



Universidad de Valladolid

Trabajo de Fin de Grado

Grado en Finanzas, Banca y Seguros

Título del Trabajo Fin de Grado: Aplicación de la Inteligencia Artificial en las Inversiones Financieras

Presentado por:

Carlos Ruiz Barón

Tutelado por:

Eleuterio Vallelado González

Valladolid, 31 de agosto de 2021

TABLA DE CONTENIDO

I.	RESUMEN	5
II.	ABSTRACT	5
1.	NACIMIENTO Y EVOLUCIÓN DE LA INTELIGENCIA ARTIFICIAL	6
2.	LA INTELIGENCIA ARTIFICIAL DENTRO DEL SECTOR FINANCIERO	8
2.1	Optimización de carteras.	9
2.2	Predicción bursátil mediante inteligencia artificial.....	15
2.3	Análisis del sentimiento financiero	19
2.4	Combinación.....	22
2.5	Conclusión de la inteligencia artificial en el sector financiero.....	24
3.	TIPOS DE SISTEMAS INTELIGENTES SUSCEPTIBLES DE USO EN EL SECTOR FINANCIERO....	24
3.1	Redes neuronales artificiales (ANN).....	27
3.2	Lógica difusa.....	28
3.3	Algoritmos genéticos (GA)	29
3.4	Aprendizaje automático (ML).....	30
4.	INVERSIÓN Y GESTIÓN EN PRESENCIA DE INTELIGENCIA ARTIFICIAL	32
5.	CONCLUSIÓN	39
6.	BIBLIOGRAFÍA.....	39

TABLA DE ILUSTRACIONES

Ilustración 1	Diagrama de flujo para la previsión financiera utilizando un modelo de Inteligencia Artificial.	16
Ilustración 2.	Red neuronal artificial de tres capas - Adaptado de Müller y Reinhardt (1990)...	28
Ilustración 3	Interpretación lógica difusa - Adaptado de Borba (2009).....	29
Ilustración 4	Espacio de solución (con la calidad de la solución en el eje vertical) – Adaptado Rafaely y Bennell (2006).....	30
Ilustración 5	Tipos de aprendizaje automático con ejemplos. - Adaptado de Milana y Ashta (2021).	31
Ilustración 6	Gráfico de rentabilidades (Promedio excluye MSCI World).....	46
Ilustración 7	Gráfico rentabilidad – volatilidad.....	47
Ilustración 8	Tendencia del incremento % de los flujos.....	49
Ilustración 9	Incremento % de Flujos y Rentabilidad a 4 semanas.	50
Ilustración 10	Incremento % de Flujos y Rentabilidad a 5 años.....	50
Ilustración 11	Gráfico del Dividendo a repartir.....	51
Ilustración 12	Gráfico del Rendimiento Anual por Dividendo.	52
Ilustración 13	Gráfico de la ratio PER.....	52
Ilustración 14	Gráfico evolución histórica ETFs, NASDAQ 100 y MSCI World (Base 100).....	55

TABLA DE TABLAS Y GRÁFICOS

Tabla 1	Tamaño y rendimientos de algunos fondos negociados en bolsa de IA	45
Tabla 2	Retornos tomando en cuenta la YTD de algunos fondos negociados en bolsa de IA	46
Tabla 3	Volatilidades en diferentes periodos y ratio Beta.	47

Tabla 4 Flujo de fondos de los ETF.	48
Tabla 5 Incremento porcentual de los Flujos de fondos de los ETF.	48
Tabla 6 Dividendos y ratio PER.	51
Tabla 7 Participaciones y Categoría de los ETFs.	53
Tabla 8 Composición QQQ, VGT, XLK, FDN y IYW.	53
Tabla 9 Composición de FTEC, IXN, QYLD, XT e IGM.	54
Tabla 10 Aspectos técnicos.	56

I. RESUMEN

La aplicación de la Inteligencia Artificial (IA) en la inversión financiera es un área de investigación que ha atraído una gran atención desde los años 90, cuando se produjo un acelerado desarrollo tecnológico. Desde entonces, se han propuesto innumerables enfoques para tratar el problema de la predicción de precios en el mercado de valores, como por ejemplo la optimización de carteras, predicción bursátil mediante IA, análisis de sentimientos financieros y combinaciones que implican dos o más enfoques. Un analista de IA construido para digerir la información financiera de las empresas, la divulgación cualitativa y los indicadores macroeconómicos es capaz de batir a la mayoría de los analistas humanos en las previsiones del precio de las acciones y generar un exceso de rentabilidad en comparación con el seguimiento de los analistas humanos.

II. ABSTRACT

The application of Artificial Intelligence (AI) to financial investment is an area of research that has attracted a great deal of attention since the 1990s, when technology development accelerated. Since then, countless approaches have been proposed to address the problem of price prediction in the stock market, such as portfolio optimisation, stock market prediction using AI, financial sentiment analysis, and combinations involving two or more approaches. An AI analyst built to digest company financial information, qualitative disclosure and macroeconomic indicators is able to beat most human analysts in stock price forecasting and generate excess returns compared to tracking human analysts.

1. NACIMIENTO Y EVOLUCIÓN DE LA INTELIGENCIA ARTIFICIAL

La inteligencia artificial (IA) es una disciplina con 70 años de historia, ya que surge a mediados del siglo XX, cuando empiezan a publicarse las primeras investigaciones sobre esta rama de la ciencia computacional. Alan Turing, científico británico que fue decisivo para descifrar los mensajes alemanes durante la Segunda Guerra Mundial, sentó las primeras bases en 1950 con un ensayo titulado “Maquinaria Computacional e Inteligencia” en el que pronosticó que en cincuenta años “se podrá hablar de máquinas pensantes”. Cinco años después, un matemático estadounidense, John McCarthy, acuñó la expresión “inteligencia artificial” para referirse a la nueva disciplina.

En estos últimos 70 años, la IA ha experimentado un gran desarrollo, pero su evolución no ha sido regular. Con fases de mucha efervescencia y grandes progresos y otras de indiferencia. A estos periodos de escepticismo y escaso progreso se les ha venido llamando inviernos de la inteligencia artificial. Alan Turing en su ensayo “Maquinaria Computacional e Inteligencia” publicado en la revista Mind en 1950 planteó la pregunta: ¿pueden pensar las máquinas? Turing elude responder directamente por la dificultad de definir lo que se considera máquina y lo que se considera pensar, y sustituye la pregunta inicial por un juego de imitación, el que luego sería conocido como test de Turing, esta prueba ha sido durante muchos años una referencia para medir el nivel de inteligencia humana de un dispositivo mecánico. En el juego intervienen tres participantes (uno que pregunta y dos que responden) y el interrogador debe decidir cuál de sus dos interlocutores es una persona y cuál es una máquina tras una conversación de cinco minutos. Si la máquina engaña al interrogador, aprueba el test y demuestra que en esas condiciones piensa o al menos se comporta como un ser humano. Durante la década de los 60 y los 70, y a pesar de la limitada capacidad computacional de la época, se consiguieron numerosos avances, como el primer chatbot funcional, “Eliza”, un software creado por el profesor de informática Joseph Weizenbaum, o las redes con backpropagation, con el método de cálculo del gradiente utilizado en algoritmos de aprendizaje supervisado utilizados para entrenar redes neuronales artificiales. En esta época nace un interés por el área de la traducción automática.

En cambio, desde 1975 hasta 1980, es considerado el primer invierno de la IA, las decepciones en áreas como la traducción automática, que habían despertado una gran expectación por su potencial utilidad en la Guerra Fría, y las dificultades en el uso de los llamados perceptrones (redes neuronales artificiales básicas) desinflaron la burbuja de la IA. Como resultado de ello, las ayudas públicas se redujeron o desaparecieron y los proyectos se estancaron.

Durante el surgimiento de la IA, en los primeros años, los proyectos estaban siendo orientados hacia lo que se denominó la IA fuerte (en inglés, general o strong), que trata de replicar la inteligencia humana, y que por tanto puede ser utilizada en múltiples actividades. Pero en los años 80, ante la dificultad de conseguir este objetivo, el interés se trasladó hacia la IA débil (en inglés, narrow o weak), abordando aplicaciones y sistemas en ámbitos tan concretos como la planificación financiera, el diagnóstico médico, la visión artificial, la exploración geológica o el diseño de circuitos microelectrónicos.

El segundo invierno de la IA, entre 1985 y 1995, estuvo marcado por una apatía investigadora e inversora motivada por los decepcionantes resultados de los programas puestos en marcha en distintos países del mundo. Muchas empresas quebraron y los sistemas expertos que se habían desarrollado empezaron a recibir críticas por parte de los especialistas. La más señalada fue la de John McCarthy, el matemático que bautizó la disciplina, que puso como ejemplo de mala práctica un sistema de asistencia médica que en determinadas circunstancias permitía matar las bacterias, pero no salvar la vida del paciente.

A finales del siglo XX y principios del XXI, surgen grandes avances gracias a la aplicación de métodos de ingeniería específica y a un incremento significativo de la potencia computacional, lo cual facilita el desarrollo de herramientas de investigación más sofisticadas. En 1997 el ordenador Deep Blue, desarrollado por IBM, se convirtió en la primera máquina en ganar al entonces campeón mundial de ajedrez, el ruso Garry Kasparov, lo cual tuvo un gran impacto en la opinión pública mundial. Ese mismo año, dos veinteañeros de la Universidad de Stanford, en California, crearon Google, que en los siguientes años haría revolucionar el mundo de la inteligencia artificial. Otro hito fue la carrera de coches autónomos organizada en 2005 por la agencia de Estados Unidos Darpa, en la que cinco vehículos consiguieron completar con éxito sus 212 kilómetros.

Herramientas imprescindibles para el desarrollo posterior de la IA también surgen en esta época como el lenguaje de programación Python y la librería de cálculo numérico de código abierto Numpy.

En 2004 Google publica un artículo que popularizó el modelo de programación e inspiró la creación en 2006 de Hadoop, un sistema de código abierto que permite trabajar con sistemas computacionales distribuidos para resolver problemas que requieren del análisis de grandes cantidades de datos. Esto hace posible gestionar cantidades enormes de información en un tiempo razonable y con un coste también razonable. Este es el inicio del Big Data. La disponibilidad de grandes cantidades de datos, la reducción de los costes de infraestructura y la mejora de la capacidad de los ordenadores son los tres factores clave que marcan un punto de inflexión. La conjunción de todos ellos permite industrializar técnicas avanzadas de machine learning (aprendizaje automático), así como el uso de redes neuronales cada vez más complejas.

Durante esta última época se han ido sucediendo los hitos tecnológicos en ramas concretas (la IA débil). Destaca la aparición de IBM Watson¹, la superación en 2014 del test de Turing por parte de una máquina que simulaba ser un adolescente, el auge de la realidad virtual o el lanzamiento en 2014 del asistente virtual Alexa, de Amazon. Además, gracias al crecimiento del código abierto aparecen librerías de software como TensorFlow y XGBoost, que permiten aprovechar las capacidades de los algoritmos de machine learning. Se han popularizado comunidades de análisis de datos como Kaggle, donde se comparte información para entrenar modelos de aprendizaje automático y en la que los usuarios compiten por encontrar el mejor algoritmo para resolver casos, estos casos son habitualmente financiados por empresas.

2. LA INTELIGENCIA ARTIFICIAL DENTRO DEL SECTOR FINANCIERO

La relevancia de la tecnología tanto para los ingresos como para los costes de una institución financiera han hecho de ella un componente esencial, siendo el sector financiero uno de lo más competitivos, en el que cualquier avance puede significar una ventaja competitiva diferenciadora. La relevancia de la tecnología

¹ Plataforma de Inteligencia Artificial para negocios, creada por IBM en 2011. Es una colección de servicios y habilidades que incluyen Machine Learning, razonamiento y decisiones tecnológicas; así como lenguaje, habla y visión tecnológica.

se evidencia con el nacimiento de las FinTech, que son todas aquellas actividades que impliquen el empleo de la innovación y los desarrollos tecnológicos para el diseño, oferta y prestación de productos y servicios financieros (Fintech e Insurtech, 2017). Estas empresas se caracterizan por realizar actividades de manera muy eficiente y transparente, brindando una excelente experiencia de usuario, utilizando siempre la tecnología para tal fin, con el objetivo de lograr una verdadera desintermediación en la cadena de valor de las industrias tradicionales (Fintech Spain, 2018).

A partir de la década de 1990, con la introducción de métodos computacionales en las finanzas, muchas investigaciones se han centrado en la aplicación de la Inteligencia Artificial en las inversiones financieras en el mercado de valores (Ferreira et al, 2021). Las principales ventajas de utilizar métodos computacionales para automatizar el proceso de inversión financiera incluyen la eliminación de la "irracionalidad momentánea" o de las decisiones tomadas en función de las emociones, la capacidad de reconocer y explorar patrones que los humanos pasan por alto y el consumo inmediato de información en tiempo real. Esta área de conocimiento se conoce como Finanzas Computacionales.

Más recientemente, dentro de las finanzas computacionales, está aumentando el uso y la investigación de las técnicas de IA aplicadas a las inversiones financieras. Aunque un ordenador realiza la gran mayoría de las operaciones de los fondos de inversión de forma automatizada, el 90% de estas operaciones se siguen realizando mediante un procedimiento codificado (Chang, 2018). Por lo tanto, la inteligencia artificial tiene un gran potencial de desarrollo.

En general, la IA se aplica a las finanzas en tres áreas diferentes: la optimización de carteras financieras, la predicción de precios o tendencias futuras de los activos financieros, y el análisis del sentimiento de las noticias o los comentarios de las redes sociales sobre los activos o las empresas.

2.1 Optimización de carteras.

La optimización de carteras, o selección de carteras, es un problema que consiste en determinar el conjunto de activos financieros que mejor se adapta a un inversor concreto, con el objetivo optimizar el binomio rentabilidad riesgo, en busca de maximizar beneficios.

La Teoría Moderna de Carteras, (Markowitz 1956), fue la primera contribución a los modelos de optimización de carteras. Markowitz introdujo dos métricas para evaluar el rendimiento de una cartera: la rentabilidad esperada y el riesgo. La rentabilidad esperada expresa la idea de que un activo que ha tenido un buen rendimiento en el pasado reciente tiende a mantener ese rendimiento en el futuro. Como previsión, el riesgo es la métrica propuesta para modelar la incertidumbre de la rentabilidad.

“El modelo de Markowitz considera las partes del presupuesto total de un inversor invertidas en cada activo. Considerando n activos disponibles, x_j ($j \in \{1, \dots, n\}$) es la proporción del capital total invertido en el activo j .

Así, existe una restricción que garantiza que la suma de las inversiones debe ser igual a el capital disponible para la inversión, o $\sum_{j=1}^n x_j = 1$. En el modelo inicial, no se permitía la venta en corto y, por tanto, $x_j \geq 0$, $\forall j \in \{1, \dots, n\}$.

El modelo utiliza una variable aleatoria R_j , cuya media es igual a $\mu_j = E(R_j)$, donde $E(R)$ es una función que devuelve el valor esperado de la variable aleatoria R .

Esta variable aleatoria está compuesta por T diferentes escenarios, en los que cada escenario t ($t = 1, \dots, T$) se produce con una probabilidad p_t , de modo que $\sum_{t=1}^T p_t = 1$. En cada escenario R_j asume un valor igual a r_{jt} . Así, el valor esperado de R_j puede determinarse mediante $\mu_j = \sum_{t=1}^T p_t r_{jt} = 1$.

En la práctica, la serie histórica de tasas de rendimiento de un activo representa sus escenarios. Considerando que cada escenario se produce con la misma probabilidad, el valor de la rentabilidad esperada de un activo j puede definirse como:

$$\mu_j = \frac{1}{T-1} \sum_{t=1}^T r_{jt}$$

donde r_j^t es la tasa de rentabilidad del activo j en el periodo comprendido entre $t-1$ y t de una serie histórica compuesta por T cotizaciones de j . Así, la rentabilidad R_x de una cartera X es la media ponderada de las rentabilidades de los activos que componen X , es decir, $R_x = \sum_{j=1}^n R_j x_j$ y la rentabilidad esperada de X se puede calcularse de la siguiente manera:

$$\mu(X) = E(R_x) = E\left(\sum_{j=1}^n R_j x_j\right) = \sum_{j=1}^n \mu_j x_j$$

Sin embargo, la mayor contribución del modelo de Markowitz es la introducción del concepto de riesgo de cartera, definido en su modelo como la varianza de los rendimientos históricos de una cartera con respecto a su valor esperado:

$$\sigma^2(Rx) = E\{(Rx - E(Rx))^2\}$$

La varianza de la cartera se define en función de los pares valores de correlación de los rendimientos de los activos que componen eso. Por tanto, la diversidad de la cartera tiende a reducir su riesgo. H. Markowitz (1956).

$$\sigma^2(X) = \sum_{i=1}^n \sum_{j=1}^n \sigma_{ij} x_i x_j$$

Por último, el modelo clásico de Markowitz para la optimización de carteras es:

$$\min \sum_{i=1}^n \sum_{j=1}^n \sigma_{ij} x_i x_j$$

▪ Sujeto a:

$$\sum_{j=1}^n \mu_j x_j \geq \mu_0$$

$$\sum_{j=1}^n x_j = 1$$

$$x_j \geq 0 \quad j = 1, \dots, n$$

Donde μ_0 es la rentabilidad mínima esperada en la cartera.”

La teoría de Markowitz se ha extendido mucho y se han introducido varios cambios en su propuesta original. El uso de la varianza de la cartera como medida de riesgo, por ejemplo, ha sido ampliamente criticado, ya que la varianza tiene en cuenta tanto las desviaciones negativas como las positivas. Luego, surgieron medidas de riesgo a la baja que sólo tienen en cuenta las peores rentabilidades históricas de las carteras (Rockafellar y Uryasev, 2002).

Numerosos trabajos han mejorado estos modelos, creando más medidas de riesgo y proponiendo restricciones que los acercan más cerca de los aspectos prácticos de la negociación bursátil. Existen varios métodos de optimización

exactos, heurísticos e híbridos para resolver estos modelos de optimización de carteras, que son cada vez más complejos (Gandomi et al, 2021). A continuación, se nombran una serie de trabajos de investigación que tratan de mejorar dichos modelos:

- M. G. Speranza en 1996, con su trabajo "Un algoritmo heurístico para un modelo de optimización de cartera aplicado al mercado de valores de Milán" propone un modelo de optimización de carteras de desviación media-absoluta (MAD) con el objetivo de minimizar la desviación absoluta (medida de riesgo). La rentabilidad esperada es la rentabilidad media de una serie histórica, y la restricción de rentabilidad mínima define su límite inferior. El modelo también considera una restricción de cardinalidad que limita el número de activos de la cartera a un límite superior.
- En 1999, R. Mansini y M. G. Speranza, en su trabajo, "Algoritmos heurísticos para el problema de selección de cartera con lotes mínimos de transacciones", hablan de un modelo de desviación media semi-absoluta que tenía como objetivo minimizar la desviación semi-absoluta como medida de riesgo, y la rentabilidad media está restringida a un valor de límite inferior. El modelo también considera la restricción de los lotes de transacción, y demuestra que esta restricción hace que el modelo sea NP²-completo³.

Aunque la primera medida de riesgo propuesta por Markowitz es la varianza, algunos de los primeros estudios sobre optimización de carteras intentaron utilizar otras medidas, como la Desviación Absoluta o la Desviación Semiabsoluta. También se consideraron otras restricciones para acercar el modelo a la realidad.

- Chang, Meade, Beasley y Sharaiha (2000) consideraron un modelo de Media-Varianza, en el que la varianza es la medida de riesgo a

² La teoría de la complejidad computacional es una rama de la teoría de la computación que se centra en la clasificación de los problemas computacionales de acuerdo con su dificultad inherente, y en la relación entre dichas clases de complejidad.

³ Se puede decir que los problemas de NP-completo son los problemas más difíciles de NP.

minimizar, y la rentabilidad media se limita a un valor de límite inferior. La cardinalidad⁴ de la cartera está limitada a un único valor.

Con el aumento de la complejidad de los modelos y considerando un mayor número de activos y una mayor serie histórica, los trabajos comenzaron a utilizar heurísticas en lugar de métodos exactos, ya que estos métodos resuelven modelos complejos en tiempo polinómico, como, por ejemplo:

- Zhu, Wang y Chen (2011) proponen el algoritmo de Optimización por Enjambre de Partículas (PSO) con operadores específicos y operadores de reparación para tres modelos de optimización monobjetivo diferentes: Modelo de media-varianza con restricción de retorno mínimo, modelo de función de utilidad de media-varianza usando factores de peso, y modelo de optimización de cartera de maximización de ratio de Sharpe.

Otra tendencia que se observó posteriormente es el uso de modelos multiobjetivo, ya que la elección de priorizar la rentabilidad o el riesgo depende del perfil de un inversor concreto. En un modelo multiobjetivo, se proporciona un conjunto de carteras no dominadas para poder elegir posteriormente la mejor cartera según el perfil del inversor. Algunos estudios enfocados en esta tendencia son:

- Zhang en 2012, aplicó el Algoritmo Genético y el Recocido Simulado a un modelo monobjetivo de optimización de carteras propuesto en el que el objetivo es una función de utilidad formada por la minimización de la varianza y la maximización de la diversidad de la cartera, y la restricción de rentabilidad mínima define un límite inferior para la rentabilidad media.
- En abril de 2018, Ertenlice y Kalayci, con su estudio sobre los algoritmos de inteligencia de enjambre aplicados a los modelos de optimización de carteras. Los algoritmos analizados son: PSO (Particle Swarm Optimization), BPO (Business Process Optimization), ACO (Ant Colony Optimization), ABC (Artificial Bee Colony), CSO (Cat

⁴ Indica el número o cantidad de los elementos de un conjunto, sea esta cantidad finita o infinita.

Swarm Optimization), FA (Firefly Algorithm), IWO (Improved invasive weed optimization), BA (Bat Algorithm) y FWA (Fireworks Algorithm). Estos modelos pretenden minimizar el riesgo sujeto a un rendimiento mínimo, cardinalidad y costes de transacción. Las medidas de riesgo consideradas son la varianza, la varianza con asimetría, la semivarianza, la desviación absoluta (MAD), el valor en riesgo (VaR), la rentabilidad mínima y el valor en riesgo condicional (CVaR).

Las principales restricciones de los modelos mencionados son; la restricción de rentabilidad mínima que define un límite inferior para la rentabilidad esperada de la cartera; la restricción de los lotes de transacción que garantiza el capital invertido en un determinado activo sea un múltiplo de un número mínimo de acciones; la restricción de cardinalidad limita el número de activos que pueden componer la cartera, la restricción de cardinalidad fija sólo permite un valor de cardinalidad para la cartera, mientras que la restricción de cardinalidad variable permite un rango de valores enteros para el número de activos en la cartera; los costes de transacción están relacionados con el comercio de activos en la Bolsa, algunos modelos de optimización de carteras consideran la restricción que garantiza que el coste total de la cartera, incluidos los costes de transacción, no puede superar el capital disponible para la inversión.

Los métodos de optimización pueden ser heurísticos, exactos o híbridos, cuando se utilizan ambos. También existe la posibilidad de utilizar algoritmos de aprendizaje automático (ML) para ayudar en el proceso de optimización. Los métodos a posteriori se utilizan a menudo para problemas multiobjetivo cuando se requiere la selección de una sola solución como los Multi-Attribute Utility Theory (MAUT).

Los modelos de optimización de carteras son cada vez más complejos, presentando más restricciones y, en algunos casos, varios objetivos. Así, se tiende a utilizar heurísticas para resolverlos ya que los métodos exactos no pueden resolver algunos modelos más complejos en tiempo polinómico. Un número más significativo de objetivos se deriva del creciente número de métricas

propuestas para representar el rendimiento y, principalmente, el riesgo de una cartera financiera.

2.2 Predicción bursátil mediante inteligencia artificial

La predicción o previsión bursátil mediante series temporales históricas se ha convertido en una técnica muy utilizada por los inversores para obtener beneficios financieros en la negociación de acciones. Estas predicciones, realizadas inicialmente por métodos estadísticos, se han ido realizando cada vez más por algoritmos de Inteligencia Artificial. Por lo tanto, la IA aplicada a las inversiones es una herramienta muy útil para ayudar a los inversores a obtener beneficios financieros.

Desde 1965, muchos investigadores han defendido la hipótesis de un mercado eficiente (Lo, 2007), que afirma que el mercado incorpora toda la información que tienen todos los participantes del mercado y sus expectativas, por lo que los cambios de precio son completamente aleatorios e impredecibles.

En contraste con la hipótesis del mercado eficiente, otros investigadores creen que los precios del mercado fluctúan con una tendencia. Teniendo en cuenta esta hipótesis, se pueden considerar dos escuelas de análisis de mercado:

1. El análisis técnico, que defiende las tendencias en los movimientos de los precios de las acciones y trata de predecirlas a través de los precios históricos de los activos.
2. El análisis fundamental, que sostiene que el contexto socioeconómico de una empresa interfiere en el precio futuro de sus acciones y, por tanto, proporciona información que puede utilizarse para pronosticar los precios futuros de los activos (Murphy, 1999).

El marco general de un modelo de predicción de Inteligencia Artificial aplicado a la previsión financiera se presenta en la ilustración 1. El primer paso es la adquisición de todos los datos necesarios para entrenar y probar el modelo de predicción. Estos datos pueden ser tratados, transformados o reducidos para eliminar la información ruidosa y resaltar la información importante. A continuación, el “predictor” utiliza los datos tratados para entrenar su modelo, en

el que sus parámetros pueden optimizarse en un paso de validación. Por último, el rendimiento del modelo entrenado con los parámetros ajustados debe evaluarse en una etapa de prueba.



Ilustración 1 Diagrama de flujo para la previsión financiera utilizando un modelo de Inteligencia Artificial.

Golan y Ziarko (1995) proponen un método de la Teoría de Conjuntos Rugosos que genera reglas para ayudar en las acciones de negociación en la Bolsa, que incluyen la compra, la venta y el mantenimiento de un activo. Este método utiliza indicadores fundamentalistas como datos de entrada.

Un año más tarde, Schierholt y Dagli (1996) propusieron una Red Neural Probabilística para predecir las tendencias de los movimientos de los precios financieros utilizando series históricas de precios de los activos. Se consideraron tres clases diferentes de tendencias, cada una de las cuales indica una acción diferente: comprar, mantener y vender un determinado activo.

Kim, Min y Han (2006) propusieron un Algoritmo Genético (GA) que selecciona las mejores ponderaciones para las predicciones de varios clasificadores y combinándolos en una sola predicción. Los clasificadores utilizan indicadores técnicos como variables de entrada y predicen las tendencias financieras considerando cuatro clases diferentes: Bear, Edged-Down, Edged-Up, y Bull.

Desde los primeros trabajos sobre predicción de tendencias de activos, ya se utilizaban algoritmos de Machine Learning (ML). También era común el uso de

heurísticas de optimización como los Algoritmos Genéticos (GA), especialmente para la combinación de diferentes algoritmos de clasificación.

Por ejemplo, Huang, Yang, y Chuang (2008) combinaron Support Vector Machine (SVM), Kth Nearest Neighbor (KNN), red neuronal Back-propagation, árbol de decisión y regresión logística utilizando un comité de votación después de realizar un método de selección de características envolvente. Utilizando datos de precios, volumen e índices técnicos para realizar una clasificación binaria de activos, el artículo concluye que la votación funciona mejor que los clasificadores individuales.

Cavalcante et al (2016), estudiaron los modelos de aprendizaje automático para la predicción del mercado de valores. Estudian primero las técnicas de preprocesamiento: normalización, exclusión de valores atípicos, agrupación y selección de características. Los modelos de previsión considerados son la Red Neural Artificial (RNA) y SVM. Los métodos de conjuntos que combinan ambos e integran los modelos mencionados anteriormente con heurísticos para predecir los precios futuros de los activos o las tendencias de los precios.

Una tendencia que se ha explorado cada vez más es el uso de técnicas complejas de preprocesamiento de los datos de entrada, que facilita la ejecución de los algoritmos de aprendizaje automático y aumenta su precisión, ya que los datos ruidosos tienden a ser eliminados, dejando sólo los datos más relevantes.

Recientemente, ha habido una tendencia creciente a aplicar redes neuronales profundas para la previsión bursátil. Por ejemplo, Zhong y Enke (2019), desarrollaron una Red Neuronal Profunda (DNN) para clasificar las tendencias futuras de los precios de los activos (considerando dos direcciones del precio siguiente). El conjunto de datos consiste en 60 atributos (incluyendo rendimientos e indicadores técnicos) de activos pertenecientes al ETF SPDR S&P 500 entre junio de 2003 y mayo de 2013, con frecuencia diaria. En comparación con una Red Neural Artificial (RNA), los resultados muestran que, aunque la DNN presenta una mayor precisión, la RNA proporciona mayores rendimientos y menores riesgos (varianza) en una simulación de negociación en Bolsa.

En el artículo, de Vignesh (2020), se recopilan los precios de apertura, cierre, mínimos y máximos de los activos de Yahoo y Microsoft desde enero de 2011 hasta diciembre de 2015 y calculó cinco indicadores técnicos con características de: impulso, volatilidad, impulso del índice, volatilidad del índice, impulso de la acción, volatilidad del precio de la acción. El artículo compara además los modelos SVM (Support Vector Machine) y LSTM (Deep Learning Long Short Term Memory) para el problema de la clasificación binaria de las tendencias bursátiles, y los resultados indican la mejor precisión del algoritmo LSTM.

Lin (2020), propone en una nueva Red Neuronal Convolutiva (CNN) bidimensional, que utiliza una matriz compuesta por futuros, opciones, precios de apertura, de cierre, altos y bajos, y el volumen de transacciones de cada activo en una serie temporal de 120 días de datos. Para ello, se utilizan 5 activos taiwaneses y 5 estadounidenses. La CNN propuesta se utiliza para predecir las tendencias del movimiento de los precios de los activos financieros. Considera tres clases diferentes: clase 1, para los días en que la rentabilidad supera el 1% (tendencia alcista), -1, para los días en que la rentabilidad es inferior al -1% (tendencia bajista) y 0, en caso contrario (movimiento lateral). La precisión del nuevo clasificador se compara con la de la SVM, la red neuronal y la CNN unidimensional y los resultados muestran que la nueva CNN supera a todos los demás clasificadores considerando cada uno de los 10 activos.

Para predecir los precios de los activos y sus tendencias, la gran mayoría de los métodos encontrados en la literatura emplean técnicas de aprendizaje automático. Las técnicas de regresión se utilizan habitualmente para la predicción de precios, mientras que las técnicas de clasificación se emplean con frecuencia para predecir las tendencias de los movimientos de los precios de los activos. Se identificó una cantidad creciente de datos utilizados como entradas o características, lo que implica la necesidad de utilizar métodos para seleccionar y preprocesar estos datos de entrada para filtrar sólo la información más esencial. Los métodos de aprendizaje profundo son otra tendencia que muestra resultados prometedores en trabajos recientes, a pesar de su gran complejidad computacional, lo que hace que la selección y el preprocesamiento de los datos sean aún más importantes.

2.3 Análisis del sentimiento financiero

El análisis de sentimientos es el campo de estudio que analiza los sentimientos y estados de ánimo de las personas hacia una entidad, como un producto, para evaluar si las opiniones son negativas o positivas y su grado de negatividad o positividad. Para realizar el análisis de sentimientos, primero es necesario recopilar un gran número de textos, como los extraídos de las redes sociales o los sitios web de noticias, escritos en un lenguaje natural. Por tanto, también es necesaria la aplicación de métodos de procesamiento del lenguaje natural (Liu, 2012). El análisis de sentimientos se ha aplicado cada vez más en varias áreas de conocimiento, como las finanzas computacionales.

En finanzas, varios investigadores comprueban el efecto de las noticias y las opiniones sobre los precios futuros de los activos, poniendo en jaque la hipótesis del mercado eficiente, basada en la idea de que las noticias y las opiniones guían a los inversores, creando tendencias en los precios del mercado y, por tanto, proporcionando posibilidades para que un inversor obtenga beneficios en las operaciones bursátiles (Ferreira, Gandomi y Cardoso, 2021).

Mittermayer (2004) recopiló prensa relacionada con acciones en NYSE o en el NASDAQ-AMEX, considerando sólo los comunicados de prensa de empresas con un volumen de negocio superior a 5.000.000 de dólares al día. El reprocesamiento de texto elimina las palabras vacías, los números y los términos menos significativos según la medida $TF \times IDF^5$. Estos comunicados de prensa se clasifican en "Buenas noticias", "Malas noticias" y "Sin movimiento" (para noticias neutras). Las buenas noticias provocan una subida del 3% en la cotización de las acciones en los 60 minutos siguientes al comunicado de prensa y aumentan la media de la cotización en al menos un 1% durante este intervalo. Las malas noticias provocan una bajada del 3% en la cotización de las acciones en los 60 minutos siguientes al comunicado de prensa y disminuyen la media de las cotizaciones en al menos un 1% durante este intervalo. Las demás noticias se clasifican como "Sin movimiento". Se aplicó un modelo SVM para predecir los precios de las acciones utilizando el sentimiento de las noticias y las series

⁵ Frecuencia inversa de documento, es una medida numérica que expresa cuán relevante es una palabra para un documento en una colección. Esta medida se utiliza a menudo como un factor de ponderación en la recuperación de información y la minería de texto.

históricas de precios. Los resultados muestran un recuerdo de aproximadamente el 60% y una mejor rentabilidad acumulada y media por operación que el operador aleatorio en una simulación bursátil.

Takahashi, et al (2006) analizaron 77.256 informes de analistas del servicio web de Thomson Financial relacionados con las empresas de la Bolsa de Tokio desde el 1 de enero de 2001 hasta el 31 de marzo de 2003. Se extrajeron 12 palabras clave del título de los informes obtenidos y se clasificaron en tres clases: Noticias buenas, malas y neutras. El cambio de la estimación mensual de beneficios de consenso para el próximo año fiscal (CESFY1) se utiliza como indicador numérico del rendimiento futuro de las acciones. Un modelo de aprendizaje automático utiliza una etiqueta de clasificación binaria según los cambios de previsión de beneficios mensuales: revisión al alza o a la baja para predecir los movimientos de las acciones. El rendimiento del modelo propuesto indica que el sentimiento está relacionado con los precios de las acciones 20 días antes y 20 días después de la prensa.

En relación con los trabajos que realizan análisis de sentimientos, se observa que los estudios más antiguos utilizaban noticias sobre un determinado activo para asignarle un estado de ánimo. Una desventaja de utilizar las noticias es que suelen ser más neutras, lo que dificulta la diferenciación entre las buenas y las malas, además de la menor cantidad, en relación con los comentarios en las redes sociales.

En 2013, Samilovic et al utilizaron un conjunto de datos de 1.600.000 (800.000 positivos y 800.000 negativos) tweets recogidos y etiquetados por la Universidad de Stanford. El paso de preprocesamiento eliminó nombres de usuario y enlaces, identificó apariciones de más de dos letras en una palabra y la cambió a una sola letra, dibujó palabras de negación explícitas, exclamaciones y signos de interrogación, además de realizar tokenización de texto, eliminación de palabras vacías se eliminaron las palabras que aparecieron solo una vez. Se aplicaron dos modelos de análisis de sentimiento. El primero clasifica los documentos en dos clases: negativo y positivo, mientras que el segundo los clasifica en tres categorías: negativo, neutral y positivo. El análisis de sentimientos presenta una precisión cercana al 80%. A continuación, el estudio analizó una correlación entre 152.572 tuits en los que se hablaba de información bursátil relevante sobre

ocho empresas en nueve meses de 2011 y los precios de cierre de las acciones de estas ocho empresas en el mismo periodo. Se realizó una prueba de hipótesis estadística para series temporales estacionarias con el fin de determinar el nivel de correlación lineal entre el sentimiento y el precio de cierre de las acciones y si uno contiene información predictiva sobre el otro (análisis de causalidad de Granger). Los resultados indican que el sentimiento de los tweets puede predecir los movimientos del precio de las acciones para varios activos, y la clase neutral introducida puede mejorar la correlación entre los tweets de opinión y el precio de cierre de las acciones en determinadas situaciones.

Allen et al (2019) asignaron puntuaciones de sentimiento diarias para el mercado DJIA mediante la acumulación de puntuaciones de sentimiento de alta frecuencia de los componentes del DJIA obtenidas del conjunto de datos TRNA desde enero de 2006 hasta octubre de 2012. Los componentes del DJIA se etiquetaron según tres clases: positiva, neutral o negativa (y una probabilidad asociada a cada una). A continuación, el sentimiento diario se calculó como la predicción media del sentimiento ponderada por las probabilidades de cada una de estas predicciones a corregir. El documento aplicó una regresión lineal y cuantifica a estas puntuaciones diarias, analizando su correlación con los precios de las acciones de la base de datos Thomson Tick History. Las regresiones consideraron los sentimientos diarios hasta 5 días antes de un precio determinado y ese precio. Los resultados demuestran que el sentimiento diario de las noticias financieras puede predecir los precios, ya que muestran una correlación significativa.

Estos trabajos desarrollan modelos de aprendizaje automático, Machine Learning, para predecir el sentimiento del activo utilizando textos recogidos de las noticias o de los comentarios de las redes sociales. También utilizan diccionarios de léxico que asignan valores de sentimiento basados en los textos recogidos. Además, emplean conjuntos de datos que contienen el valor del sentimiento asociado al texto. La investigación en el análisis del sentimiento bursátil suele poner a prueba el impacto de las noticias u opiniones en los precios de las acciones, desafiando la hipótesis del mercado eficiente. Para ello, se analiza la correlación entre el valor del sentimiento de una determinada empresa y el precio de sus acciones en un futuro próximo (unos días después de la publicación de la noticia o el comentario). Por último, utilizan estos valores de

sentimiento para predecir los precios o el movimiento de las acciones, con la intención de obtener beneficios en las operaciones bursátiles.

Se observa en estos análisis de sentimientos aplicados a las finanzas que se utilizan las noticias como datos de entrada. Sin embargo, se tiende a utilizar los comentarios en las redes sociales, lo que aumenta considerablemente el tamaño total de estos datos. Así, el preprocesamiento de estos datos y la selección de los términos más importantes se convierte en una tarea necesaria en este enfoque. El análisis de sentimiento aplicado a las inversiones financieras se utiliza habitualmente, en la práctica, para decidir si se compra o se vende un activo en estudio y, por tanto, se combina frecuentemente con el análisis histórico de los precios de estos activos. En esta combinación, el sentimiento predicho se utiliza como una de las características del algoritmo de Machine Learning para predecir el precio o la tendencia de movimiento del activo.

2.4 Combinación

Existen trabajos que combinan o integran dos o más enfoques, de los expuestos en los apartados anteriores de este trabajo; la optimización de carteras financieras, la predicción de precios o tendencias futuras de los activos financieros, y el análisis del sentimiento de las noticias o los comentarios de las redes sociales sobre los activos o las empresas; generalmente con el objetivo de mejorar el rendimiento de un modelo de aprendizaje automático o aumentar los beneficios proporcionados por las simulaciones de operaciones en el mercado de valores. Aunque la gran mayoría de los trabajos mencionados anteriormente utilizan un solo enfoque, muchos artículos, algunos de ellos descritos a continuación, indican mejores métodos combinados, estos trabajos son de más reciente elaboración.

Geva y Zahavi (2014) utilizaron indicadores bursátiles históricos y noticias para predecir los movimientos del mercado de valores, analizando 72 activos del S&P 500 desde el 15 de septiembre de 2006 hasta el 31 de agosto de 2007, recopilando precios históricos, volúmenes de negociación, mejores precios de compra y venta, además de 10 indicadores técnicos. El análisis de sentimiento clasifica cada documento de noticias como negativo o positivo, y se realiza una regresión lineal para asignar valores que indiquen cuán positiva o negativa es una noticia. Se utilizó un modelo de clasificación para predecir las posibilidades

de que un determinado activo supere una rentabilidad del 1% en el siguiente periodo. Para ello, se seleccionaron y utilizaron como características la polaridad de las noticias, los precios y los indicadores técnicos. Los resultados del trabajo muestran que la integración de datos de mercado con datos textuales contribuye a mejorar el rendimiento del modelo en comparación con el uso de sólo datos de mercado y que el uso de representaciones de datos textuales más avanzadas mejora aún más la predicción del modelo.

Xing et al, (2018) con su estudio, utilizaron los mensajes de opinión extraídos de StockTwits, el precio de cierre histórico y los volúmenes de negociación diarios de las acciones de la API de Quandl, y los datos de capitalización bursátil de Yahoo! Finance, del 14 de agosto de 2017 al 16 de noviembre de 2017. El documento propone el uso del análisis de sentimientos para crear opiniones de mercado, que posteriormente se utilizaron en el modelo de selección de activos de Black-Litterman⁶. Para el análisis de sentimiento, los documentos extraídos se analizaron y clasificaron utilizando una Red Neuronal Recurrente (RNN) compuesta por un método de clustering evolutivo (ECM) y una Red de Memoria a Largo Plazo (LSTM). Los resultados indican que el modelo propuesto supera a otros modelos Black-Litterman que no tienen en cuenta el análisis del sentimiento.

Azhikodan et al (2019) en su documento relatan la aplicación de un algoritmo de aprendizaje de refuerzo profundo y análisis de sentimiento en la previsión de las tendencias bursátiles. El modelo propuesto considera la información bursátil, el capital, los activos y la tendencia bursátiles pronosticada como entorno para el modelo de aprendizaje por refuerzo, mientras que las acciones del agente son comprar, vender y mantener activos. La predicción de la tendencia se realizó mediante una Red Neuronal Profunda Compuesta por una capa convolucional y una capa LSTM, que considera las noticias (representadas por la incrustación de texto) y los precios históricos de los activos como características.

⁶ Es un modelo matemático para la asignación de carteras desarrollado en 1990 en Goldman Sachs por Fischer Black y Robert Litterman, y publicado en 1992

2.5 Conclusión de la inteligencia artificial en el sector financiero

Para la optimización de carteras financieras, se puede comprobar una tendencia creciente en el uso de modelos multiobjetivo y métodos heurísticos. Así, los modelos son cada vez más complejos y se trabaja para que los métodos sean rápidos. Sin embargo, el número de trabajos que comparan estos modelos más complejos con modelos monobjetivo más básicos y con métodos exactos con heurística es todavía mínimo.

En cuanto a las previsiones que utilizan datos históricos de activos, los métodos de aprendizaje automático se están utilizando cada vez más en los últimos años. En concreto, se ha producido un aumento significativo de los métodos de Deep Learning, que ha dado resultados prometedores. Mientras tanto, existen grandes variaciones en las características utilizadas en los diferentes trabajos, incluyendo indicadores técnicos y fundamentalistas.

Los primeros trabajos sobre análisis de sentimientos aplicados a la inversión financiera emplearon las noticias como objeto de estudio. Debido a la popularización de las redes sociales, existe un gran número de comentarios sobre los activos financieros y sus empresas en Internet, que se está convirtiendo en la fuente de información más utilizada en este tipo de análisis. Sin embargo, son muy pocos los trabajos que consideran el uso de ambas fuentes (noticias y comentarios en las redes sociales).

La IA está potenciando la economía convencional como una alternativa más personalizada y avanzada. Estas alternativas son los mecanismos financieros, productos, modelos, servicios, sistemas y aplicaciones. Su objetivo es crear un campo de investigación integral, multidimensional y económico-financiero impulsado por el papel de la inteligencia artificial en las finanzas y la tecnología financiera de próxima generación, direcciones de investigación y oportunidades.

3. TIPOS DE SISTEMAS INTELIGENTES SUSCEPTIBLES DE USO EN EL SECTOR FINANCIERO

Se pueden identificar cuatro tipos de sistemas inteligentes comúnmente utilizados en contabilidad, auditoría y finanzas: redes neuronales artificiales, lógica difusa, algoritmos genéticos y aprendizaje automático. Un sistema debe

ser lo suficientemente inteligente como para ser útil en aplicaciones relacionadas con la contabilidad o las finanzas.

La mayoría de los problemas financieros no se pueden resolver fácilmente con técnicas convencionales. Algunos ejemplos son la predicción de quiebras y el desarrollo de estrategias rentables para operar en bolsa. En estos casos, una de las alternativas es el uso de sistemas de inteligencia artificial.

- Las redes neuronales artificiales (ANN) son algoritmos inspirados vagamente en ideas desarrolladas originalmente en la investigación sobre la naturaleza y el funcionamiento del cerebro. Se utilizan en tareas cognitivas, como el aprendizaje y la optimización. De las cuatro técnicas cuyas aplicaciones se analizan en este apartado (redes neuronales, lógica difusa, algoritmos genéticos y aprendizaje automático), ésta es la más antigua. El primer artículo que presentó las redes neuronales artificiales fue publicado por McCulloch y Pitts en 1943, con el nombre de "A Logical Calculus of the Ideas Immanent in Nervous Activity". Las redes neuronales pueden "entender" por sí mismas las características de un problema, utilizando para su aprendizaje un conjunto de ejemplos cuyo resultado es esperado y las salidas ya son conocidas (Müller y Reinhardt, 1990).
- El concepto de lógica difusa fue introducido por Lofti Zadeh en 1965 como forma de reducir y explicar la complejidad de algunos sistemas (Cox, 1998). Esta idea fue casi desconocida para la mayoría del público hasta finales de los años 80, cuando el metro de Sendai adoptó un sistema basado en la lógica difusa, Automatic Train Operator (ATO), y se crearon muchas empresas con el objetivo de desarrollar productos basados en esta tecnología. La atención inicial sobre este tema disminuyó, pero todavía es posible encontrar aplicaciones de la lógica difusa en áreas muy diferentes a las originales, como la contabilidad y las finanzas.
- Según Nanda y Pendharkar (2001) los algoritmos genéticos son métodos de búsqueda paralela que comienzan con un conjunto de soluciones posibles y, mediante operadores especiales (evaluación, selección, cruce y mutación), evolucionan hacia soluciones más prometedoras. Según Nunez-Letamendia (2002) estos algoritmos se inspiran en la evolución

biológica, la selección natural y la genética. Se basan en una función que evalúa la calidad de una solución dada al problema, y esta función puede obtenerse incluso para problemas que son difíciles de resolver con las técnicas convencionales.

- El aprendizaje automático (ML) es un tipo de inteligencia artificial (IA) aplicada que permite a los sistemas informáticos aprender de los datos u observaciones, y mejorar automáticamente la predictibilidad utilizando el aprendizaje continuo. Por lo general, aparece en la disciplina de la informática, pero puede aplicarse en disciplinas como las ciencias sociales, las finanzas, la contabilidad y la banca, la investigación de marketing, la investigación de operaciones y las ciencias aplicadas. Utiliza técnicas de cálculo intensivo, como el análisis de aglomerados, la reducción de la dimensionalidad y el análisis de vectores de apoyo. El ML ha experimentado un aumento de reconocimiento entre académicos, investigadores y profesionales en las últimas dos décadas debido a su capacidad para ayudar a predecir con mayor precisión.

Estos métodos de inteligencia artificial tienen múltiples usos. La capacidad de reconocer patrones que presentan las redes neuronales artificiales puede utilizarse en problemas que van desde la detección del cáncer de mama (Übely, 2007) hasta la fijación de precios de los derivados financieros (Montagna et al, 2003). Dentro de las muchas aplicaciones en finanzas, algunas de ellas, a modo de ejemplo son: la previsión de precios de las acciones, el análisis de créditos y la predicción de quiebras.

Las redes neuronales artificiales y los algoritmos genéticos son modelos que requieren poco conocimiento para ser resueltos. Por el contrario, la lógica difusa se puede utilizar para varios problemas en los que las variables no se pueden describir con claridad. Debido a esta flexibilidad, hay más de una forma de resolver varios problemas en este campo. Esta flexibilidad se debe, al menos en el caso de las ANN y los algoritmos genéticos, a que estos modelos requieren poco conocimiento sobre el problema a resolver. Y, al ser una forma de describir la incertidumbre, la lógica difusa puede utilizarse en diversos problemas en los que las variables no pueden describirse con claridad.

3.1 Redes neuronales artificiales (ANN)

Este método utiliza unidades básicas (neuronas) para construir redes en las que cada unidad recibe entradas de otras neuronas. Todas las entradas se multiplican por su respectivo peso sináptico⁷. La suma de estas entradas multiplicadas es transformada por una función de activación antes de ser enviada a las neuronas de la capa siguiente (Calderón y Cheh, 2002).

Para que una ANN sea útil, es necesario entrenarla. El proceso de aprendizaje encuentra el mejor peso sináptico para cada neurona, de forma que la salida de las neuronas de la última capa se acerque lo más posible a la respuesta correcta para el problema.

La ilustración 2 muestra una ANN feed-forward de tres capas, también conocida como perceptrón. La capa superior es la de entrada y recibe dos variables del entorno. La capa inferior es la capa de salida. Las capas intermedias (en este ejemplo sólo hay una) se denominan llamadas capas ocultas. Una ANN con la arquitectura sencilla como la presentada en la imagen puede utilizarse para resolver problemas como la operación booleana XOR⁸ (or exclusivo).

El uso generalizado y la utilidad de las redes neuronales artificiales se pueden explicar por su capacidad de aprender utilizando datos de entrenamiento (ejemplos) y luego generalizar los patrones encontrados, aplicándolos a datos fuera del conjunto de entrenamiento. Esto hace que las ANN sean especialmente útil en problemas que no se conocen con gran detalle, e incluso pueden tratar con datos que contienen distorsiones, ruido y datos irrelevantes (Hwang y Lin, 2000).

⁷ El peso sináptico define la fuerza de una conexión sináptica entre dos neuronas

⁸ Se le denomina la compuerta de "algunos, pero no todos", su expresión Booleana es una suma binaria de un dígito cada uno y el resultado obtenido será la salida.




Ilustración 2. Red neuronal artificial de tres capas - Adaptado de Müller y Reinhardt (1990).

3.2 Lógica difusa

En la lógica convencional (binaria), un elemento pertenece o no a un conjunto determinado, y nunca está entre estos estados posibles. Aunque puede simplificar las situaciones complejas, se le acusa de distorsionar la realidad (Grint, 1997). La lógica difusa permite representar estados inciertos de forma más sencilla: en lugar de pertenecer o no al conjunto un elemento puede tener varios grados de asociación con él.

Los conjuntos difusos son funciones que asignan, en una escala de cero a uno, la asociación de un elemento al conjunto. El cero significa que el elemento no pertenece al conjunto, mientras que el uno significa que el elemento pertenece plenamente al conjunto. Los valores entre cero y uno indican grados intermedios de pertenencia.

La ilustración 3 muestra dos gráficos: el de la izquierda es un conjunto clásico, mientras que el de la derecha es un conjunto difuso, ambos evaluando un producto en función de su coste. En el conjunto clásico, un producto que cuesta 50 dólares pertenece al conjunto de productos caros, pero uno que cuesta 40 dólares no. Hay una discontinuidad en el punto en el que el producto se convierte en caro.




Ilustración 3 Interpretación lógica difusa - Adaptado de Borba (2009).

En el conjunto difuso, se muestra una situación en la que la transición entre ser barato o caro se realiza de forma gradual, a través de la lógica difusa. Ahora un producto que cuesta 45 dólares es razonablemente caro, y un producto que cuesta 30 dólares no es tan caro. Existen infinitas posibilidades de que se sitúe entre 0 y 1, lo que hace que esta función sea más intuitiva y realista.

Es posible ejecutar varias operaciones utilizando la lógica difusa. Las más comunes son la unión, la intersección y el complemento. Con las reglas de inferencia (políticas), es posible crear modelos que ayuden a la toma de decisiones.

3.3 Algoritmos genéticos (GA)

El funcionamiento básico de un algoritmo genético fue descrito por primera vez en los años 70 por John Holland, y sus primeras aplicaciones fueron en ingeniería. Para buscar soluciones óptimas, los GA generan primero un conjunto de soluciones aleatorias para el problema en cuestión, y luego calculan la calidad de cada una de estas soluciones mediante una función de evaluación. A continuación, mediante un mecanismo de reproducción, estos algoritmos combinan las mejores soluciones, originando otras nuevas que posiblemente sean más adecuadas que las primeras. El nuevo conjunto de soluciones se evalúa a continuación. Los procedimientos de reproducción y evaluación se repiten hasta que el conjunto de soluciones no pueda mejorarse más.




Ilustración 4 Espacio de solución (con la calidad de la solución en el eje vertical) – Adaptado Rafaely y Bennell (2006).

Este proceso se muestra en la ilustración 4, que representa todas las soluciones posibles para un problema en el eje horizontal, y la calidad de cada una de estas soluciones en el eje vertical. Se genera aleatoriamente un conjunto de soluciones y se espera que, a través de un GA, algunas de estas soluciones converjan gradualmente al punto A, llamado máximo global. Existe el riesgo de que, en lugar de converger a este punto, lo hagan al punto B, llamado máximo local. Este riesgo, sin embargo, puede minimizarse mediante la adopción de estrategias que mantengan el conjunto de soluciones heterogéneo.

Los algoritmos genéticos son adecuados para explorar un amplio espacio de soluciones, partiendo de una simple muestra de valores aleatorios (la población inicial). La evolución se produce de forma que los cromosomas más prometedores sobreviven y mejoran, convirtiéndose finalmente en soluciones aceptables para el problema (Rafaely y Bennell, 2006).

3.4 Aprendizaje automático (ML)

El ML se basa en las matemáticas, la teoría de la probabilidad y la estadística. Como se muestra en la ilustración 5, incluye el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje por refuerzo. El aprendizaje supervisado utiliza datos etiquetados y retroalimentación si el resultado es correcto. En cambio, el aprendizaje no supervisado debe encontrar su estructura o patrones a partir de datos no etiquetados, y el sistema puede aprender por sí mismo. El aprendizaje por refuerzo permite que la estructura aprenda para un entorno en línea, y la asignación de créditos se basa en mensajes positivos y negativos (Boden, 2018; Li et al., 2018). El aprendizaje por refuerzo podría ser beneficioso en la negociación de valores que requieren un reequilibrio constante de las carteras (Luo et al, 2019).

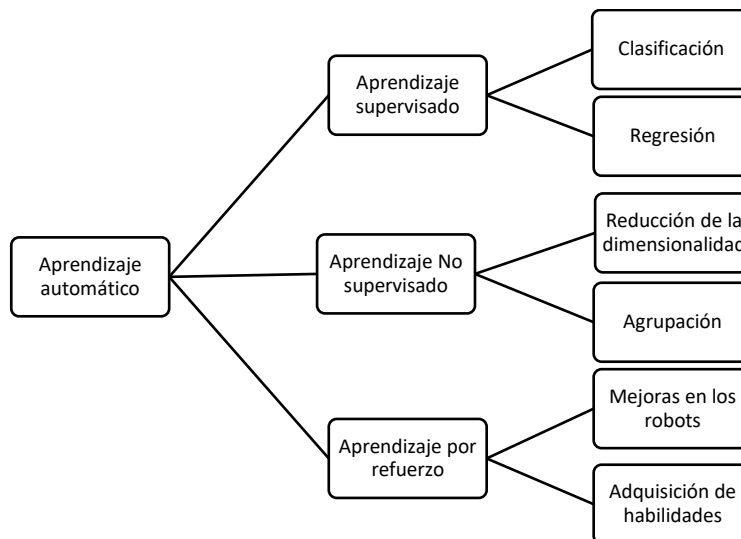


Ilustración 5 Tipos de aprendizaje automático con ejemplos. - Adaptado de Milana y Ashta (2021).

El análisis de datos permite reagrupar y analizar la información que se encuentra en diversos lugares en formatos no estructurados utilizando IA y ML. Este procedimiento podría ayudar a los bancos a mejorar la gestión de sus relaciones con los clientes, prevenir la detección de fraudes y cumplir con los requisitos de información contable o legal (González Carrasco et al, 2019). Del mismo modo, el Internet of Things (IoT), el ML y la IA están ayudando a la gestión de la cadena de suministro al reagrupar los datos en diversos lugares y aumentar la eficiencia de las finanzas de la cadena de suministro (McCrea, 2019). El uso de datos masivos que permite el IoT debe sopesarse con las necesidades de privacidad y seguridad de cada usuario, lo que indica que la inteligencia debe separarse de los datos, y esto se está haciendo mediante el ML Federado (Yang et al., 2020). El aprendizaje federado o colaborativo permite aprender de varias fuentes sin intercambiar información. Así, los datos de varios actores de la cadena de suministro pueden utilizarse para el aprendizaje sin revelar los datos.

La capacidad de utilizar datos no estructurados también significa que los contratos complicados pueden ser digitalizados y luego analizados o estructurados. Por ejemplo, los contratos de arrendamiento son largos y específicos para cada uno de ellos. Sin embargo, si se pueden digitalizar, se puede utilizar el ML para mejorar la eficiencia de la recuperación de datos en un formato estructurado. Así, ayudaría a que los bienes inmuebles corporativos se

conviertan en una clase de activos de alta velocidad, de baja fricción, y orientados a los datos (McGrath et al, 2019).

Una aplicación más directa del ML a los mercados financieros es el diseño de un procedimiento de selección de carteras en línea (Bin y Hoy, 2014). La selección de carteras en línea es un problema de decisión secuencial. Existen varios enfoques, como los puntos de referencia, los enfoques Follow-the-Winner, los enfoques Follow-the-Loser, los enfoques basados en Pattern-Matching y los algoritmos de Meta-Learning. Estos enfoques permiten elegir el algoritmo adecuado.

4. INVERSIÓN Y GESTIÓN EN PRESENCIA DE INTELIGENCIA ARTIFICIAL

La importancia de la previsión ha sido subrayada por los investigadores durante mucho tiempo, especialmente desde que el medio ambiente se volvió más volátil y turbulento (Duus, 1999). El desarrollo de la tecnología de la información para la previsión sólo puede desarrollarse si la organización tiene información sobre los indicadores. No obstante, las previsiones se basan en acontecimientos pasados y no pueden incorporar fácilmente toda la información pertinente, especialmente la información no estructurada. Si la IA combinada con el análisis de datos pudiera ayudar a hacer mejores pronósticos, sin duda ayudaría a los inversores. Lo que es particularmente importante para los inversores es el problema del tiempo: los datos en el pasado no ocurren con frecuencia regular, y el futuro también es difícil de predecir en cuanto al tiempo.

Según un reciente artículo del Financial Times (25 de enero de 2021), los propietarios de capital privado a menudo tienen prisa por transformar las empresas analógicas en empresas que se han modernizado completamente utilizando la tecnología. Así, en su estrategia de añadir valor, seleccionan empresas digitalmente analógicas y les ayudan a utilizar tecnologías como la IA y la analítica de datos. Esto no es sólo para reemplazar a los hombres con máquinas, sino también para descubrir qué servicios necesitan los clientes y cómo entregarlos mejor.

Esta prisa por adoptar la IA está correlacionada con el auge de las acciones relacionadas con la IA, lo que indica las expectativas de los inversores de esta

tecnología. La tabla 1 muestra los resultados de Exchange Traded Funds (ETF⁹s) de valores de IA, Los ETF de Inteligencia Artificial son fondos que cumplen al menos uno de los siguientes tres criterios:

- Son fondos que invierten específicamente en empresas implicadas en el desarrollo de nuevos productos o servicios, mejoras tecnológicas en la investigación científica relacionada con la inteligencia artificial, o
- Son fondos que tienen al menos el 25% de la exposición de la cartera a empresas que gastan grandes cantidades en gastos de investigación y desarrollo (I+D) de inteligencia artificial. Ejemplos de tales compañías son Amazon, Tesla Motors, Apple y Alphabet, o,
- Son fondos que utilizan metodologías de inteligencia artificial para seleccionar valores individuales para su inclusión en el fondo.

Estos fondos promedian rendimientos anuales del 14-15%, dependiendo de si el promedio es simple o ponderado. El valor total de los activos es de 337 mil millones de \$, lo que indica que hay una atracción considerable para esta clase de activos. Estos resultados validan la importancia de la investigación sobre la IA en general y el uso de la IA en los mercados financieros en particular.

Se puede plantear la cuestión de qué sería mejor para predecir la evolución de ETFs que un paseo aleatorio (hipótesis de mercado eficiente). Se-Hak y Kim (2004) mostraron que el error de previsión era menor en el Razonamiento basado en Casos (CBR), seguido de ANNs, pero ambos eran mejores que la hipótesis de paseo aleatorio sin cambios. También demostraron que es mejor crear varios puntos intermedios y utilizar las previsiones iteradas en lugar de predecir el valor final de un salto.

La IA se ha utilizado para construir indicadores para predecir los sentimientos de los inversores, que pueden influir en el precio de los activos. Los inversores no son totalmente racionales y es más probable que se vean afectados por factores psicológicos a la hora de tomar decisiones. Por ejemplo, Ruan et al. (2020) han construido un indicador del sentimiento de los inversores utilizando ML profundo

⁹ Fondo de inversión cotizado, es un fondo de inversión cuya principal característica es que se negocia en mercados de valores secundarios.

para pronosticar los rendimientos del mercado de valores asumiendo que los sentimientos de los inversores pueden afectar en gran medida a los precios de los activos. Esta técnica supera a otros predictores ampliamente reconocidos y puede funcionar bien en comparaciones transversales entre sectores. La IA puede estimar directamente el sentimiento de los inversores sin estar sujeta a interferencias o a los errores de aproximación habituales.

Muchos investigadores tratan de hacer predicciones a largo plazo. Sin embargo, estas pueden ser menos importantes que las predicciones a corto plazo basadas en las cuales los gerentes pueden alterar el próximo corto plazo (Millner y Heyen, 2021). Este resultado se relaciona con el enfoque de opciones reales, que reconoce el valor de la espera para ejercer opciones como el abandono y la inversión en fases (Copeland y Tufano, 2004; Luehrman, 1998; Van Putten y MacMillan, 2004). "Si bien las mejoras en las predicciones a largo plazo a menudo requieren nuevos enfoques científicos que reduzcan los errores de especificación errónea del modelo, las predicciones a corto plazo a menudo se pueden mejorar sustancialmente simplemente reduciendo los errores de medición en condiciones iniciales (es decir, aumentando la calidad de las observaciones)". (Millner y Heyen, 2021). Si las prescripciones a corto plazo son bastante fiables utilizando técnicas estadísticas y econométricas, entonces el valor añadido del uso de la IA puede ser solo para que dichos modelos pueden estar dando soluciones en tiempo real más rápido, lo que permite que los pronósticos se actualicen en tiempo real. Petrelli y Cesarini (2021) recomiendan el uso de la IA para pronosticar precios de activos de alta frecuencia.

La tabla 1 nos muestra una visión general de los fondos seleccionados, están ordenados por volumen gestionado en \$ encontramos fondos de gran tamaño como QQQ, VGT y XLK... Para simplificar el análisis nos vamos a centrar en los 10 fondos con mayor volumen de activos gestionados: Invesco QQQ Trust (QQQ), Vanguard Information Technology ETF (VGT), Technology Select Sector SPDR Fund (XLK), First Trust Dow Jones Internet Index Fund (FDN), iShares U.S. Technology ETF (IYW), Fidelity MSCI Information Technology Index ETF (FTEC), iShares Global Tech ETF (IXN), iShares Exponential Technologies ETF (XT), Global X NASDAQ 100 Covered Call ETF (QYLD) y iShares Expanded Tech Sector ETF (IGM). Estos 10 fondos suman 336 miles de millones de \$, de

activos gestionados, para ponerlo en contexto el PIB de Dinamarca en el año 2019 es de 350,1 miles de millones de \$.

En tabla 2, se observan las rentabilidades históricas de estos fondos a 1 semana, 1 mes, 1 año, 3 años y 5 años. A corto plazo, entendiendo el corto plazo como el periodo de tiempo inferior a un año (1 semana y 1 mes) las rentabilidades oscilan entre -2,54% y 3,17%; datos que no destacarían en comparación con ETFs de gestión tradicional. En cambio, en el largo plazo, las rentabilidades a 3 años están por encima del 75% (excepto el fondo QYLD, 27,15%) y a 5 años el rendimiento medio de los 10 fondos se sitúa en el 224,23% de media cuando el MSCI World¹⁰, índice que usaremos para comparar dichos fondos con la evolución del mercado mundial, retorna en los últimos 5 años una rentabilidad del 99,245%.

La volatilidad es la fluctuación de la rentabilidad de una acción respecto a su media en un espacio de tiempo determinado, en nuestro análisis tomamos como referencia 5, 3, 1 años y 4 y 1 semanas. La volatilidad del mercado se mide hallando la desviación estándar entre las variaciones de los precios durante un periodo de tiempo determinado. El concepto estadístico de desviación estándar permite ver cuánto difiere su valor medio. Así, cuanto más alta sea la desviación estándar, más se moverá esa cartera, hacia arriba o hacia abajo de la media. Recordemos que la volatilidad de una cartera no es la suma de las volatilidades de los activos que la componen, depende de la relación existente entre dichos activos. Analizando los datos de la tabla 3 y la correspondiente ilustración 7 con el gráfico “Análisis rentabilidad – riesgo”, observamos que las volatilidades de los distintos fondos a muy corto plazo son superiores al 50%, en cambio con el aumento del horizonte temporal se sitúan no superiores al 15% de media. La ratio Beta, nos indica que las volatilidades en 8 de los 10 fondos son superiores al índice de referencia ($\beta > 1$), por lo tanto, tienen mayor riesgo sistemático que el mercado, aunque el promedio de los 10 ratios Beta es 1, por lo tanto los fondos seleccionados replican los índices de referencia.

¹⁰ Siglas de Morgan Stanley Capital International y refleja el desarrollo de las empresas con mayor capitalización bursátil de 23 países desarrollados.

Los flujos de fondos, medidos en las tablas 4 y 5, son también conocidos como flujos de activos o simplemente "flujos", miden el movimiento neto de efectivo dentro y fuera de los vehículos de inversión. Los flujos de fondos no reflejan el rendimiento de la inversión, solo la forma en que los inversores mueven su dinero. Las salidas reflejan rescates de acciones, o cuando los inversores sacan su dinero de los fondos, mientras que las entradas reflejan las compras de acciones. Los flujos de fondos son una ventana al comportamiento de los inversores y a menudo se consideran un indicador del sentimiento de los inversores. Las entradas pueden sugerir que los inversores son optimistas sobre los posibles rendimientos futuros, mientras que las salidas sugieren que los inversores son más cautelosos. Sabiendo esto se observa que la tendencia de los flujos de estos fondos es positiva, estos fondos han ido acumulando activos en sus carteras debido al aumento de inversores interesados en estas oportunidades de inversión tratando de buscar rentabilidad a sus capitales. Teniendo la mayoría de los fondos incrementos porcentuales a 5 años de más del 19%.

Los fondos de inversión con reparto de dividendos invierten en compañías que ofrecen este tipo de incentivos a sus inversores. Dicho de otra forma, utilizan los dividendos para aumentar el capital del fondo y poder aumentar el nivel de inversiones realizadas. Los 10 fondos seleccionados reparten dividendos entre los \$0,35 y los \$2,61 dichos datos lo podemos observar en la tabla 6. El rendimiento anual por dividendo es uno de los factores usados para valorar las acciones de una determinada empresa y en nuestro caso un ETF. Esta rentabilidad se muestra en porcentaje, que especifica la relación entre los dividendos que se han repartido anualmente por cada participación del fondo, y el coste que tiene esa participación. A excepción del fondo QYLD, que tiene un rendimiento anual por dividendo del 11,72%, el resto de los fondos no tiene rendimientos elevados ya que ningún fondo supera el 1,5% de rendimiento anual de dividendos.

La tabla 6 contiene los valores de los ratios PER de los fondos analizados. El ratio PER es uno de los ratios financieros más utilizados en el análisis fundamental. Nos indica si la acción de una empresa está sobrevalorada o

infravalorada, para llegar a esta conclusión debemos tener en cuenta el PER sectorial, tomaremos como referencia la media del PER de los 46 ETFs que componen la lista original (29,4387). Un PER elevado, generalmente por encima de 25, puede indicar dos cosas. Por un lado, puede indicar que el fondo esté sobrevalorado, pero por otro lado puede indicar que los inversores estiman que los beneficios del fondo van a subir en los próximos años.

La composición de estos fondos, analizada en las tablas 7, 8 y 9, obviamente está protagonizada por empresas implicadas en el desarrollo de nuevos productos o servicios, mejoras tecnológicas en la investigación científica relacionada con la inteligencia artificial, como hemos explicado anteriormente. Podemos observar que existe cierta concentración de activos, ya que el porcentaje de activos que componen los diez activos principales supera el 50% en 9 de los 10 ETFs seleccionados. Las empresas que protagonizan estos tops 10, son grandes tecnológicas como Apple y Microsoft, pioneras en el desarrollo y apuesta por la IA. También se atiende al criterio de ETFdb.com, para clasificar los ETFs según su composición:

- Renta variable de alta capitalización (Large Cap Growth Equity): Invierten en acciones de empresas de crecimiento que se consideran de gran tamaño, generalmente con una capitalización de mercado de 10.000 millones de dólares o más (QQQ¹¹, FDN¹², XT¹³ y QYLD¹⁴).
- Renta variable de acciones tecnológicas (Technology Equities): Ofrecen exposición a los valores del sector tecnológico. Los valores tecnológicos tienden a tener un poco más de volatilidad que otros sectores, ya que tienen un perfil de rentabilidad-riesgo más elevado (VGT¹⁵, XLK¹⁶, IYW¹⁷, FTEC¹⁸, IXN¹⁹ y IGM²⁰).

¹¹ Invesco QQQ Trust

¹² First Trust Dow Jones Internet Index Fund

¹³ iShares Exponential Technologies ETF

¹⁴ Global X NASDAQ 100 Covered Call ETF

¹⁵ Vanguard Information Technology ETF

¹⁶ Technology Select Sector SPDR Fund

¹⁷ iShares U.S. Technology ETF

¹⁸ Fidelity MSCI Information Technology Index ETF

¹⁹ iShares Global Tech ETF

²⁰ iShares Expanded Tech Sector ETF

La evolución histórica de estos fondos, reflejada en la ilustración 12, ha sido positiva, como hemos comentado antes los diez fondos promedian a 5 años una rentabilidad del 224,23%, evolución similar obtiene el NASDAQ 100 debido a que es un índice indicador del comportamiento de la industria tecnológica y asimismo del sentimiento inversor respecto a acciones de carácter más especulativo. Es uno de los índices bursátiles más seguidos en los Estados Unidos y suele ser uno de los tres índices "principales" que los comentaristas del mercado citan a menudo, junto con el promedio industrial Dow Jones y el S&P 500. Debido a que el NDX100 tiene una alta concentración de empresas en el sector de la tecnología. El NDX100 a menudo se considera un buen barómetro de lo bien que está funcionando el mercado tecnológico. En cambio, el MSCI World, obtiene peores datos ya que tiene como objetivo reflejar el 85% de la capitalización de mercado de cada uno de los 23 países que le componen, y lo hace comprando las empresas más grandes de cada país, tiene como ventaja la gran diversificación, ya que no es un índice temático y solo tiene en cuenta la capitalización de la empresa para ser incluida en el índice. Por lo tanto, la gran exposición de los fondos seleccionados a empresas implicadas en el desarrollo de nuevos productos o servicios, y mejoras tecnológicas en la investigación científica relacionada con la inteligencia artificial, se han beneficiado enormemente de estas tendencias estos últimos años, convirtiendo estos fondos en una buena alternativa en el mercado.

Para terminar, un básico análisis técnico recogido en la tabla 10. El RSI es un oscilador de impulso que mide la velocidad y el cambio de los movimientos del precio en el mercado. El RSI oscila entre 0 y 100 (Cannessa, 2019). Tradicionalmente, y según J. W. Wilder (1978), el RSI se considera en condición de sobrecompra cuando está por encima de 70 y en condición de sobreventa cuando está por debajo de 30. Los fondos seleccionados, todos ellos están más próximos de la condición de sobrecompra que sobreventa, es decir indica que el precio del fondo en particular es más alto que su valor intrínseco. Las bandas de Bollinger vienen a refutar lo anteriormente explicado, ya que los operadores creen que cuanto más se mueven los precios a la banda superior, más sobrecompra el mercado, y cuanto más se mueven los precios a la banda inferior, más sobrevendido está el mercado.

5. CONCLUSIÓN

Un analista de IA construido para digerir la información financiera de las empresas, la divulgación cualitativa y los indicadores macroeconómicos es capaz de batir a la mayoría de los analistas humanos en las previsiones del precio de las acciones y generar un exceso de rentabilidad en comparación con el seguimiento de los analistas humanos. En la competición "hombre contra máquina", la ventaja relativa del "analista IA" es mayor cuando la empresa es compleja y cuando la información es de alta dimensión, transparente y de gran volumen. Una cartera que sigue la diferencia entre las previsiones de la IA y las de los analistas genera un exceso de rentabilidad mensual de más de 60 puntos básicos (Cao, 2021). Los analistas humanos siguen siendo competitivos cuando la información crítica requiere conocimientos institucionales (como la naturaleza de los activos intangibles). La ventaja de la IA sobre los analistas humanos disminuye con el tiempo cuando los analistas obtienen acceso a datos alternativos y a recursos internos de IA. La combinación de la potencia de cálculo de la IA y el arte humano de comprender la información produce mayor potencial para generar previsiones precisas.

La combinación de la IA y el arte de los expertos humanos produce el mayor potencial en la generación de previsiones precisas en entornos en los que las dos habilidades son complementarias, lo que sugiere un futuro de "Hombre + Máquina" en las profesiones de alta cualificación. La complementariedad entre humanos y máquinas proporciona orientación sobre cómo los humanos pueden adaptarse para sobrevivir y prosperar en la era de las máquinas. Por ejemplo, reformar la educación y la formación profesional para reforzar las habilidades blandas y la creatividad puede ayudar a los profesionales humanos a prepararse mejor para el futuro que se avecina.

6. BIBLIOGRAFÍA

- Millner, A. y Heyen, D. (2021): Prediction: The long and the short of it. *American Economic Journal: Microeconomics*, 13, 374–398.
- Copeland, T. y Tufano, P. (2004): A real-world way to manage real options. *Harvard Business Review*, 82, 90–99.
- Luehrman, T. A. (1998): Strategy as a portfolio of real options. *Harvard Business Review*, 76, 89–99.

- Van Putten, A. B. y MacMillan, I. C. (2004): Making real options really work. *Harvard Business Review*, 82, 134–141.
- Cao, S. (2021): From Man vs. Machine to Man + Machine: The Art and AI of Stock Analyses. NEBR, 28800 working paper, DOI 10.3386/w28800. <http://www.nber.org/papers/w28800>
- Cao, L. (2020): AI in Finance: A Review. University of Technology Sydney, Australia. <http://dx.doi.org/10.2139/ssrn.3869625>
- Asociación española Fintech e Insurtech. (2017): Libro Blanco de la Regulación Fintech en España. https://asociacionfintech.es/wp-content/uploads/2018/06/AEFI_LibroBlanco_02_10_2017.pdf
- Fintech Spain. (2018): Curso MOOC Fintech: la banca del futuro con Nebrija Global Campus. <https://fintechspain.com/2017/11/21/mooc-fintech-la-banca-del-futuro/>
- Han, Y., Liu, Y., Zhou, G., y Zhu, Y. (2021): Technical Analysis in the Stock Market: A Review. Disponible en SSRN: <https://ssrn.com/abstract=3850494> o <http://dx.doi.org/10.2139/ssrn.3850494>
- G. D. C. Ferreira, F., H. Gandomi, A. y T. N. Cardoso, R., (2021). Artificial Intelligence Applied to Stock Market Trading: A Review. <https://ieeexplore.ieee.org/document/9350582>
- Speranza M. G. (1996): A heuristic algorithm for a portfolio optimization model applied to the Milan stock market, 23, 433–441.
- Wuerges, A. F., y Alonso Borba, J. (2009). Artificial Intelligence Systems applied to Accounting, Auditing and Finance. Universidade Federal de Santa Catarina, Brazil. Disponible en SSRN: <https://ssrn.com/abstract=1462453> o <http://dx.doi.org/10.2139/ssrn.1462453>
- M. Chang. (2018). How A.I. Traders Will Dominate Hedge Fund Industry. <https://youtu.be/lzaBbQKUAA>
- Fernández, A. (2019). Inteligencia artificial en los servicios financieros. *Boletín económico, artículos analíticos*. 1-8.
- Markowitz, H. (1952): “Portfolio selection,” *J. Finance*: 7, 77–91.
- Mansini. R. y Speranza M. G (1999): Heuristic algorithms for the portfolio selection problem with minimum transaction lots. *Eur. J. Oper. Res.*, 114, 219–233.
- Chang. T.-J., Meade. N., Beasley. J. E., y Sharaiha. Y. M. (2000): Heuristics for cardinality constrained portfolio optimisation, 27, 1271–1302.

- Cao, S., Jiang, W., Wang, J. L., y Yang, B. (2021): From Man vs. Machine to Man + Machine: The Art and AI of Stock Analyses. Disponible en SSRN: <https://ssrn.com/abstract=3840538> o <http://dx.doi.org/10.2139/ssrn.3840538>
- Zhu. H., Wang. Y., Wang. K., y Chen. C. Y. (2011) Particle Swarm Optimization (PSO) for the constrained portfolio optimization problem, 38, 10161–10169.
- Zhang. W.-G., Liu. Y.-J. y W.-J. Xu (2012): A possibilistic mean-semivarianceentropy model for multi-period portfolio selection with transaction costs, 222, 341–349.
- Ertenlice, O. y Kalayci, C. B. (2018): A survey of swarm intelligence for portfolio optimization: Algorithms and applications, 39, 36–52.
- Lo, A. W. (2007): Efficient markets hypothesis. The New Palgrave Dictionary of Economics. Basingstoke. <https://alo.mit.edu/wp-content/uploads/2015/08/emh2007.pdf>
- Chartier, E., Bowden, I., Pinkerton, M., y Townley, A. (2021): Behavioral Finance: The Impact of Artificial Intelligence and Social Media Analytics. <https://ssrn.com/abstract=3709112> o <http://dx.doi.org/10.2139/ssrn.3709112>
- Murphy, J. J. (1999): Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications (New York Institute of Finance Series). New York, NY, USA: New York Institute of Finance. 377-390.
- Golan, R. H. y Ziarko, W. (1995): A methodology for stock market analysis utilizing rough set theory <https://ieeexplore.ieee.org/document/495230>
- Schierholt, K. y Dagli, C. H. (1996): Stock market prediction using different neural network classification architectures, 72–78.
- Kim, M.J., Min, S.-H. y Han, I. (2006) An evolutionary approach to the combination of multiple classifiers to predict a stock price index, 31, 241–247.
- Huang, C., Yang, D. y Chuang, Y (2008): Application of wrapper approach and composite classifier to the stock trend prediction, 34, 2870–2878.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P. y A. Oliveira, L. I. (2016): Computational intelligence and financial markets: A survey and future directions, 55, 194–211.
- Kotecha, K., Piuri, V., Shah, H. N., y Patel, R. (2020): Data Science and Intelligent Applications. Lecture Notes on Data Engineering and Communications Technologies, 52.
- Zhong, X. y Enke, D. (2019): Predicting the daily return direction of the stock market using hybrid machine learning algorithms, 5, 1–20.

- Vignesh, C. K. (2020): Applying machine learning models in stock market prediction,5, 395–398.
- Wu, J. M. T., Li, Z., Srivastava, G., Tasi, M. H. y Lin, J. C.W. (2020): 'A graphbased convolutional neural network stock price prediction with leading indicators,1–17.
- Liu, B. (2012): Sentiment analysis and opinion mining, 5, 1–167.
- Mittermayer, M. A. (2004): Forecasting intraday stock price trends with text mining techniques, 37, 1029–1038.
- Takahashi, S., Takahashi, M., Takahashi, H. y Tsuda, K. (2006): Analysis of Stock Price Return Using Textual Data and Numerical Data Through Text Mining, 4252, 310–316.
- Mohri, M., Rostamizadeh, A., y Talwalkar, A. (2018): Foundations of Machine Learning, 2, 213-237.
- Allen, D. E., McAleer, M. y Singh, A. K. (2019): Daily market news sentiment and stock prices, 51, 3212–3235.
- Geva, T. y Zahavi, J. (2014): Empirical evaluation of an automated intraday stock recommendation system incorporating both market data and textual news,57, 212–223.
- Deloitte. (2019). Artificial intelligence in investment management. Artificial intelligence. The next frontier for investment management firms, 1–15.
- Xing, F. Z., Cambria, E. y Welsch, R. E. (2018): Intelligent asset allocation via market sentiment views, 13, 25–34.
- Azhikodan, A., Bhat, A. G. K. y Jadhav, M. V. (2019): 'Stock trading bot using deep reinforcement learning, 41–49.
- Müller, B., Reinhardt, J. (1990): Neural networks: an introduction. 13-23.
- Zonavalue Club. (2020): Guía de la inteligencia artificial aplicada a la inversión, 1–11.
- Cox, E. (1998): The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems. 21-97.
- Nanda, S. y Pendharkar, P. (2001): Linear models for minimizing misclassification costs in bankruptcy prediction. International Journal of Intelligent Systems in Accounting, Finance and Management, 155.
- Everis. (2020): Inteligencia artificial en el sector financiero, 1–59.
- Nunez-Letamendia, L. (2002): Trading systems designed by genetic algorithms. Managerial Finance, Patrington, 28.
- Übeyli, E. D. (2007): Implementing automated diagnostic systems for breast cancer detection. <https://doi.org/10.1016/j.eswa.2006.08.005>

- Montagna y Guido (2003). Pricing derivatives by path integral and neural networks. *Physica A*, v. 324, p. 189-195.
- Calderon, T. G. y Cheh, J. J. (2002): A roadmap for future neural networks research in auditing and risk assessment. *International Journal of Accounting Information Systems*, 3, 203-236.
- Hwang, M. I. y Lin, J. W.(2000). Neural fuzzy systems: A tutorial and an application. *The Journal of Computer Information Systems*, 40, 27.
- Zubillaga Rego, A., Pastor López, I., y García Bringas, P. (2020): Inteligencia artificial: una aproximación desde las finanzas. *Boletín de estudios económicos*, 75, 99–117.
- Rafaely, B. y Bennell, J. A. (2006): Optimisation of FTSE 100 tracker funds; A comparison of genetic algorithms and quadratic programming. *Managerial Finance*, Patrinton, 32, 477.
- Gómez Martínez, R., Prado Román, C. y Saz Peñas, L. J. (2020): Inteligencia artificial como herramienta de análisis en gestión Value. *Revista Electrónica de Comunicaciones y Trabajos de ASEPUMA*, 21, 89–104.
- Artificial Intelligence ETF List [en línea]. (2021). ETFdb.com. [Consultado el 7 de julio de 2021]. Disponible en: https://etfdb.com/themes/artificial-intelligence-etfs/#complete-list__returns&sort_name=assets_under_management&sort_order=desc&page=1

1. TABLA DE RENDIMIENTOS Y TAMAÑOS DE FONDOS IA

Esta es una lista de todos los ETF de inteligencia artificial negociados en los EE. UU. que actualmente están etiquetados por la base de datos de ETF.

Símbolo	ETF	Total Activos (\$)	Cambio de precio de YTD ²¹	Volumen Promedio Diario	Precio de Cierre Anterior	Cambio intradía
QQQ	Invesco QQQ Trust	185.433.000.000	17,59%	39.017.804,0	\$368,05	-0,44%
VGT	Vanguard Information Technology ETF	49.835.700.000	18,11%	507.203,0	\$416,48	-0,16%
XLK	Technology Select Sector SPDR Fund	45.114.600.000	19,57%	6.916.574,0	\$154,86	-0,08%
FDN	First Trust Dow Jones Internet Index Fund	10.857.300.000	14,04%	223.763,0	\$242,02	-1,14%
IYW	iShares U.S. Technology ETF	8.457.640.000	23,18%	420.845,0	\$104,60	-0,35%
FTEC	Fidelity MSCI Information Technology Index ETF	6.289.730.000	18,07%	276.598,0	\$122,95	-0,24%
IXN	iShares Global Tech ETF	5.784.350.000	17,53%	982.612,0	\$58,74	-0,51%
XT	iShares Exponential Technologies ETF	3.998.750.000	14,02%	158.703,0	\$64,98	-0,46%
QYLD	Global X NASDAQ 100 Covered Call ETF	3.857.020.000	6,41%	2.434.582,0	\$22,65	0,04%
IGM	iShares Expanded Tech Sector ETF	3.726.210.000	19,42%	35.977,0	\$417,35	-0,31%
ARKQ	ARK Autonomous Technology & Robotics ETF	2.783.760.000	6,36%	437.283,0	\$81,14	-0,94%
BOTZ	Global X Robotics & Artificial Intelligence ETF	2.512.590.000	3,86%	473.222,0	\$34,36	-1,26%
KOMP	SPDR S&P Kensho New Economies Composite ETF	2.035.220.000	11,95%	139.334,0	\$64,19	0,28%
ROBO	ROBO Global Robotics & Automation Index ETF	1.865.330.000	9,59%	105.575,0	\$66,73	-0,76%
PNQI	Invesco NASDAQ Internet ETF	1.104.150.000	10,25%	16.211,0	\$251,58	-0,82%
DRIV	Global X Autonomous & Electric Vehicles ETF	1.072.220.000	20,76%	318.365,0	\$28,89	0,00%
IRBO	iShares Robotics and Artificial Intelligence Multisector ETF	440.510.000	9,88%	52.554,0	\$43,69	-0,79%
ROBT	First Trust Nasdaq Artificial Intelligence & Robotics ETF	254.064.000	8,43%	22.812,0	\$54,35	-0,69%
DTEC	ALPS Disruptive Technologies ETF	239.305.000	8,35%	10.874,0	\$50,10	-0,63%
EBIZ	Global X E-commerce ETF	214.435.000	-1,63%	32.057,0	\$31,31	-2,10%
AIEQ	AI Powered Equity ETF	167.760.000	17,58%	21.475,0	\$41,70	-0,48%
IETC	iShares Evolved U.S. Technology ETF	132.550.000	21,15%	22.158,0	\$57,46	-0,35%
LEGR	First Trust Indxx Innovative Transaction & Process ETF	117.761.000	15,32%	19.154,0	\$42,96	0,07%
QTUM	Defiance Quantum ETF	115.690.000	21,75%	15.466,0	\$50,40	0,02%
LOUP	Innovator Loup Frontier Tech ETF	78.405.100	4,35%	16.622,0	\$52,01	-0,38%
UBOT	Direxion Daily Robotics, Artificial Intelligence & Automation Index Bull 2X Shares	42.054.700	3,57%	10.685,0	\$42,02	-2,64%
IEIH	iShares Evolved U.S. Innovative Healthcare ETF	40.783.200	14,29%	3.508,0	\$36,77	-0,76%
IEHS	iShares Evolved U.S. Healthcare Staples ETF	34.562.600	15,75%	5.392,0	\$43,17	-0,09%
KOIN	Capital Link NextGen Protocol ETF	30.704.800	16,77%	4.351,0	\$43,77	-0,30%

²¹ La rentabilidad YTD es la cantidad de beneficios (o pérdidas) obtenidos por una inversión desde el primer día de negociación del año natural en curso. En fondos de inversión, la rentabilidad YTD mide la rentabilidad comprendida en el periodo desde el 1 de enero del año en curso hasta la fecha del cálculo, en nuestros datos el 7 de julio de 2021.

IEDI	iShares Evolved U.S. Discretionary Spending ETF	22.888.800	13,88%	3.785,0	\$45,59	-0,37%
QRFT	QRAFT AI Enhanced U.S. Large Cap ETF	21.943.000	14,96%	4.586,0	\$43,65	-0,66%
IEME	iShares Evolved U.S. Media and Entertainment ETF	18.728.200	9,90%	5.655,0	\$37,19	-0,59%
IECS	iShares Evolved U.S. Consumer Staples ETF	14.731.900	7,06%	2.989,0	\$32,82	0,37%
BOB	Merlyn.AI Best-of-Breed Core Momentum ETF	14.152.300	N/A	3.043,0	\$26,15	-0,15%
AIQ	AI Powered International Equity ETF	11.756.500	9,09%	3.983,0	\$33,43	-0,48%
EKAR	Capital Link NextGen Vehicles & Technology ETF	11.603.700	14,12%	1.126,0	\$42,07	-0,52%
BUZ	Sprott Buzz Social Media Insights ETF	8.776.429	11,92%	3.112,0	\$35,01	0,11%
TCHF	iShares Edge MSCI Multifactor Technology ETF	8.560.403	10,69%	744,0	\$42,73	-0,88%
IEFN	iShares Evolved U.S. Financials ETF	6.288.180	27,31%	2.245,0	\$32,05	2,04%
XKCP	SPDR Kensho Clean Power ETF	5.368.993	31,66%	4.823,0	\$37,62	-1,16%
BIKR	Rogers AI Global Macro ETF	3.753.945	9,13%	521,0	\$24,97	0,00%
AUGR	Defiance Future Tech ETF	3.569.055	21,45%	1.829,0	\$23,87	-0,79%
MSUS	LHA Market State U.S. Tactical ETF	3.435.285	-8,73%	2.098,0	\$22,91	-0,26%
XKFF	SPDR Kensho Final Frontiers ETF	3.312.443	28,96%	1.945,0	\$33,28	-0,30%
DQML	Realty Shares Fundstrat DQM Long ETF	2.609.164	16,83%	1.283,0	\$25,92	-0,61%
PETZC	Gabelli Pet Parents' NextShares	732.965	N/A	N/A	\$99,97	0,00%
Total 46 ETFs.	Suma total de activos y promedio de cambio de precio de YTD	336.798.366.662	13,74%			

Tabla 1 Tamaño y rendimientos de algunos fondos negociados en bolsa de IA
Fuente: ETF Base consultada el 7 de julio de 2021.

2. TABLA DE RENTABILIDADES Y RETORNOS TENIENDO EN CUENTA LA YTD

Incluye información histórica sobre todos los ETF de Inteligencia Artificial listados en los intercambios estadounidenses por la base de datos de ETF y el MSCI World.

Símbolo	ETF	Cambio de precio de YTD	1 semana	4 semanas	1 año	3 años	5 años
QQQ	Invesco QQQ Trust	17,59%	0,95%	1,95%	34,77%	109,01%	228,25%
VGT	Vanguard Information Technology ETF	18,11%	1,04%	2,30%	36,18%	124,85%	276,21%
XLK	Technology Select Sector SPDR Fund	19,57%	0,95%	2,42%	35,26%	121,03%	252,14%
FDN	First Trust Dow Jones Internet Index Fund	14,04%	0,05%	-2,54%	29,04%	75,62%	207,72%
IYW	iShares U.S. Technology ETF	23,18%	1,37%	3,17%	40,94%	127,59%	274,93%
FTEC	Fidelity MSCI Information Technology Index ETF	18,07%	0,99%	2,25%	36,07%	119,59%	265,71%
IXN	iShares Global Tech ETF	17,53%	1,01%	2,35%	35,71%	111,70%	244,66%
XT	iShares Exponential Technologies ETF	14,02%	1,56%	2,23%	35,46%	77,51%	163,92%
QYLD	Global X NASDAQ 100 Covered Call ETF	6,41%	0,71%	1,58%	17,01%	27,15%	71,10%
IGM	iShares Expanded Tech Sector ETF	19,42%	0,91%	1,18%	35,45%	111,00%	257,63%
MSCI	MSCI WORLD		0,71%	1,724%	29,170%	41,676%	99,245%
PROMEDIO	Promedio sin MSCI WORLD				33,59%	100,51%	224,23%

Tabla 2 Retornos tomando en cuenta la YTD de algunos fondos negociados en bolsa de IA
Fuente: ETF Base consultada el 7 de julio de 2021.




Ilustración 6 Gráfico de rentabilidades (Promedio excluye MSCI World)
Fuente: ETF Base consultada el 7 de julio de 2021.

3. TABLA DE VOLATILIDADES, BETA Y DESVIACIÓN ESTANDAR

Incluye información histórica de la volatilidad²² sobre todos los ETF de Inteligencia Artificial listados en los intercambios estadounidenses por la base de datos de ETF.

Símbolo	ETF	Volatilidad de 5 días	Volatilidad de 20 días	Volatilidad de 50 días	Volatilidad de 200 días	Beta β	Desviación Estándar ²³
QQQ	Invesco QQQ Trust	54,35%	8,88%	10,04%	14,00%	1,02	28,55%
VGT	Vanguard Information Technology ETF	65,47%	10,05%	11,61%	15,58%	1,07	33,20%
XLK	Technology Select Sector SPDR Fund	93,63%	10,44%	11,80%	15,54%	1,04	12,23%
FDN	First Trust Dow Jones Internet Index Fund	197,19%	13,18%	13,88%	17,55%	1,03	18,76%
IYW	iShares U.S. Technology ETF	84,40%	10,74%	12,13%	16,21%	1,05	9,02%
FTEC	Fidelity MSCI Information Technology Index ETF	156,14%	10,13%	11,83%	15,79%	1,07	9,80%
IXN	iShares Global Tech ETF	102,39%	9,50%	11,71%	15,75%	1,02	4,78%
XT	iShares Exponential Technologies ETF	146,31%	8,20%	9,70%	12,09%	0,99	5,44%
QYLD	Global X NASDAQ 100 Covered Call ETF	107,47%	3,76%	4,68%	9,38%	0,66	1,05%
IGM	iShares Expanded Tech Sector ETF	97,31%	10,27%	12,01%	15,49%	1,08	34,26%
PROMEDIO		110,47%	9,52%	10,94%	14,74%	1,00	15,71%

Tabla 3 Volatilidades en diferentes periodos y ratio Beta.

Fuente: ETF Base consultada el 7 de julio de 2021.




Ilustración 7 Gráfico rentabilidad – volatilidad.

Fuente: ETF Base consultada el 7 de julio de 2021.

²² Calculada sobre la varianza de las rentabilidades a los últimos 5 días, 20 días, 50 días y 200 días.

²³ Dato anualizado, calculado sobre la varianza de las rentabilidades anuales.

4. TABLA DE FLUJO DE FONDOS

Incluye datos de flujo de fondos para todos los ETF de Inteligencia Artificial listados en EE. UU. El flujo total de fondos es la entrada de capital en un ETF menos la salida de capital del ETF durante un período de tiempo determinado. Flujos de fondos en dólares estadounidenses.

Símbolo	ETF	Total activos \$	YTD FF	1 semana FF	4 semanas FF	1 año FF	3 años FF	5 años FF
QQQ	Invesco QQQ Trust	185.433.000.000	\$6.439.506.850	\$239.523.150	-\$171.477.250	\$11.215.668.600	\$28.008.572.200	\$35.551.431.800
VGT	Vanguard Information Technology ETF	49.835.700.000	\$842.878.348	-\$8.787.570	-\$264.744.012	\$1.173.079.076	\$2.706.414.028	\$8.199.592.451
XLK	Technology Select Sector SPDR Fund	45.114.600.000	-\$226.726.728	\$115.214.202	\$607.265.656	-\$1.311.500.908	-\$1.404.771.797	\$1.526.837.845
FDN	First Trust Dow Jones Internet Index Fund	10.857.300.000	-\$1.661.701.200	-\$12.050.300	\$75.731.550	-\$1.917.975.300	-\$3.667.123.400	-\$800.512.150
IYW	iShares U.S. Technology ETF	8.457.640.000	\$149.563.605	\$77.560.420	\$120.879.265	-\$176.755.245	-\$505.072.705	-\$583.225.745
FTEC	Fidelity MSCI Information Technology Index ETF	6.289.730.000	\$96.209.385	\$6.122.650	\$12.492.635	\$279.059.015	\$997.165.955	\$2.276.329.885
IXN	iShares Global Tech ETF	5.784.350.000	\$159.286.532.353	\$75.871.025	\$160.436.932.778	\$159.329.410.328	\$159.803.489.563	\$160.811.685.761
XT	iShares Exponential Technologies ETF	3.998.750.000	\$428.922.515	\$0	\$28.323.935	\$318.959.700	\$74.000.995	\$1.203.854.260
QYLD	Global X NASDAQ 100 Covered Call ETF	3.857.020.000	\$2.217.317.942	\$62.531.998	\$411.259.571	\$2.578.563.214	\$3.553.134.228	\$3.802.545.728
IGM	iShares Expanded Tech Sector ETF	3.726.210.000	-\$45.424.780	\$0	\$41.295.415	\$85.638.105	\$289.362.985	\$354.100.358

Tabla 4 Flujo de fondos de los ETF.

Fuente: ETF Base consultada el 7 de julio de 2021.

Símbolo	ETF	Δ% 1 semana	Δ% 4 semanas	Δ% 1 año	Δ% 3 años	Δ% 5 años
QQQ	Invesco QQQ Trust	0,1293%	-0,0924%	6,4377%	17,7918%	23,7197%
VGT	Vanguard Information Technology ETF	-0,0176%	-0,5284%	2,4106%	5,7425%	19,6935%
XLK	Technology Select Sector SPDR Fund	0,2560%	1,3644%	-2,8249%	-3,0198%	3,5029%
FDN	First Trust Dow Jones Internet Index Fund	-0,1109%	0,7024%	-15,0132%	-25,2480%	-6,8667%
IYW	iShares U.S. Technology ETF	0,9255%	1,4500%	-2,0471%	-5,6353%	-6,4510%
FTEC	Fidelity MSCI Information Technology Index ETF	0,0974%	0,1990%	4,6427%	18,8409%	56,7182%
IXN	iShares Global Tech ETF	1,3291%	-103,7402%	-103,7672%	-103,7556%	-103,7312%
XT	iShares Exponential Technologies ETF	0,0000%	0,7134%	8,6679%	1,8855%	43,0733%
QYLD	Global X NASDAQ 100 Covered Call ETF	1,6480%	11,9352%	201,6934%	1169,2335%	6980,4435%
IGM	iShares Expanded Tech Sector ETF	0,0000%	1,1207%	2,3523%	8,4194%	10,5009%

Tabla 5 Incremento porcentual de los Flujos de fondos de los ETF.

Fuente: ETF Base consultada el 7 de julio de 2021.

Tendencia del incremento % de los flujos

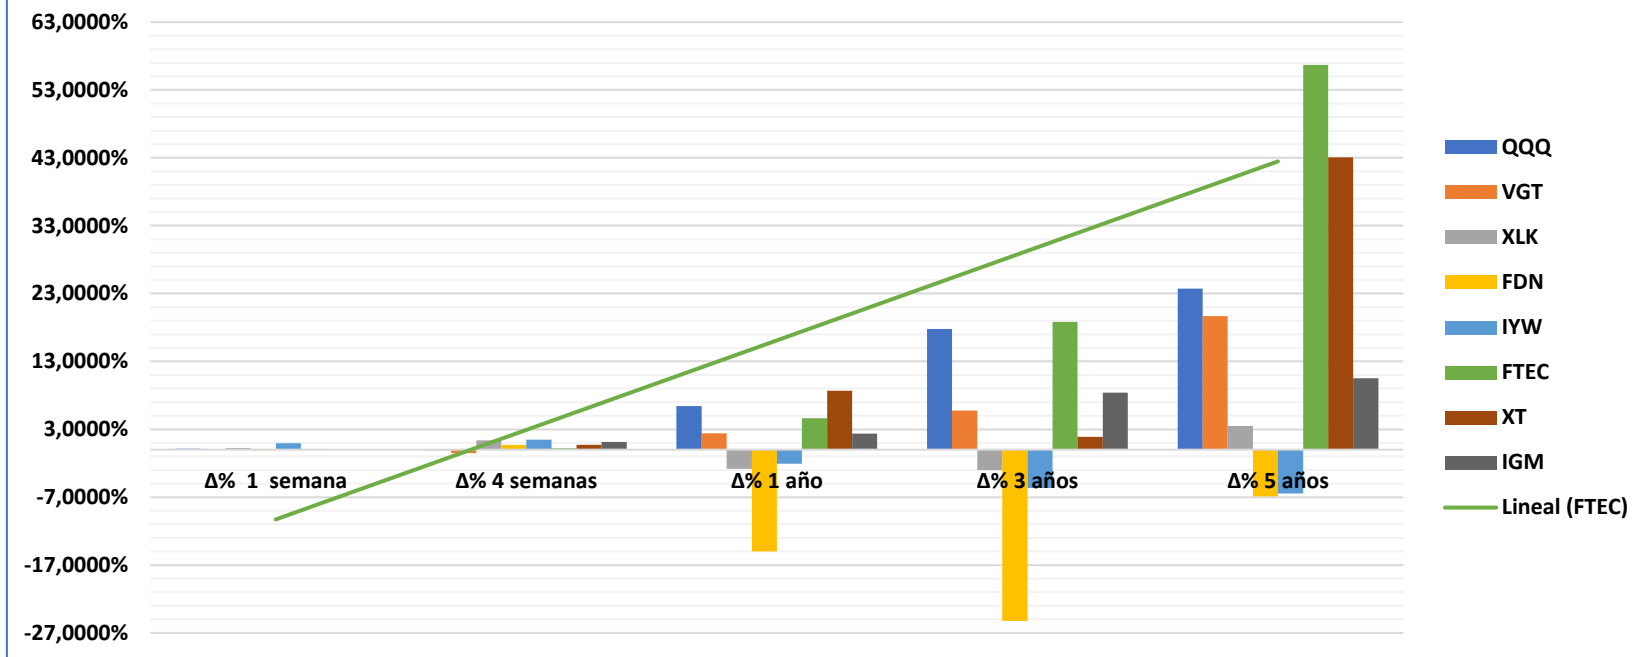


Ilustración 8 Tendencia del incremento % de los flujos.
Fuente: ETF Base consultada el 7 de julio de 2021




Ilustración 9 Incremento % de Flujos y Rentabilidad a 4 semanas.
Fuente: ETF Base consultada el 7 de julio de 2021

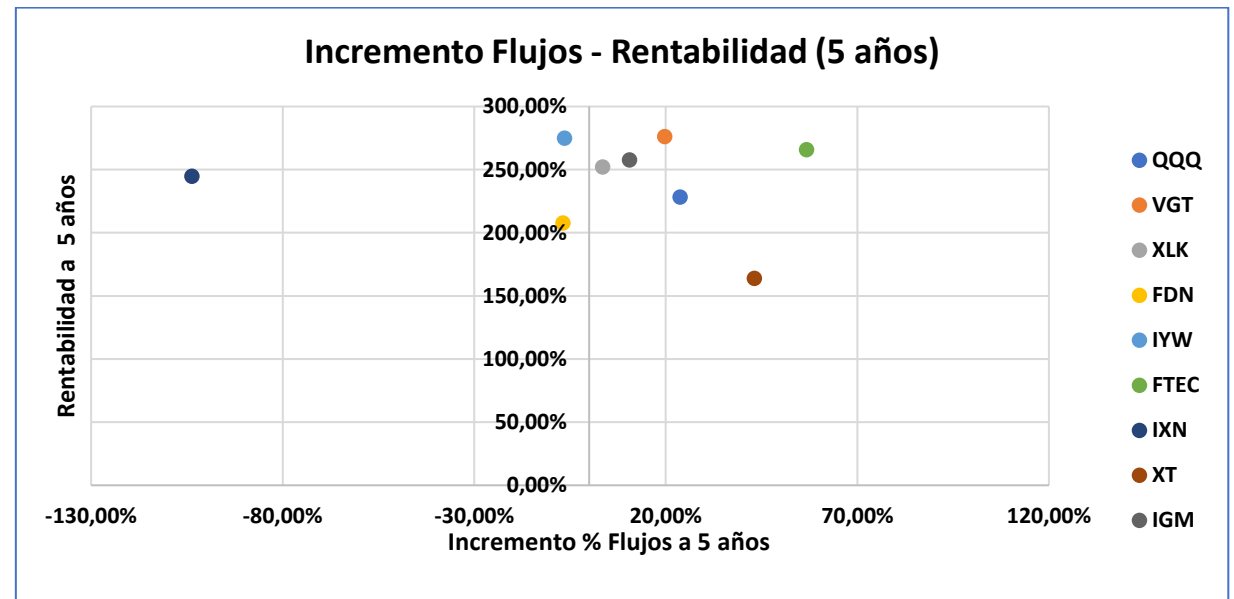


Ilustración 10 Incremento % de Flujos y Rentabilidad a 5 años
Fuente: ETF Base consultada el 7 de julio de 2021

5. TABLA DE DIVIDENDOS Y RATIO PER.

Incluye datos de los repartos de dividendos y la ratio PER para los ETF seleccionados de Inteligencia Artificial en los intercambios estadounidenses que actualmente son rastreados por la base de datos de ETF.

Símbolo	ETF	Fecha Dividendo	Dividendo	Rendimiento Anual por Dividendo %	PER
QQQ	Invesco QQQ Trust	21/06/2021	\$1,74	0,47%	33,12
VGT	Vanguard Information Technology ETF	24/06/2021	\$2,61	0,63%	35,60
XLK	Technology Select Sector SPDR Fund	21/06/2021	\$1,08	0,69%	28,40
FDN	First Trust Dow Jones Internet Index Fund	21/12/2021	\$0,00	0,00%	42,25
IYW	iShares U.S. Technology ETF	10/06/2021	\$0,35	0,34%	40,58
FTEC	Fidelity MSCI Information Technology Index ETF	18/06/2021	\$0,79	0,64%	34,36
IXN	iShares Global Tech ETF	10/06/2021	\$1,13	1,91%	40,98
XT	iShares Exponential Technologies ETF	10/06/2021	\$0,47	0,72%	28,71
QYLD	Global X NASDAQ 100 Covered Call ETF	19/07/2021	\$2,65	11,72%	35,05
IGM	iShares Expanded Tech Sector ETF	10/06/2021	\$0,78	0,19%	44,78

Tabla 6 Dividendos y ratio PER.

Fuente: ETF Base consultada el 7 de julio de 2021




Ilustración 11 Gráfico del Dividendo a repartir.

Fuente: ETF Base consultada el 7 de julio de 2021.

Rendimiento Anual por Dividendo




Ilustración 12 Gráfico del Rendimiento Anual por Dividendo.
Fuente: ETF Base consultada el 7 de julio de 2021.

PER




Ilustración 13 Gráfico de la ratio PER.
Fuente: ETF Base consultada el 7 de julio de 2021.

6. TABLA DE PARTICIPACIONES Y CATEGORÍA

Incluye el número de tenencias para cada ETF y el porcentaje de activos que componen los diez activos principales que actualmente están etiquetados por la Base de Datos de ETF.

Símbolo	ETF	Categoría en ETFdb.com	Nº de Participaciones	% en Top 10
QQQ	Invesco QQQ Trust	Renta variable de alta capitalización	103	52,53%
VGT	Vanguard Information Technology ETF	Acciones tecnológicas	359	56,95%
XLK	Technology Select Sector SPDR Fund	Acciones tecnológicas	76	67,32%
FDN	First Trust Dow Jones Internet Index Fund	Renta variable de alta capitalización	44	53,22%
IYW	iShares U.S. Technology ETF	Acciones tecnológicas	161	63,36%
FTEC	Fidelity MSCI Information Technology Index ETF	Acciones tecnológicas	350	57,70%
IXN	iShares Global Tech ETF	Acciones tecnológicas	131	56,05%
XT	iShares Exponential Technologies ETF	Renta variable de alta capitalización	195	7,99%
QYLD	Global X NASDAQ 100 Covered Call ETF	Renta variable de alta capitalización	104	54,14%
IGM	iShares Expanded Tech Sector ETF	Acciones tecnológicas	334	51,27%

Tabla 7 Participaciones y Categoría de los ETFs
Fuente: ETF Base consultada el 7 de julio de 2021.

Cartera QQQ	Ponderación	Cartera VGT	Ponderación	Cartera XLK	Ponderación	Cartera FDN	Ponderación	Cartera IYW	Ponderación
AAPL	11,36%	AAPL	20,09%	AAPL	22,16%	AMZN	9,30%	AAPL	18,40%
MSFT	10,53%	MSFT	16,75%	MSFT	21,52%	FB	7,90%	MSFT	17,87%
AMZN	7,42%	NVDA	3,96%	NVDA	4,75%	GOOGL	5,53%	GOOGL	5,41%
GOOG	4,12%	V	3,21%	V	3,77%	GOOG	5,28%	GOOG	5,41%
FB	3,96%	MAMÁ	2,81%	PYPL	3,06%	PYPL	5,26%	FB	4,38%
GOOGL	3,80%	PYPL	2,52%	MAMÁ	3,01%	CRM	4,90%	NVDA	4,34%
TSLA	3,73%	ADBE	2,44%	ADBE	2,93%	NFLX	4,84%	ADBE	2,68%
NVDA	3,63%	CRM	1,93%	CRM	2,35%	CSCO	4,76%	CRM	2,15%
PYPL	2,24%	CSCO	1,91%	CSCO	2,32%	CHASQUEAR	3,08%	CSCO	2,13%
ADBE	2,16%	INTC	1,79%	INTC	2,04%	ZM	2,91%	INTC	1,86%
RESTO	47,05%	RESTO	42,59%	RESTO	32,09%	RESTO	46,24%	RESTO	35,37%

Tabla 8 Composición QQQ, VGT, XLK, FDN y IYW.
Fuente: ETF Base consultada el 7 de julio de 2021.

Cartera FTEC	Ponderación	Cartera IXN	Ponderación	Cartera QYLD	Ponderación	Cartera XT	Ponderación	Cartera IGM	Ponderación
AAPL	20,29%	AAPL	17,58%	AAPL	11,37%	1548 ²⁴	1,28%	AAPL	9,34%
MSFT	17,52%	MSFT	17,07%	MSFT	10,38%	COF	0,80%	MSFT	9,26%
NVDA	4,04%	NVDA	3,77%	AMZN	7,41%	ASM	0,79%	AMZN	7,64%
V	3,24%	V	2,99%	GOOG	4,05%	LLY	0,76%	FB	5,94%
MAMÁ	2,61%	2330 ²⁵	2,89%	FB	3,95%	507685 ²⁶	0,76%	GOOGL	4,52%
ADBE	2,52%	ASML	2,49%	GOOGL	3,76%	ASML	0,73%	GOOG	4,32%
PYPL	2,48%	5930 ²⁷	2,45%	TSLA	3,73%	ALNY	0,72%	NVDA	3,45%
CRM	2,02%	PYPL	2,43%	NVDA	3,48%	GORRO	0,70%	V	2,74%
CSCO	1,99%	MAMÁ	2,39%	PYPL	2,24%	NVDA	0,70%	PYPL	2,22%
INTC	1,76%	ADBE	2,33%	ADBE	2,15%	NOVO. B	0,69%	MAMÁ	2,18%
RESTO	41,53%	RESTO	43,61%	RESTO	47,48%	RESTO	92,07%	RESTO	48,39%

Tabla 9 Composición de FTEC, IXN, QYLD, XT e IGM.

Fuente: ETF Base consultada el 7 de julio de 2021.

²⁴ Genscript Biotech Corporation

²⁵ Taiwán Semiconductor Manufacturing Co., Ltd.

²⁶ Wipro Limited

²⁷ Samsung Electronics Co., Ltd

7. GRÁFICA EVOLUCIÓN HISTÓRICA DE LOS FONDOS Y BENCHMARK.

Incluye cotización histórica de los últimos 6 años sobre los fondos seleccionados de Inteligencia Artificial listados en las bolsas estadounidenses que actualmente son rastreados por la base de datos de ETF y la evolución de los índices NASDAQ 100 y MSCI WORLD.

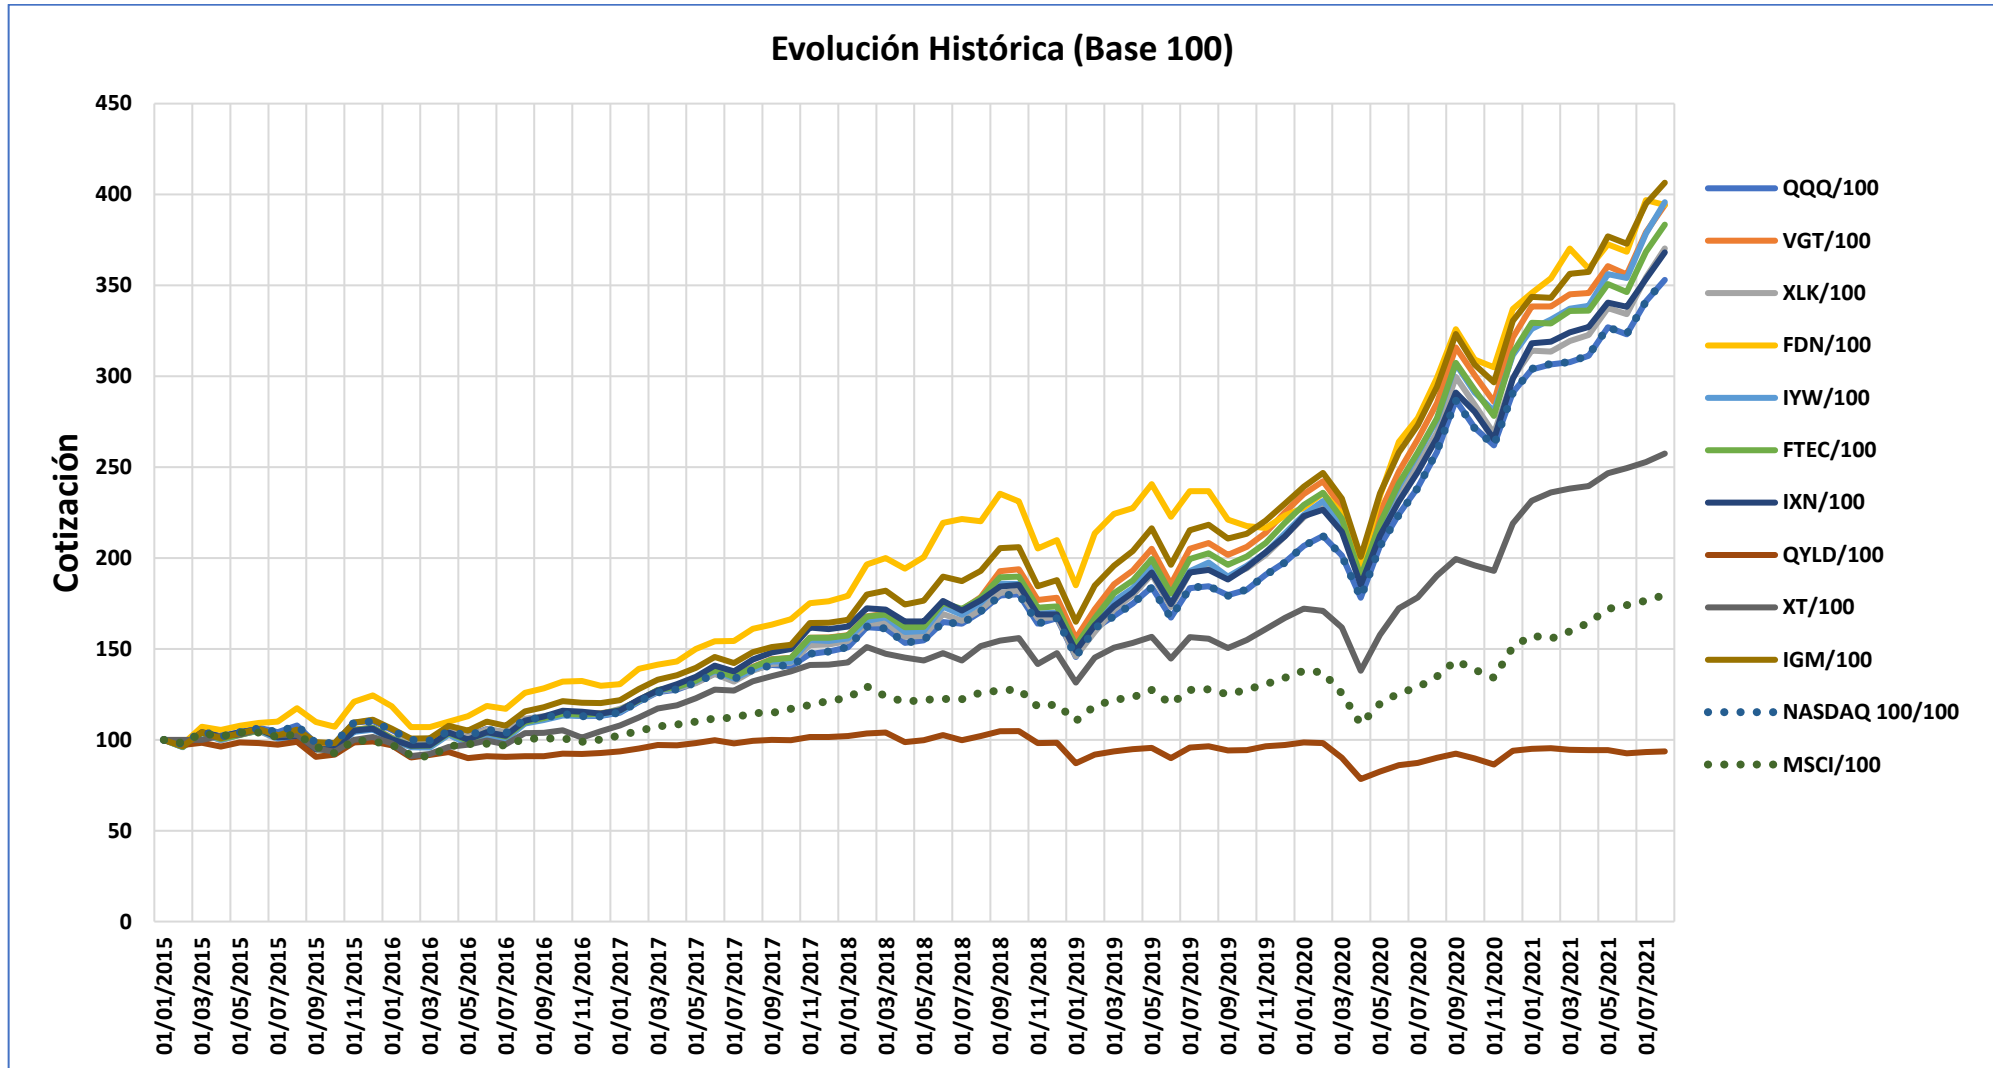


Ilustración 14 Gráfico evolución histórica ETFs, NASDAQ 100 y MSCI World (Base 100).
Fuente: ETF Base consultada el 7 de julio de 2021.

8. TABLA ASPECTOS TÉCNICOS.

La siguiente tabla contiene cierta información técnica para todos los ETF de Inteligencia Artificial que se enumeran en los intercambios de EE. UU. y son rastreados por la base de datos de ETF.

Símbolo	ETF	Precio de Cierre Anterior	Lower Bollinger	Upper Bollinger	Soporte 1	Resistencia 1	RSI
QQQ	Invesco QQQ Trust	\$368,05	\$356,20	\$371,15	\$366,85	\$369,31	63,77
VGT	Vanguard Information Technology ETF	\$416,48	\$400,36	\$419,11	N/A	N/A	65,04
XLK	Technology Select Sector SPDR Fund	\$154,86	\$149,39	\$155,77	N/A	N/A	64,97
FDN	First Trust Dow Jones Internet Index Fund	\$242,02	\$237,25	\$251,60	\$240,71	\$243,85	50,44
IYW	iShares U.S. Technology ETF	\$104,60	\$99,35	\$105,54	\$104,28	\$104,87	66,52
FTEC	Fidelity MSCI Information Technology Index ETF	\$122,95	\$118,27	\$123,79	N/A	N/A	64,43
IXN	iShares Global Tech ETF	\$58,74	\$56,51	\$59,22	\$58,64	\$58,87	62,86
XT	iShares Exponential Technologies ETF	\$64,98	\$61,94	\$65,39	\$64,86	\$65,11	61,87
QYLD	Global X NASDAQ 100 Covered Call ETF	\$22,65	\$22,10	\$22,71	N/A	N/A	66,23
IGM	iShares Expanded Tech Sector ETF	\$417,35	\$403,78	\$423,12	\$416,06	\$418,68	60,52

Tabla 10 Aspectos técnicos.

Fuente: ETF Base consultada el 7 de julio de 2021