	Jul 1, (Año base - 2)	12,83
Apr 1, (Año base - 7)	13,52	Dec 1, (Año base - 5)	18,21	Aug 1, (Año base - 2)	12,86
May 1, (Año base - 7)	16,3	Jan 1, (Año base - 4)	20,2	Sep 1, (Año base - 2)	12,12
Jun 1, (Año base - 7)	16,86	Feb 1, (Año base - 4)	20,55	Oct 1, (Año base - 2)	21,23
Jul 1, (Año base - 7)	13,45	Mar 1, (Año base - 4)	13,95	Nov 1, (Año base - 2)	18,07
Aug 1, (Año base - 7)	16,6	Apr 1, (Año base - 4)	15,7	Dec 1, (Año base - 2)	25,42
Sep 1, (Año base - 7)	16,6	May 1, (Año base - 4)	14,19	Jan 1, (Año base - 1)	16,57
Oct 1, (Año base - 7)	13,75	Jun 1, (Año base - 4)	15,63	Feb 1, (Año base - 1)	14,78
Nov 1, (Año base - 7)	13,7	Jul 1, (Año base - 4)	11,87	Mar 1, (Año base - 1)	13,71
Dec 1, (Año base - 7)	13,72	Aug 1, (Año base - 4)	13,42	Apr 1, (Año base - 1)	13,12
Jan 1, (Año base - 6)	18,41	Sep 1, (Año base - 4)	13,29	May 1, (Año base - 1)	18,71
Feb 1, (Año base - 6)	14	Oct 1, (Año base - 4)	17,06	Jun 1, (Año base - 1)	15,08
Mar 1, (Año base - 6)	13,41	Nov 1, (Año base - 4)	13,33	Jul 1, (Año base - 1)	16,12
Apr 1, (Año base - 6)	11,41	Dec 1, (Año base - 4)	14,04	Aug 1, (Año base - 1)	18,98
May 1, (Año base - 6)	11,4	Jan 1, (Año base - 3)	11,99	Sep 1, (Año base - 1)	16,24
Jun 1, (Año base - 6)	11,57	Feb 1, (Año base - 3)	12,92	Oct 1, (Año base - 1)	13,22
Jul 1, (Año base - 6)	16,95	Mar 1, (Año base - 3)	12,37	Nov 1, (Año base - 1)	12,62
Aug 1, (Año base - 6)	12,09	Apr 1, (Año base - 3)	10,82	Dec 1, (Año base - 1)	13,78

Sep 1, (Año base - 6)	16,31	May 1, (Año base - 3)	11,18	Jan 1, (Año base)	18,84
Oct 1, (Año base - 6)	14,03	Jun 1, (Año base - 3)	10,41	Feb 1, (Año base)	40,11
Nov 1, (Año base - 6)	13,33	Jul 1, (Año base - 3)	10,26	Mar 1, (Año base)	53,54
Dec 1, (Año base - 6)	19,2	Aug 1, (Año base - 3)	10,59	Apr 1, (Año base)	34,15
Jan 1, (Año base - 5)	20,97	Sep 1, (Año base - 3)	9,51	May 1, (Año base)	27,51
Feb 1, (Año base - 5)	15,29	Oct 1, (Año base - 3)	10,18	Jun 1, (Año base)	30,43
Mar 1, (Año base - 5)	15,29	Nov 1, (Año base - 3)	11,28	Jul 1, (Año base)	24,46
Apr 1, (Año base - 5)	13,84	Dec 1, (Año base - 3)	11,04	Aug 1, (Año base)	26,41
May 1, (Año base - 5)	18,23	Jan 1, (Año base - 2)	13,54	Sep 1, (Año base)	26,37
Jun 1, (Año base - 5)	18,23	Feb 1, (Año base - 2)	19,85	Oct 1, (Año base)	38,02
Jul 1, (Año base - 5)	12,12	Mar 1, (Año base - 2)	19,97	Nov 1, (Año base)	20,57
Aug 1, (Año base - 5)	28,43	Apr 1, (Año base - 2)	15,93	Dec 1, (Año base)	22,75

Tabla 53

Resultados del Proceso de Ocultación de Datos de la Tabla 16

Origen del Activo	Global
Nombre del Activo	Altair Strategic Bond
Perfil de Riesgo	Muy alto (alta volatilidad y especulación)
Tipo de Activo	Activo digital descentralizado
Moneda Base	USD

Tabla 54*Resultados del Proceso de Ocultación de Datos de la Tabla 17*

Fecha	Último	Vol.	Fecha	Último	Vol.	Fecha	Último	Vol.
27.12.(Año base)	32.193,30	962,22K	28.04.(Año base - 1)	5.830,90	5,56M	27.08.(Año base - 3)	4.573,80	622,35K
20.12.(Año base)	26.454,40	805,84K	21.04.(Año base - 1)	5.265,90	6,56M	20.08.(Año base - 3)	4.352,30	628,02K
13.12.(Año base)	23.844,00	1,01M	14.04.(Año base - 1)	5.290,20	4,90M	13.08.(Año base - 3)	4.150,50	997,13K
06.12.(Año base)	18.808,90	642,93K	07.04.(Año base - 1)	5.051,80	5,83M	06.08.(Año base - 3)	3.871,60	644,93K
29.11.(Año base)	19.146,50	883,70K	31.03.(Año base - 1)	5.046,20	36,99M	30.07.(Año base - 3)	3.262,80	675,09K
22.11.(Año base)	17.730,70	1,15M	24.03.(Año base - 1)	4.111,80	19,14M	23.07.(Año base - 3)	2.733,50	859,86K
15.11.(Año base)	18.687,20	985,86K	17.03.(Año base - 1)	4.002,50	20,06M	16.07.(Año base - 3)	2.836,50	1,35M
08.11.(Año base)	16.071,00	849,61K	10.03.(Año base - 1)	4.006,40	19,44M	09.07.(Año base - 3)	1.975,10	777,01K
01.11.(Año base)	14.828,40	969,23K	03.03.(Año base - 1)	3.944,30	19,19M	02.07.(Año base - 3)	2.564,90	526,68K
25.10.(Año base)	13.797,30	737,16K	24.02.(Año base - 1)	3.823,10	12,42M	25.06.(Año base - 3)	2.424,60	737,13K
18.10.(Año base)	13.117,20	649,57K	17.02.(Año base - 1)	4.120,40	5,61M	18.06.(Año base - 3)	2.590,10	623,37K
11.10.(Año base)	11.362,10	458,66K	10.02.(Año base - 1)	3.616,80	3,65M	11.06.(Año base - 3)	2.655,10	1,07M
04.10.(Año base)	11.298,40	415,50K	03.02.(Año base - 1)	3.661,40	3,78M	04.06.(Año base - 3)	2.900,30	710,05K
27.09.(Año base)	10.544,20	473,68K	27.01.(Año base - 1)	3.502,50	3,68M	28.05.(Año base - 3)	2.545,40	732,63K
20.09.(Año base)	10.727,90	521,93K	20.01.(Año base - 1)	3.570,90	3,16M	21.05.(Año base - 3)	2.052,40	1,18M
13.09.(Año base)	11.081,80	552,84K	13.01.(Año base - 1)	3.677,80	3,50M	14.05.(Año base - 3)	2.040,20	552,75K
06.09.(Año base)	10.441,90	24,92M	06.01.(Año base - 1)	3.597,20	3,80M	07.05.(Año base - 3)	1.763,70	689,31K

30.08.(Año base)	10.092,20	56,56M	30.12.(Año base - 2)	3.785,40	3,52M	30.04.(Año base - 3)	1.545,30	609,50K
23.08.(Año base)	11.468,10	3,40M	23.12.(Año base - 2)	3.706,80	4,18M	23.04.(Año base - 3)	1.336,30	364,25K
16.08.(Año base)	11.661,30	3,65M	16.12.(Año base - 2)	3.964,40	4,77M	16.04.(Año base - 3)	1.240,90	301,86K
09.08.(Año base)	11.845,30	3,46M	09.12.(Año base - 2)	3.228,70	2,82M	09.04.(Año base - 3)	1.177,00	309,20K
02.08.(Año base)	11.764,30	3,74M	02.12.(Año base - 2)	3.430,40	2,98M	02.04.(Año base - 3)	1.180,80	495,23K
26.07.(Año base)	11.803,10	4,12M	25.11.(Año base - 2)	4.196,20	3,46M	26.03.(Año base - 3)	1.086,10	542,07K
19.07.(Año base)	9.704,10	2,56M	18.11.(Año base - 2)	3.920,40	2,69M	19.03.(Año base - 3)	966,3	691,92K
12.07.(Año base)	9.170,20	2,76M	11.11.(Año base - 2)	5.621,80	1,64M	12.03.(Año base - 3)	971,4	700,54K
05.07.(Año base)	9.233,30	3,03M	04.11.(Año base - 2)	6.427,10	1,04M	05.03.(Año base - 3)	1.179,20	563,14K
28.06.(Año base)	9.134,40	2,61M	28.10.(Año base - 2)	6.386,20	897,36K	26.02.(Año base - 3)	1.264,30	352,15K
21.06.(Año base)	9.008,30	3,24M	21.10.(Año base - 2)	6.494,20	685,44K	19.02.(Año base - 3)	1.149,10	373,70K
14.06.(Año base)	9.358,80	3,38M	14.10.(Año base - 2)	6.572,20	1,21M	12.02.(Año base - 3)	1.052,30	219,71K
07.06.(Año base)	9.471,30	3,94M	07.10.(Año base - 2)	6.321,70	907,69K	05.02.(Año base - 3)	1.008,30	404,97K
31.05.(Año base)	9.669,60	4,72M	30.09.(Año base - 2)	6.596,30	64,74M	29.01.(Año base - 3)	1.031,80	282,01K
24.05.(Año base)	9.692,50	6,17M	23.09.(Año base - 2)	6.603,90	59,02M	22.01.(Año base - 3)	918,5	256,52K
17.05.(Año base)	9.177,00	7,89M	16.09.(Año base - 2)	6.729,60	33,27M	15.01.(Año base - 3)	919,8	346,77K
10.05.(Año base)	9.379,50	12,52M	09.09.(Año base - 2)	6.519,00	22,18M	08.01.(Año base - 3)	819,6	641,94K
03.05.(Año base)	9.554,60	9,63M	02.09.(Año base - 2)	6.184,30	26,79M	01.01.(Año base - 3)	888,9	1,65M
26.04.(Año base)	8.966,30	8,77M	26.08.(Año base - 2)	7.189,60	26,36M	25.12.(Año base - 4)	963,4	367,77K
19.04.(Año base)	7.540,40	12,22M	19.08.(Año base - 2)	6.734,80	20,84M	18.12.(Año base - 4)	891,1	358,58K

12.04.(Año base)	7.230,80	7,48M	12.08.(Año base - 2)	6.379,10	17,63M	11.12.(Año base - 4)	787,2	181,20K
05.04.(Año base)	6.867,80	8,36M	05.08.(Año base - 2)	6.231,60	1,71M	04.12.(Año base - 4)	774	209,60K
29.03.(Año base)	6.857,40	9,18M	29.07.(Año base - 2)	7.014,30	1,55M	27.11.(Año base - 4)	764,2	283,01K
22.03.(Año base)	6.233,70	10,15M	22.07.(Año base - 2)	8.234,10	1,80M	20.11.(Año base - 4)	734,1	250,91K
15.03.(Año base)	6.186,20	14,45M	15.07.(Año base - 2)	7.408,70	1,92M	13.11.(Año base - 4)	747,9	322,97K
08.03.(Año base)	5.182,70	16,09M	08.07.(Año base - 2)	6.254,80	1,88M	06.11.(Año base - 4)	704,3	253,50K
01.03.(Año base)	8.887,80	6,44M	01.07.(Año base - 2)	6.765,50	1,03M	30.10.(Año base - 4)	702,1	351,15K
23.02.(Año base)	8.543,70	7,28M	24.06.(Año base - 2)	6.398,90	1,34M	23.10.(Año base - 4)	715	279,12K
16.02.(Año base)	9.655,70	5,93M	17.06.(Año base - 2)	6.167,30	988,81K	16.10.(Año base - 4)	655,5	186,59K
09.02.(Año base)	9.907,70	5,39M	10.06.(Año base - 2)	6.505,80	1,32M	09.10.(Año base - 4)	637	190,80K
02.02.(Año base)	9.895,50	4,78M	03.06.(Año base - 2)	7.515,80	868,03K	02.10.(Año base - 4)	617,7	154,85K
26.01.(Año base)	9.381,60	4,89M	27.05.(Año base - 2)	7.646,60	984,53K	25.09.(Año base - 4)	613,4	151,47K
19.01.(Año base)	8.341,60	4,60M	20.05.(Año base - 2)	7.361,30	1,08M	18.09.(Año base - 4)	602,6	158,87K
12.01.(Año base)	8.916,30	6,33M	13.05.(Año base - 2)	8.245,10	1,14M	11.09.(Año base - 4)	607,1	176,68K
05.01.(Año base)	8.024,10	6,53M	06.05.(Año base - 2)	8.459,50	1,26M	04.09.(Año base - 4)	624,5	190,28K
29.12.(Año base - 1)	7.376,80	4,70M	29.04.(Año base - 2)	9.853,50	1,17M	28.08.(Año base - 4)	598,8	177,29K
22.12.(Año base - 1)	7.321,50	5,29M	22.04.(Año base - 2)	9.352,40	1,60M	21.08.(Año base - 4)	570,3	180,45K
15.12.(Año base - 1)	7.156,20	5,22M	15.04.(Año base - 2)	8.923,10	1,27M	14.08.(Año base - 4)	582,6	216,33K
08.12.(Año base - 1)	7.080,80	3,88M	08.04.(Año base - 2)	8.004,40	1,51M	07.08.(Año base - 4)	584,6	211,25K
01.12.(Año base - 1)	7.510,90	5,17M	01.04.(Año base - 2)	6.905,70	1,50M	31.07.(Año base - 4)	586,5	444,48K

24.11.(Año base - 1)	7.546,60	6,29M	25.03.(Año base - 2)	6.938,20	1,80M	24.07.(Año base - 4)	654,7	217,98K
17.11.(Año base - 1)	7.324,10	6,19M	18.03.(Año base - 2)	8.547,40	1,75M	17.07.(Año base - 4)	655,2	285,32K
10.11.(Año base - 1)	8.497,30	4,02M	11.03.(Año base - 2)	7.874,90	1,84M	10.07.(Año base - 4)	660,7	309,16K
03.11.(Año base - 1)	8.804,50	4,63M	04.03.(Año base - 2)	8.762,00	1,66M	03.07.(Año base - 4)	651,8	590,38K
27.10.(Año base - 1)	9.300,60	6,08M	25.02.(Año base - 2)	11.402,30	1,41M	26.06.(Año base - 4)	698,1	593,43K
20.10.(Año base - 1)	9.230,60	4,23M	18.02.(Año base - 2)	9.704,30	1,93M	19.06.(Año base - 4)	663,5	1,18M
13.10.(Año base - 1)	7.957,30	3,38M	11.02.(Año base - 2)	11.073,50	1,64M	12.06.(Año base - 4)	753,8	1,21M
06.10.(Año base - 1)	8.304,40	4,00M	04.02.(Año base - 2)	8.559,60	3,00M	05.06.(Año base - 4)	591,6	398,83K
29.09.(Año base - 1)	8.127,30	3,23M	28.01.(Año base - 2)	9.241,10	1,89M	29.05.(Año base - 4)	572	663,12K
22.09.(Año base - 1)	8.208,50	4,23M	21.01.(Año base - 2)	11.467,50	1,33M	22.05.(Año base - 4)	524,2	459,13K
15.09.(Año base - 1)	9.993,00	2,51M	14.01.(Año base - 2)	12.858,90	1,39M	15.05.(Año base - 4)	443,6	255,85K
08.09.(Año base - 1)	10.337,30	2,74M	07.01.(Año base - 2)	14.292,20	691,25K	08.05.(Año base - 4)	456,4	277,91K
01.09.(Año base - 1)	10.461,10	3,62M	31.12.(Año base - 3)	17.172,30	770,83K	01.05.(Año base - 4)	458,5	326,08K
25.08.(Año base - 1)	9.594,40	3,29M	24.12.(Año base - 3)	12.531,50	1,04M	24.04.(Año base - 4)	448,5	476,55K
18.08.(Año base - 1)	10.131,00	3,57M	17.12.(Año base - 3)	14.396,50	1,46M	17.04.(Año base - 4)	450,1	333,40K
11.08.(Año base - 1)	10.218,10	4,62M	10.12.(Año base - 3)	19.345,50	1,02M	10.04.(Año base - 4)	430	269,29K
04.08.(Año base - 1)	11.314,50	4,55M	03.12.(Año base - 3)	14.843,40	1,26M	03.04.(Año base - 4)	418	242,22K
28.07.(Año base - 1)	10.815,70	3,89M	26.11.(Año base - 3)	10.912,70	919,63K	27.03.(Año base - 4)	418,5	328,93K
21.07.(Año base - 1)	9.492,10	4,02M	19.11.(Año base - 3)	8.754,70	551,27K	20.03.(Año base - 4)	416,5	264,86K
14.07.(Año base - 1)	10.826,70	6,29M	12.11.(Año base - 3)	7.780,90	1,00M	13.03.(Año base - 4)	408,7	324,33K

07.07.(Año base - 1)	11.364,90	5,64M	05.11.(Año base - 3)	6.339,90	1,07M	06.03.(Año base - 4)	410,4	405,06K
30.06.(Año base - 1)	11.268,00	6,41M	29.10.(Año base - 3)	7.363,80	976,41K	28.02.(Año base - 4)	399	528,15K
23.06.(Año base - 1)	11.906,50	7,21M	22.10.(Año base - 3)	5.726,60	722,59K	21.02.(Año base - 4)	431,3	466,28K
16.06.(Año base - 1)	10.721,70	5,15M	15.10.(Año base - 3)	6.006,60	670,51K	14.02.(Año base - 4)	440,1	559,58K
09.06.(Año base - 1)	8.812,50	4,24M	08.10.(Año base - 3)	5.824,70	805,69K	07.02.(Año base - 4)	390,1	420,40K
02.06.(Año base - 1)	7.901,40	4,88M	01.10.(Año base - 3)	4.435,80	443,24K	31.01.(Año base - 4)	376,7	465,80K
26.05.(Año base - 1)	8.545,70	20,69M	24.09.(Año base - 3)	4.360,60	588,23K	24.01.(Año base - 4)	377,8	484,64K
19.05.(Año base - 1)	8.027,40	6,20M	17.09.(Año base - 3)	3.788,00	781,52K	17.01.(Año base - 4)	388,6	688,23K
12.05.(Año base - 1)	7.262,60	9,03M	10.09.(Año base - 3)	3.698,90	1,43M	10.01.(Año base - 4)	385	735,95K
05.05.(Año base - 1)	7.190,30	5,78M	03.09.(Año base - 3)	4.335,10	870,55K	03.01.(Año base - 4)	448,3	457,61K

Tabla 55*Resultados del Proceso de Ocultación de Datos de la Tabla 18*

Date	Price (DXY)	Date	Price (DXY)	Date	Price (DXY)
12/27/(Año base)	89,94	04/28/(Año base - 1)	97,52	08/27/(Año base - 3)	92,81
12/20/(Año base)	90,32	04/21/(Año base - 1)	98,01	08/20/(Año base - 3)	92,74
12/13/(Año base)	90,02	04/14/(Año base - 1)	97,38	08/13/(Año base - 3)	93,43
12-06-(Año base)	90,98	04-07-(Año base - 1)	96,97	08-06-(Año base - 3)	93,07
11/29/(Año base)	90,7	03/31/(Año base - 1)	97,39	07/30/(Año base - 3)	93,54
11/22/(Año base)	91,79	03/24/(Año base - 1)	97,28	07/23/(Año base - 3)	93,26
11/15/(Año base)	92,39	03/17/(Año base - 1)	96,65	07/16/(Año base - 3)	93,86
11-08-(Año base)	92,75	03-10-(Año base - 1)	96,6	07-09-(Año base - 3)	95,15
11-01-(Año base)	92,23	03-03-(Año base - 1)	97,31	07-02-(Año base - 3)	96,01
10/25/(Año base)	94,04	02/24/(Año base - 1)	96,53	06/25/(Año base - 3)	95,63
10/18/(Año base)	92,77	02/17/(Año base - 1)	96,51	06/18/(Año base - 3)	97,26
10-11-(Año base)	93,68	02-10-(Año base - 1)	96,9	06-11-(Año base - 3)	97,16
10-04-(Año base)	93,06	02-03-(Año base - 1)	96,64	06-04-(Año base - 3)	97,27
09/27/(Año base)	93,84	01/27/(Año base - 1)	95,58	05/28/(Año base - 3)	96,71
09/20/(Año base)	94,64	01/20/(Año base - 1)	95,79	05/21/(Año base - 3)	97,44
09/13/(Año base)	92,93	01/13/(Año base - 1)	96,34	05/14/(Año base - 3)	97,14
09-06-(Año base)	93,33	01-06-(Año base - 1)	95,67	05-07-(Año base - 3)	99,25
08/30/(Año base)	92,72	12/30/(Año base - 2)	96,18	04/30/(Año base - 3)	98,65
08/23/(Año base)	92,37	12/23/(Año base - 2)	96,4	04/23/(Año base - 3)	99,05
08/16/(Año base)	93,25	12/16/(Año base - 2)	96,96	04/16/(Año base - 3)	99,98
08-09-(Año base)	93,1	12-09-(Año base - 2)	97,44	04-09-(Año base - 3)	100,56
08-02-(Año base)	93,43	12-02-(Año base - 2)	96,51	04-02-(Año base - 3)	101,18
07/26/(Año base)	93,35	11/25/(Año base - 2)	97,27	03/26/(Año base - 3)	100,35
07/19/(Año base)	94,43	11/18/(Año base - 2)	96,92	03/19/(Año base - 3)	99,63

07-12-(Año base)	95,94	11-11-(Año base - 2)	96,46	03-12-(Año base - 3)	100,3
07-05-(Año base)	96,65	11-04-(Año base - 2)	96,9	03-05-(Año base - 3)	101,25
06/28/(Año base)	97,17	10/28/(Año base - 2)	96,54	02/26/(Año base - 3)	101,54
06/21/(Año base)	97,43	10/21/(Año base - 2)	96,36	02/19/(Año base - 3)	101,09
06/14/(Año base)	97,62	10/14/(Año base - 2)	95,71	02-12-(Año base - 3)	100,95
06-07-(Año base)	97,32	10-07-(Año base - 2)	95,22	02-05-(Año base - 3)	100,8
05/31/(Año base)	96,94	09/30/(Año base - 2)	95,62	01/29/(Año base - 3)	99,87
05/24/(Año base)	98,34	09/23/(Año base - 2)	95,13	01/22/(Año base - 3)	100,53
05/17/(Año base)	99,86	09/16/(Año base - 2)	94,22	01/15/(Año base - 3)	100,74
05-10-(Año base)	100,4	09-09-(Año base - 2)	94,93	01-08-(Año base - 3)	101,18
05-03-(Año base)	99,73	09-02-(Año base - 2)	95,36	01-01-(Año base - 3)	102,22
04/26/(Año base)	99,08	08/26/(Año base - 2)	95,14	12/25/(Año base - 4)	102,21
04/19/(Año base)	100,38	08/19/(Año base - 2)	95,15	12/18/(Año base - 4)	103,01
04-12-(Año base)	99,78	08-12-(Año base - 2)	96,1	12-11-(Año base - 4)	102,95
04-05-(Año base)	99,52	08-05-(Año base - 2)	96,36	12-04-(Año base - 4)	101,59
03/29/(Año base)	100,58	07/29/(Año base - 2)	95,14	11/27/(Año base - 4)	100,77
03/22/(Año base)	98,36	07/22/(Año base - 2)	94,68	11/20/(Año base - 4)	101,49
03/15/(Año base)	102,82	07/15/(Año base - 2)	94,45	11/13/(Año base - 4)	101,21
03-08-(Año base)	98,75	07-08-(Año base - 2)	94,75	11-06-(Año base - 4)	99,06
03-01-(Año base)	95,95	07-01-(Año base - 2)	94,04	10/30/(Año base - 4)	97,06
02/23/(Año base)	98,13	06/24/(Año base - 2)	94,64	10/23/(Año base - 4)	98,35
02/16/(Año base)	99,26	06/17/(Año base - 2)	94,52	10/16/(Año base - 4)	98,69
02-09-(Año base)	99,12	06-10-(Año base - 2)	94,79	10-09-(Año base - 4)	98,02
02-02-(Año base)	98,68	06-03-(Año base - 2)	93,55	10-02-(Año base - 4)	96,63
01/26/(Año base)	97,39	05/27/(Año base - 2)	94,19	09/25/(Año base - 4)	95,46
01/19/(Año base)	97,85	05/20/(Año base - 2)	94,19	09/18/(Año base - 4)	95,48
01-12-(Año base)	97,64	05/13/(Año base - 2)	93,64	09-11-(Año base - 4)	96,11
01-05-(Año base)	97,36	05-06-(Año base - 2)	92,54	09-04-(Año base - 4)	95,34

12/29/(Año base - 1)	96,84	04/29/(Año base - 2)	92,57	08/28/(Año base - 4)	95,84
12/22/(Año base - 1)	96,92	04/22/(Año base - 2)	91,54	08/21/(Año base - 4)	95,57
12/15/(Año base - 1)	97,69	04/15/(Año base - 2)	90,32	08/14/(Año base - 4)	94,51
12-08-(Año base - 1)	97,17	04-08-(Año base - 2)	89,8	08-07-(Año base - 4)	95,72
12-01-(Año base - 1)	97,7	04-01-(Año base - 2)	90,11	07/31/(Año base - 4)	96,19
11/24/(Año base - 1)	98,27	03/25/(Año base - 2)	89,97	07/24/(Año base - 4)	95,53
11/17/(Año base - 1)	98,27	03/18/(Año base - 2)	89,48	07/17/(Año base - 4)	97,47
11-10-(Año base - 1)	98	03-11-(Año base - 2)	90,23	07-10-(Año base - 4)	96,58
11-03-(Año base - 1)	98,35	03-04-(Año base - 2)	90,09	07-03-(Año base - 4)	96,3
10/27/(Año base - 1)	97,24	02/25/(Año base - 2)	89,93	06/26/(Año base - 4)	95,65
10/20/(Año base - 1)	97,83	02/18/(Año base - 2)	89,88	06/19/(Año base - 4)	95,45
10/13/(Año base - 1)	97,28	02-11-(Año base - 2)	89,1	06-12-(Año base - 4)	94,21
10-06-(Año base - 1)	98,3	02-04-(Año base - 2)	90,44	06-05-(Año base - 4)	94,57
09/29/(Año base - 1)	98,81	01/28/(Año base - 2)	89,19	05/29/(Año base - 4)	94,03
09/22/(Año base - 1)	99,11	01/21/(Año base - 2)	89,07	05/22/(Año base - 4)	95,52
09/15/(Año base - 1)	98,51	01/14/(Año base - 2)	90,57	05/15/(Año base - 4)	95,33
09-08-(Año base - 1)	98,26	01-07-(Año base - 2)	90,97	05-08-(Año base - 4)	94,61
09-01-(Año base - 1)	98,39	12/31/(Año base - 3)	91,95	05-01-(Año base - 4)	93,89
08/25/(Año base - 1)	98,92	12/24/(Año base - 3)	92,12	04/24/(Año base - 4)	93,08
08/18/(Año base - 1)	97,64	12/17/(Año base - 3)	93,35	04/17/(Año base - 4)	95,12
08-11-(Año base - 1)	98,14	12-10-(Año base - 3)	93,93	04-10-(Año base - 4)	94,7
08-04-(Año base - 1)	97,49	12-03-(Año base - 3)	93,9	04-03-(Año base - 4)	94,23
07/28/(Año base - 1)	98,07	11/26/(Año base - 3)	92,89	03/27/(Año base - 4)	94,62
07/21/(Año base - 1)	98,01	11/19/(Año base - 3)	92,78	03/20/(Año base - 4)	96,14
07/14/(Año base - 1)	97,15	11-12-(Año base - 3)	93,66	03/13/(Año base - 4)	95,09
07-07-(Año base - 1)	96,81	11-05-(Año base - 3)	94,39	03-06-(Año base - 4)	96,17
06/30/(Año base - 1)	97,29	10/29/(Año base - 3)	94,94	02/28/(Año base - 4)	97,34
06/23/(Año base - 1)	96,13	10/22/(Año base - 3)	94,92	02/21/(Año base - 4)	98,15
06/16/(Año base - 1)	96,22	10/15/(Año base - 3)	93,7	02/14/(Año base - 4)	96,6

06-09-(Año base - 1)	97,57	10-08-(Año base - 3)	93,09	02-07-(Año base - 4)	95,94
06-02-(Año base - 1)	96,54	10-01-(Año base - 3)	93,8	01/31/(Año base - 4)	97,03
05/26/(Año base - 1)	97,75	09/24/(Año base - 3)	93,08	01/24/(Año base - 4)	99,61
05/19/(Año base - 1)	97,61	09/17/(Año base - 3)	92,17	01/17/(Año base - 4)	99,57
05-12-(Año base - 1)	98	09-10-(Año base - 3)	91,87	01-10-(Año base - 4)	98,96
05-05-(Año base - 1)	97,33	09-03-(Año base - 3)	91,35	01-03-(Año base - 4)	98,54

Tabla 56

Resultados del Proceso de Ocultación de Datos de la Tabla 19

Origen del Activo	Global
Nombre del Activo	Delta Currency Asset
Perfil de Riesgo	Bajo – Medio (activo refugio)
Tipo de Activo	Commodity financiero (Indexado)
Moneda Base	USD

Tabla 57*Resultados del Proceso de Ocultación de Datos de la Tabla 20*

Fecha	Último Valor	Fecha	Último Valor
01.12.(Año base)	1.896,49	01.06.(Año base - 1)	1.409,10
01.11.(Año base)	1.777,02	01.05.(Año base - 1)	1.305,25
01.10.(Año base)	1.877,95	01.04.(Año base - 1)	1.283,35
01.09.(Año base)	1.885,44	01.03.(Año base - 1)	1.291,90
01.08.(Año base)	1.969,75	01.02.(Año base - 1)	1.312,66
01.07.(Año base)	1.974,69	01.01.(Año base - 1)	1.320,56
01.06.(Año base)	1.780,67	01.12.(Año base - 2)	1.282,73
01.05.(Año base)	1.726,30	01.11.(Año base - 2)	1.221,88
01.04.(Año base)	1.680,09	01.10.(Año base - 2)	1.214,14
01.03.(Año base)	1.571,05	01.09.(Año base - 2)	1.191,69
01.02.(Año base)	1.584,74	01.08.(Año base - 2)	1.200,71
01.01.(Año base)	1.589,81	01.07.(Año base - 2)	1.223,41
01.12.(Año base - 1)	1.517,01	01.06.(Año base - 2)	1.252,25
01.11.(Año base - 1)	1.463,90	01.05.(Año base - 2)	1.297,92
01.10.(Año base - 1)	1.513,16	01.04.(Año base - 2)	1.314,95
01.09.(Año base - 1)	1.472,00	01.03.(Año base - 2)	1.324,00
01.08.(Año base - 1)	1.519,85	01.02.(Año base - 2)	1.317,66
01.07.(Año base - 1)	1.413,55	01.01.(Año base - 2)	1.344,70

Tabla 58

Resultados del Proceso de Ocultación de Datos de la Tabla 21

Entidad	Código	Año	GDP en Billones de dólares
World	OWID_WRL	(Año base - 10)	111,634
World	OWID_WRL	(Año base - 9)	116,041
World	OWID_WRL	(Año base - 8)	119,666
World	OWID_WRL	(Año base - 7)	123,564
World	OWID_WRL	(Año base - 6)	127,815
World	OWID_WRL	(Año base - 5)	132,068
World	OWID_WRL	(Año base - 4)	136,355
World	OWID_WRL	(Año base - 3)	141,55
World	OWID_WRL	(Año base - 2)	146,737
World	OWID_WRL	(Año base - 1)	151,09
World	OWID_WRL	(Año base)	146,875

Tabla 59

Resultados del Proceso de Ocultación de Datos de la Tabla 22

Origen del Activo	Global / Referente del mercado energético internacional
--------------------------	--

Nombre del Activo	Arkan Strategic Fund
Perfil de Riesgo	Alto
Tipo de Activo	Materia prima
Moneda Base	USD

Tabla 60*Resultados del Proceso de Ocultación de Datos de la Tabla 23*

Periodo	Precio del Activo (dólares/unidad)	Periodo	Precio del Activo (dólares/unidad)
mar.(Año base - 6)	107,88	sept.(Año base - 3)	51,74
jun.(Año base - 6)	109,78	dic.(Año base - 3)	61,47
sept.(Año base - 6)	102,08	mar.(Año base - 2)	66,95
dic.(Año base - 6)	76,01	jun.(Año base - 2)	74,49
mar.(Año base - 5)	53,93	sept.(Año base - 2)	75,48
jun.(Año base - 5)	62,1	dic.(Año base - 2)	67,37
sept.(Año base - 5)	50,03	mar.(Año base - 1)	63,27
dic.(Año base - 5)	43,42	jun.(Año base - 1)	68,34
mar.(Año base - 4)	34,36	sept.(Año base - 1)	61,86
jun.(Año base - 4)	45,95	dic.(Año base - 1)	62,65
sept.(Año base - 4)	45,8	mar.(Año base)	50,53
dic.(Año base - 4)	50,08	jun.(Año base)	31,43
mar.(Año base - 3)	54,12	sept.(Año base)	42,72
jun.(Año base - 3)	50,25	dic.(Año base)	44,52

Tabla 61

Resultados del Proceso de Ocultación de Datos de la Tabla 24

Año	Evento principal	Descripción y efectos en el Activo
(Año base - 6)	Aumento de la producción de materia prima equivalente (sustituto)	El rápido incremento de la oferta de petróleo no convencional generó un exceso en el mercado global.
(Año base - 6)	Decisión de la Agrupación de productores de la materia prima de mantener niveles de producción	La negativa a reducir la producción acentuó la sobreoferta y provocó una caída de más del 50% en el precio del Activo.
(Año base - 6)	Desaceleración del crecimiento en China	La menor demanda asiática amplificó la presión bajista sobre los precios internacionales de la materia prima.
(Año base - 5)	Persistencia de la sobreoferta global	Los precios continuaron en niveles bajos debido al exceso de producción y la lenta recuperación de la demanda.
(Año base - 5)	Aumento de inventarios en EE.UU.	El incremento de reservas del activo generó preocupación sobre un nuevo colapso de precios.
(Año base - 5)	Acuerdo nuclear en el Oriente Medio	La perspectiva de un retorno del activo desde el Oriente Medio al mercado acentuó la presión sobre la oferta mundial.
(Año base - 4)	Acuerdo para recortar producción	La cooperación entre productores permitió estabilizar parcialmente los precios cerca de 55 USD/la unidad.

(Año base - 4)	Recuperación de la demanda en Asia	Un mayor consumo energético en Asia contribuyó a un leve repunte del Activo.
(Año base - 4)	Devaluación del dólar estadounidense	El debilitamiento del dólar favoreció una mejora en los precios de las materias primas.
(Año base - 3)	Reducción de inventarios globales	La disminución de las reservas impulsó una recuperación sostenida del Activo.
(Año base - 3)	Inestabilidad política en Venezuela	La caída de la producción del activo en Venezuela tensionó el mercado, elevando los precios.
(Año base - 3)	Conflictos en Oriente Medio	Las tensiones en Siria e Irak aumentaron la prima de riesgo geopolítico.
(Año base - 2)	Guerra comercial entre 2 potencias mundiales	Las tensiones comerciales generaron alta volatilidad y menor expectativa de crecimiento.
(Año base - 2)	Sanciones de EE.UU. a Oriente Medio	La reducción del suministro proveniente del Oriente Medio impulsó temporalmente los precios por sobre los 80 USD/la unidad.
(Año base - 2)	Incremento de la producción en Oriente Medio	La mayor producción compensó el déficit generado previamente, corrigiendo los precios a la baja.
(Año base - 1)	Ataques a instalaciones del Activo en Oriente Medio	La interrupción de la producción elevó bruscamente los precios en septiembre.

(Año base - 1)	Desaceleración económica global	La menor expansión económica mundial redujo la demanda energética.
(Año base - 1)	Avances en negociaciones comerciales 2 Potencias mundiales	La expectativa de un acuerdo parcial contribuyó a una leve estabilización del mercado.
(Año base)	Guerra de precios entre Oriente Medio y Europa del Este	El desacuerdo en los recortes de producción provocó un colapso de los precios a comienzos de marzo.
(Año base)	Crisis Sanitaria y confinamientos globales	La caída sin precedentes en la demanda redujo el precio del Activo a mínimos cercanos a 20 USD/la unidad.
(Año base)	Acuerdos de la Agrupación de productores de la materia prima sobre reducción y previsiones de recuperación 2021	A fines de 2020 se proyectó una lenta recuperación del consumo impulsada por los programas de vacunación para la crisis sanitaria y los ajustes de producción.