

Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ciencias Matemáticas

Escuela Profesional de Computación Científica

FinanzasAI: Un software de recomendación con Inteligencia Artificial para invertir en la Bolsa de Valores

TESIS

Para optar el Título Profesional de Licenciado en Computación Científica

AUTOR

Stiw Harrison HERRERA TAIPE

ASESOR

Dra. Rosa Luz MEDINA AGUILAR

Lima, Perú

2024



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

https://creativecommons.org/licenses/by-nc-sa/4.0/

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Herrera, S. (2024). *FinanzasAI: Un software de recomendación con Inteligencia Artificial para invertir en la Bolsa de Valores.* [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ciencias Matemáticas, Escuela Profesional de Computación Científica]. Repositorio institucional Cybertesis UNMSM.

Metadatos **complementarios**

Datos de autor	
Nombres y apellidos	Stiw Harrison Herrera Taipe
Tipo de documento de identidad	DNI
Número de documento de identidad	46068007
URL de ORCID	https://orcid.org/0000-0002-0054-6148
Datos de asesor	
Nombres y ape11idos	Dra. Rosa Luz Medina Aguilar
Tipo de documento de identidad	DNI
Número de documento de identidad	10048247
URL de ORCID	https://orcid.org/0000-0002-0175-3894
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Dra. Martha Hilda Timoteo Sánchez
Tipo de documento	DNI 25702279
Número de documento de identidad	https://orcid.org/0000-0002-7070-1094
Miembro del jurado 1	
Nombres y apellidos	Dr. Edinson Raúl Montoro Alegre
Tipo de documento	DNI 09627181
Número de documento de identidad	https://orcid.org/0000-0002-8237-9469
Datos de investigación	
Línea de investigación	Ciencias de la computación https://purl.org/pe-repo/ocde/ford#1.02.01

Grupo de investigación	No aplica.
Agencia de financiamiento	Sin financiamiento.
Ubicación geográfica de la investigación	Universidad Nacional Mayor de San Marcos País: Perú Departamento: Lima Provincia: Lima Distrito: Lima Coordenadas geográficas Latitud: -12.058333 Longitud: -77.083333
Año o rango de años en que se realizó la investigación	(septiembre del 2024)
URL de disciplinas OCDE	Matemáticas aplicadas https://purl.org/pe-repo/ocde/ford#1.01.02

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
FACULTAD DE CIENCIAS MATEMÁTICAS
Escuela Profesional de Computación Científica

ACTA DE SUSTENTACIÓN DE TESIS PARA LA OBTENCIÓN DEL TÍTULO PROFESIONAL DE LICENCIADO EN COMPUTACION CIENTÍFICA (PROGRAMA DE TITULACIÓN PROFESIONAL 2024)

En la UNMSM – Ciudad Universitaria – Facultad de Ciencias Matemáticas, siendo las 7:30 horas del sábado 28 de setiembre del 2024, se reunieron los docentes designados como Miembros del Jurado Evaluador (PROGRAMA DE TITULACIÓN PROFESIONAL 2024): Dra. Martha Hilda Timoteo Sánchez (presidente), Dr. Edinson Raúl Montoro Alegre (miembro) y la Dra. Rosa Luz Medina Aguilar (miembro asesor), para la sustentación de la Tesis titulada: «FINANZASAI: UN SOFTWARE DE RECOMENDACIÓN CON INTELIGENCIA ARTIFICIAL PARA INVERTIR EN LA BOLSA DE VALORES» presentado por el Bachiller STIW HARRISON HERRERA TAIPE, para optar el Título Profesional de Licenciado en Computación Científica.

Luego de la exposición de la Tesis, el presidente invitó al expositor a dar respuesta a las preguntas formuladas.

Realizada la evaluación correspondiente por los Miembros del Jurado Evaluador, el expositor mereció la aprobación ...sobresaliente... con un calificativo promedio de ...17 (diecisiete)

A continuación, los miembros del Jurado Evaluador dan manifiesto que el participante Bachiller STIW HARRISON HERRERA TAIPE, en vista de haber aprobado la sustentación de su Tesis, será propuesto para que se le otorgue el Título Profesional de Licenciado en Computación Científica.

Siendo las 8:10 horas se levantó la sesión firmando para constancia la presente Acta.

Dra. Martha Hilda Timoteo Sánchez
PRESIDENTE

Dr. Edinson Raúl Montoro Alegre
MIEMBRO

Dra. Rosa Luz Medina Aguilar
MIEMBRO ASESOR

UNIVERSIDAD NACIONAL MAYOR DE
SAN MARCOS
Universidad del Perú, Decana de América

CERTIFICADO DE SIMILITUD

Yo, Rosa Luz Medina Aguilar en mi condición de asesor acreditado con Dictamen N° 000005-2025-EPCC-FCM/UNMSM... de la tesis, cuyo título es: FINANZASAI UN SOFTWARE DE RECOMENDACIÓN CON INTELIGENCIA ARTIFICIAL PARA INVERTIR EN LA BOLSA DE VALORES, presentado por el bachiller HERRERA TAIPE STIW HARRISON para optar el título de Licenciado (a) en Computación Científica.

CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante la plataforma PIDS, el documento evaluado cuenta con el 5% de similitud, nivel **PERMITIDO** para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional.**

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del título correspondiente.

Lima, 15 de diciembre de 2025

Firma del Asesor: _____

DNI: 10048247

DEDICATORIA

A mi hijo Matthew Steve Herrera Peceros por todo su inmenso amor y cariño y decirle que es mi motivación principal de seguir mejorando cada día.

A mis amados padres Carmen Taipe Campos y Heber Jesus Herrera Perez por todo su amor y motivación. Gracias por enseñarme a perseverar y seguir mis sueños.

A Elizabeth Peceros Peralta, Juana Peralta, Sting Peceros por todo su apoyo incondicional.

A mis tíos y tías Carlos Herrera, Amador Rojas, Cristina Herrera, Gloria Herrera y primos por siempre estar presente para mí. Finalmente a todos los demás que siempre estuvieron apoyándome.

En el corazón de la inteligencia artificial debe latir siempre la compasión y la comprensión humana pues brilla más cuando recuerda que detrás de cada dato y algoritmo hay sueños, emociones y la esencia misma de la humanidad.

By S.T.H.H

Resumen

FinanzasAI: Un Software de Recomendación con Inteligencia Artificial para Invertir en la Bolsa de Valores

Stiw Harrison Herrera Taipe
2024

Orientadora: Dra. Rosa Luz Medina Aguilar
Título Obtenido: Licenciado en Computación Científica

Con el objetivo de encontrar las mejores empresas para invertir en la Bolsa de Valores en la actualidad viene siendo implementado la Transformación Digital o *Digital Transformation* por las empresas públicas o privadas. La Inteligencia Artificial está impactando con sus aplicaciones y solucionando problemas en las diferentes áreas. Cuando la Transformación Digital llega a las Finanzas vienen siendo creadas nuevas empresas o *Fintechs*. En este contexto, estamos combinando Inteligencia Artificial y Finanzas. De las Finanzas, seguimos el Análisis Fundamentalista que consiste en examinar los datos trimestrales publicados por las empresas, generalmente llamado de Fundamentos. Estos Fundamentos son compartidos por las empresas y de acceso libre a los inversionistas. Así, colectamos estas informaciones trimestrales de empresas que cotizan en la Bolsa de Valores de Brasil y después de un tratamiento a esas informaciones construimos una Base de Datos. Luego, usamos los algoritmos de Inteligencia Artificial para analizar nuestra Base de Datos y poder encontrar potenciales empresas a invertir.

Palabras Claves: Inteligencia Artificial, Finanzas, Transformación Digital, Inversión, Fintech.

Abstract

With the aim of finding the best companies to invest in the Stock Market currently, Digital Transformation is being implemented by public or private companies. Artificial Intelligence is impacting with its applications and solving problems in different areas. When the Digital Transformation reaches Finance, new companies or Fintechs are being created. In this context, we are combining Artificial Intelligence and Finance. In Finance, we follow Fundamentalist Analysis, which consists of examining the quarterly data published by companies, generally called fundamentals. These fundamentals are shared by companies and freely accessible to investors. Thus, we collect this quarterly information from companies listed on the Brazilian Stock Exchange and after processing this information we build a Database. Then, we use Artificial Intelligence algorithms to analyze our Database and find potential companies to invest in.

Keywords: Artificial Intelligence, Finance, Digital Transformation, Investment, Fintech.

Índice general

1. Introducción **9**
1.1. Contexto Científico 10
1.2. Propuesta de la Tesis 11
1.2.1. Objetivo General 11
1.2.2. Objetivos Específicos 11
1.3. Estructura de la Tesis 11

2. Marco Teórico **12**
2.1. Inteligencia Artificial 12
2.1.1. Machine Learning 13
2.1.1.1. Aprendizaje Supervisado 13
2.1.1.2. Aprendizaje No Supervisado 13
2.1.1.3. Aprendizaje por Refuerzo 14
2.1.2. Redes Neuronales 15
2.1.2.1. Deep Learning 16
2.1.3. Inteligencia Artificial Generativa 16
2.2. Finanzas 17
2.2.1. Inversionista 18
2.2.1.1. Educación Financiera 18
2.3. Empresa 19
2.3.1. Empresas que Cotizan en la Bolsa de Valores 19
2.3.2. Informes Financieros Trimestral de las Empresas 20
2.3.2.1. Balance Sheet (Balance Contable) 20
2.3.2.2. Statement of Income for the Year 21
2.3.3. Bolsa de Valores de Brasil (B3) 21
2.3.3.1. Indice Bovespa (IBOV) 22
2.4. Estrategias de Inversión 22
2.4.1. Análisis Fundamentalista 23
2.4.2. Top-Down (De Arriba Hacia Abajo) 23
2.4.3. Bottom-Up (De Abajo Hacia Arriba) 23
2.4.4. Value Investing (Inversión de Valor) 23
2.4.5. Growth Investing (Inversión en Crecimiento) 23
2.4.6. Buy and Hold (Compre y Mantenga) 23
2.4.7. Análisis Cuantitativo 24
2.4.8. Análisis Técnico 24
2.4.9. Swing Trade (Comercio Swing) 24
2.4.10. Tape Reading(Lectura de Cintas) 24
2.4.11. Gradiente Linear 24
2.5. Asset Allocation 24

3. Metodología y Desarrollo de Software para Inteligencia Artificial 26
3.1. Metodología 26
3.1.1. Empresas que hacen parte del Índice Bovespa 27
3.2. Construcción de una Base de Datos con las Informaciones Fundamentalistas de las Empresas 27
3.3. Selección de Modelos 28
3.4. Análisis Fundamentalista a Nuestra Base de Datos 29
3.5. Evaluación de Modelos de Inteligencia Artificial 30

4. Resultados 33
4.1. Comparando los Modelos 40
4.2. Validación 41

5. Conclusiones y Trabajos Futuros 43
5.1. Conclusiones 43
5.2. Trabajos Futuros 43

Referencias Bibliográficas 44

Capítulo 1

Introducción

Cada año la ciencia viene evolucionando y creando nuevas tecnologías. En estos escenarios nuevas frases vienen siendo frecuentemente usados. *Digital Transformation* o Transformación Digital utilizada para describir el proceso de incorporar estas nuevas tecnologías para resolver los problemas tradicionales en las diferentes áreas de la sociedad como: Economía, Educación, Medicina, Ciencias, entre otros [47], *Digital Disruption* o Disrupción digital para explicar los efectos de las tecnologías digitales en el sector aplicado [5] y *Disruptive Technology* para las tecnologías que más están impactando en la solución de los problemas en las diferentes áreas [22]. En la actualidad las tecnologías que están revolucionando son: Inteligencia Artificial (IA), Internet de las cosas (IoT), Realidad Virtual y Aumentada, *Streaming* de música y vídeo, entre otros. Desde el punto de vista de las Finanzas, la Transformación Digital implica el aprovechamiento de estas tecnologías digitales para mejorar las actividades financieras. Una tecnología disruptiva aplicada en las finanzas viene siendo la Inteligencia Artificial [22]. La Inteligencia Artificial posee fundamentos matemáticos sólidos desde los años cincuenta [30] y juntamente con los avances tecnológicos han posibilitado su aplicación en el mundo. Los avances tecnológicos como grande poder computacional presentes en los Supercomputadores [55] y técnicas para almacenar y procesar grande volumen de datos [29] han facilitado el uso de la IA. Los inversionistas, empresas públicas o privadas que apliquen todo este conjunto de técnicas están sobresaliendo sobre los demás e inclusive vienen siendo creadas nuevas empresas llamadas de *Fintech* para aplicar estas tecnologías en las Finanzas [50, 68]. Dependiendo del problema que estamos abordando en las finanzas contamos con algoritmos modernos y técnicas avanzadas de Aprendizaje de Máquina, *Deep Learning*, Redes Neuronales y Procesamiento de Lenguaje Natural, que nos permiten crear IAs sofisticadas. Podemos crear IAs tan complejas como queramos y procesar gran cantidad de datos de forma rápida usando los Supercomputadores. Así, podemos aprovechar los datos del mercado financiero en tiempo real para extraer *insight* valiosos y tomar mejores decisiones al identificar los sectores prometedores para realizar las inversiones [30]. Con la tesis queremos mostrar una aplicación de la la Inteligencia Artificial en las Finanzas, juntando teoría y práctica. En esta tesis, estamos interesados principalmente en una categoría de Inteligencia Artificial, llamado de Aprendizaje de Máquina, donde los algoritmos aprenden a partir de una Base de Datos etiquetados, esa base de datos será creada con los informes trimestrales de las empresas que cotizan en la Bolsa de Valores de Brasil.

1.1. Contexto Científico

En el contexto de la Inteligencia Artificial, uno de los trabajos pioneros fue la creación de la primera máquina inteligente denominado Máquina de Turing aproximadamente en el año 1936. En el contexto de las inversiones un primer intento de explicar el funcionamiento de la Bolsa de Valores fue presentado por Benjamin Graham y David Dodd en sus trabajos llamados de *The intelligent investor* [25] y *Security Analysis* [23]. Benjamin Graham es considerado padre de las inversiones y del Análisis Fundamentalista y tuvo a Warren Buffett como alumno quién aplicó Análisis Fundamentalista en sus inversiones con el objetivo de identificar las mejores empresas para invertir. De esa manera, él se convirtió en un gran inversionista. También podemos citar a grandes personas que contribuyeron con el desarrollo del Análisis Fundamentalista, entre ellos tenemos a Benjamin Grossbaum, conocido como el padre del Análisis de Seguridad Fundamentalista. Harry Markowitz, con su teoría de la diversificación, inspiró el modelo de Sharpe, que es un indicador que relaciona el riesgo y el retorno de una determinada inversión y William Sharpe alumno de Markowitz quién desarrolló el modelo llamado *Capital Asset Pricing Model*(CAPM) o modelo de valoración de activos de capital. Markowitz y Sharpe recibieron el Premio Nobel de Economía en 1990 por sus contribuciones a la teoría de carteras. Durante muchos años analizar y evaluar el crecimiento y desempeño de las empresas fue ampliamente utilizado de manera tradicional y continua siendo usado en el mundo de las Finanzas. Ahora con la fusión de la Inteligencia Artificial y Finanzas vienen dando buenos frutos. Recientemente muchos trabajos han discutido las posibles aplicaciones de estas técnicas en un entorno financiero [36]. Por ejemplo, creación de IA para resolver problemas de análisis de datos financiero, evaluación de crédito, prevención de ataques cibernéticos, servicio de atención al cliente, detección y prevención de fraudes, gestión de carteras, gestión de riesgos, análisis del sentimiento, valoración de activos, análisis fundamentalista, predicción macroeconómica con aplicaciones de *Large Language Models* (LLMs) en finanzas [37], etc. Las aplicaciones consolidadas de IA en las Finanzas [30] que atienden los entornos financieros son: La primera, es una aplicación brasileña de IA que proporciona información de la Bolsa de Valores de Brasil a los inversionistas, ayudándonos en la toma de decisiones y se llama Grana IA, el segundo se llama Magnifi y es un asistente de inversiones de IA experto para guiar nuestras decisiones de inversión, el tercero se llama Trade Ideas y es una aplicación de IA estadounidense que escanea acciones con el objetivo de identificar oportunidades de inversión y mejorar las estrategias de inversión, utiliza análisis técnico, volumen y precio de las acciones, otra aplicación estadounidense es Tickeron y usa Inteligencia Artificial para identificar activos de empresas, divisas y materias primas, otra aplicación es Black Box Stocks y su objetivo es ayudar a los inversionistas a tomar decisiones informadas de forma rápida usando Inteligencia Artificial para brindar acceso a datos en tiempo real directamente desde la Bolsa de Valores, tenemos a Zignaly que es una innovadora plataforma para quien hace *trading* con Criptomonedas, TrendSpider ayuda a los inversionistas a evitar riesgos y maximizar las ganancias, combina Análisis técnico con Inteligencia Artificial, FinChat es una aplicación de conversación de Finanzas con Inteligencia Artificial, parecido al ChatGPT *Generative Pre-trained Transformer*, tiene por objetivo resolver dudas de los inversores sobre el mercado financiero y mantiene a los inversionistas actualizados sobre las opiniones de multimillonarios, directores ejecutivos de empresas y personas influyentes en las finanzas, Kavout usa algoritmos de Aprendizaje de Máquina

para analizar datos y descubrir tendencias en los mercados financieros. Identifica en tiempo real oportunidades de inversión analizando el comportamiento de los inversionistas en las redes sociales y las noticias web. Finalmente tenemos a VectorVest usa Inteligencia Artificial con Análisis Fundamentalista para recomendar activos en la Bolsa de Valores Americana. Todos los softwares presentadas hasta el momento fueron implementados con algoritmos de IA para identificar oportunidades y riesgos en las Finanzas y usan Análisis Técnico, Análisis Fundamentalista para ofrecer apoyo en la toma de decisiones.

1.2. Propuesta de la Tesis

1.2.1. Objetivo General

El objetivo general de esta tesis es mostrar que podemos usar la Inteligencia Artificial y aplicarlo a las Finanzas para poder encontrar mejores empresas para invertir, para ello mostraremos que podemos ganar al principal indicador de la Bolsa de Valores llamado indicador Bovespa.

1.2.2. Objetivos Específicos

1. **Recopilación de datos:** Buscar en repositorios de datos las informaciones fundamentalistas de las empresas que cotizan en la bolsa de valores, podemos optar por repositorios de datos gratuitos o de pago.

2. **Limpieza y etiquetado de datos:** Realizar un tratamiento a los datos, obtener el precio de las empresas trimestralmente y crear nuestra base de datos,

3. **Aplicar la estrategia de inversión a la Base de Datos:** Con la Base de Datos creada y con todas las informaciones fundamentalistas colectadas, seleccionar las características más importantes usando la matriz de correlación, finalmente implementar la estrategia de inversión elegida.

4. **Crear modelos de Inteligencia Artificial:** Usar los algoritmos de Inteligencia Artificial para resolver el problema.

5. **Comparar los Modelos:** Implementar la matriz de confusión para evaluar los modelos creados y con las métricas definidas escoger al mejor modelo.

6. **Validar el mejor Modelo:** Comparar el desempeño de las indicaciones de compra del mejor modelo con el desempeño indicador Bovespa para demostrar que usando la Inteligencia Artificial aplicado a Finanzas, podemos ganarle a este indicador.

1.3. Estructura de la Tesis

La estructura de la tesis es: Capítulo 1, Introducción; Capítulo 2, Marco Teórico con las secciones de Inteligencia Artificial y Finanzas ; Capítulo 3, Metodología y Desarrollo de Software Para Inteligencia Artificial ; Capítulo 4, Resultados y finalmente Conclusiones y Trabajos Futuros en el Capítulo 5.

Capítulo 2

Marco Teórico

2.1. Inteligencia Artificial

Para conocer un poco de la Inteligencia Artificial(IA) debemos entender su historia y ella comienza con Alan Turing quién vivió entre los años 1912 a 1954. Uno de sus experimentos reconocidos fue el famoso *Test de Turing* cuyo objetivo era medir la capacidad que una computadora tiene cuando es comparado con la de un ser humano. Todos sus resultados científicos le sirvieron para ser llamado el padre de la Inteligencia Artificial y fueron sus contribuciones científicas que dieron la base para la existencia de la Inteligencia Artificial. Por otro lado, la palabra Inteligencia Artificial fue introducida en el mundo de la ciencia por John McCarthy en el año 1956. Uno de sus logros fue el desarrollo de un programa implementado en lenguaje de programación *list processing* (LISP) para competir con un jugador de ajedrez humano, fue una contribución científica que le sirvió para ser llamado padre del lenguaje de programación LISP. Podemos decir que la Inteligencia Artificial es el desarrollo de cualquier actividad en la que las máquinas imitan comportamientos inteligentes que suelen mostrar los humanos, es un campo amplio de la computación centrado en la creación de Agentes Inteligentes que puedan razonar, aprender y actuar de forma autónoma [66],[2]. Al momento de crear las aplicaciones es bueno pensar en las 3 categorías principales que puede llegar a ser nuestra aplicación.

- **Inteligencia Artificial Superficial (IAS):** También conocido como Inteligencia Artificial débil, esto es cuando la Inteligencia Artificial se especializa en una solo área, en algo específico.
- **Inteligencia Artificial Amplia (IAA):** También llamado de Inteligencia Artificial Fuerte, o Inteligencia Artificial de Nivel Humano. Este nivel se refiere cuando una computadora llega a ser tan inteligente como un ser humano. En términos generales seria una máquina que pueda realizar cualquier tarea intelectual de la forma que un ser humano pueda realizar.
- **Superinteligencia Artificial (AS):** En términos generales sería una máquina superinteligente que realiza actividades mejores que un genio. Nick Bostrom uno de los principales teóricos de la Inteligencia Artificial, en su trabajo titulado *Superintelligence: Paths, Dangers, Strategies* [53] define a la superinteligencia como un intelecto que es mucho más inteligente que los mejores cerebros humanos en prácticamente todos los campos, incluida la creatividad científica, la sabiduría general y habilidades sociales.

La Inteligencia Artificial es un campo de investigación muy amplio, entre las aplicaciones que podemos mencionar tenemos: Reconocimiento de Voz, Reconocimiento de Imagen, Resolución de Problemas Informados por Física, Aprendizaje por Refuerzo, Inteligencia Robótica, Procesamiento de Lenguaje Natural(NLP), Inteligencia Generativa, etc.

2.1.1. Machine Learning

Machine Learning (ML) o aprendizaje de máquina, muchas veces abreviado por las letras (ML) es una sub-área de la Inteligencia Artificial [52]. La palabra *Machine Learning* fue introducida en el mundo científico por Arthur Samuel [80] considerado pionero del aprendizaje de máquina. Así, la capacidad de adaptarse, modificar y mejorar nuestro comportamiento y respuestas es llamado de aprendizaje y maquina se refiere al sistema computacional. En ese artículo la palabra *Machine Learning* fue usada para referirse a los algoritmos que son capaces de auto-aprender [7], [54]. Así, podemos decir que *Machine Learning* significa la capacidad de un sistema computacional de aprender por sí mismo a resolver un problema concreto para la cual no tuviera instrucciones precisas por parte de su programador [67]. ML Es un subconjunto de la IA centrado en desarrollar algoritmos que puedan aprender de los datos. Es importante comprender las tres categorías generales del aprendizaje de máquina y estas tres categorías son detalladas a continuación.

2.1.1.1. Aprendizaje Supervisado

Aprendizaje de máquina supervisado es una sub-categoría del aprendizaje de maquina [52]. Esta metodología de enseñanza comienza con un conjunto de datos etiquetados [21]. La idea es representar características importantes llamadas de *features*, muchas veces representadas con la variable $\mathbf{x}$ y la variable $\mathbf{y}$ para la salida de los datos. La idea es encontrar patrones [7], relaciones entre las variables $\mathbf{x}$, $\mathbf{y}$. Una vez encontrado los patrones entre las variables el algoritmo crea un modelo que puede reproducir las mismas reglas con nuevos datos. Por eso es dicho que es un enseñanza basada en datos y fundamentándose de las ciencias matemáticas, estadística y computación consiguen crear aplicaciones o sistemas de softwares [34] que aprenden con esos datos para luego hacer predicciones importantes para datos nuevos. Por ejemplo, podemos intentar predecir cuales serian las mejores empresas que cotizan en la Bolsa de Valores de cualquier país usando un algoritmo supervisado. Podemos llegar a analizar resultados de nuestro interés buscando relaciones, patrones entre los atributos importantes de cada Empresa(informes de Estado de resultados(DRE) y balance contable (BP) que son datos que contienen informaciones de contabilidad y de como se encuentra la empresa. Usando estas informaciones como datos de entrada podemos por ejemplo clasificar las empresas con el objetivo de comprar o no comprar. Los algoritmos de aprendizaje supervisado más conocidos son: Árboles de Decisión, Regresión Linear, Regresión Logística, k-vecinos más cercanos, Máquina de Soporte Vectorial [27].

2.1.1.2. Aprendizaje No Supervisado

El Aprendizaje no Supervisado incluye todo tipo de aprendizaje donde pedimos al algoritmo de aprendizaje que extraiga conocimiento, alguna estructura significativa, relaciones implícitas, descubrir patrones ocultos, por sí misma usando los datos de

entrada [52] que le entregamos. Aquí nosotros no sabemos de antemano nuestra variable de salida y es por eso, que los algoritmos no supervisados son utilizados cuando queremos entender mejor los datos, a menudo se utiliza en un entorno exploratorio [54]. Los resultados de estos algoritmos son complicados de evaluar, difícil de saber si lo aprendido es algo valioso o simplemente encontró relaciones sin sentido. Estos algoritmos son ampliamente usados y como ejemplo podemos decir que este tipo de aprendizaje puede ser aplicado al tratar de encontrar patrones entre consumidores de una tienda e identificar grupos de clientes con alguna característica específica, otro ejemplo es usado por los bancos, aquí el aprendizaje no supervisado es poderoso y ampliamente usado para la detección de fraudes. Los algoritmos más usados son: Análisis de Componentes Principales (PCA), K-means [27].

2.1.1.3. Aprendizaje por Refuerzo

Aprendizaje por Refuerzo viene siendo ampliamente utilizado y esta metodología de aprendizaje tuvo sus inicios en el medio científico con el trabajo de A. Harry Klopf titulado *Brain Function and Adaptive Systems: A Heterostatic Theory* [40]. La idea propuesta por él entre los años 1970-1980 fue basado en la doctrina hedonista como sistema de aprendizaje y que hoy es llamado de Aprendizaje por Refuerzo [71]. Desde el punto de vista de la computación y en esta área en específica a la Inteligencia Artificial se le llama Agente. Asi, este Agente tendrá un objetivo claro y para llegar a concretizar ese objetivo el Agente deverá interactuar explorando su entorno y aprenderá a lograr ese objetivo a base de la interacción con su entorno que lo rodea. Así, el Agente será recompensado cada vez que se aproxime de su objetivo y registrará esa información como algo válido para ser repetido y recibirá una pena cada vez que se aleje de su objetivo y que también será registrado para que no lo repita otra vez [54].

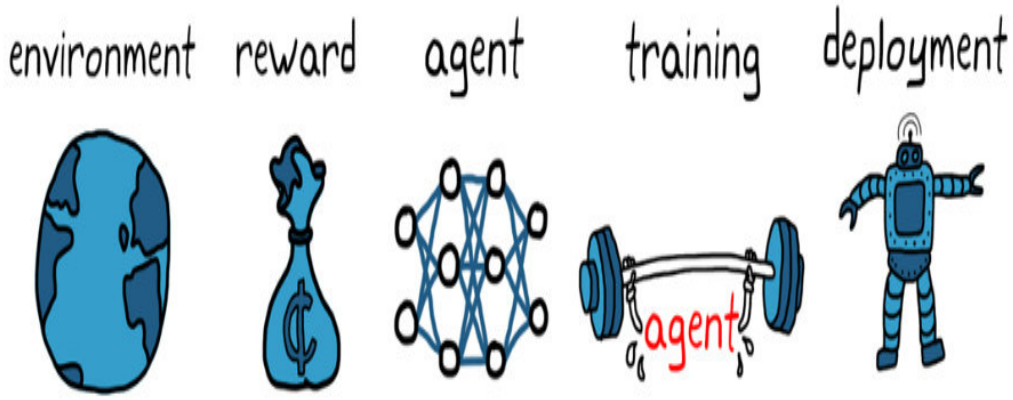


Figura 2.1: *Componentes del Aprendizaje por Refuerzo.* Fuente: MathWorks

La Figura (2.1) muestra los componentes principales que hacen parte del Aprendizaje por Refuerzo. Así, en el Aprendizaje por Refuerzo, el Agente mejora continuamente su modelo aprovechando retroalimentación de iteraciones. En la actualidad sus aplicaciones vienen siendo aplicados en los videojuegos, robótica, vehículos autónomos, etc.

2.1.2. Redes Neuronales

Las Redes Neuronales(RN) tuvieron sus inicios con Warren McCulloch y Walter Pitts y crearon un modelo computacional para estas redes basado en matemáticas y algoritmos, los resultados están detallados en su artículo *A logical calculus of the ideas immanent in nervous activit* [48]. Tiempo después Frank Rosenblatt introduce el *Perceptron* en el mundo de las ciencias, creando un algoritmo para el reconocimiento de patrones basado en una red neuronal computacional. Desde esos años, este campo viene evolucionando constantemente y creando diferentes modelos arquitecturales.

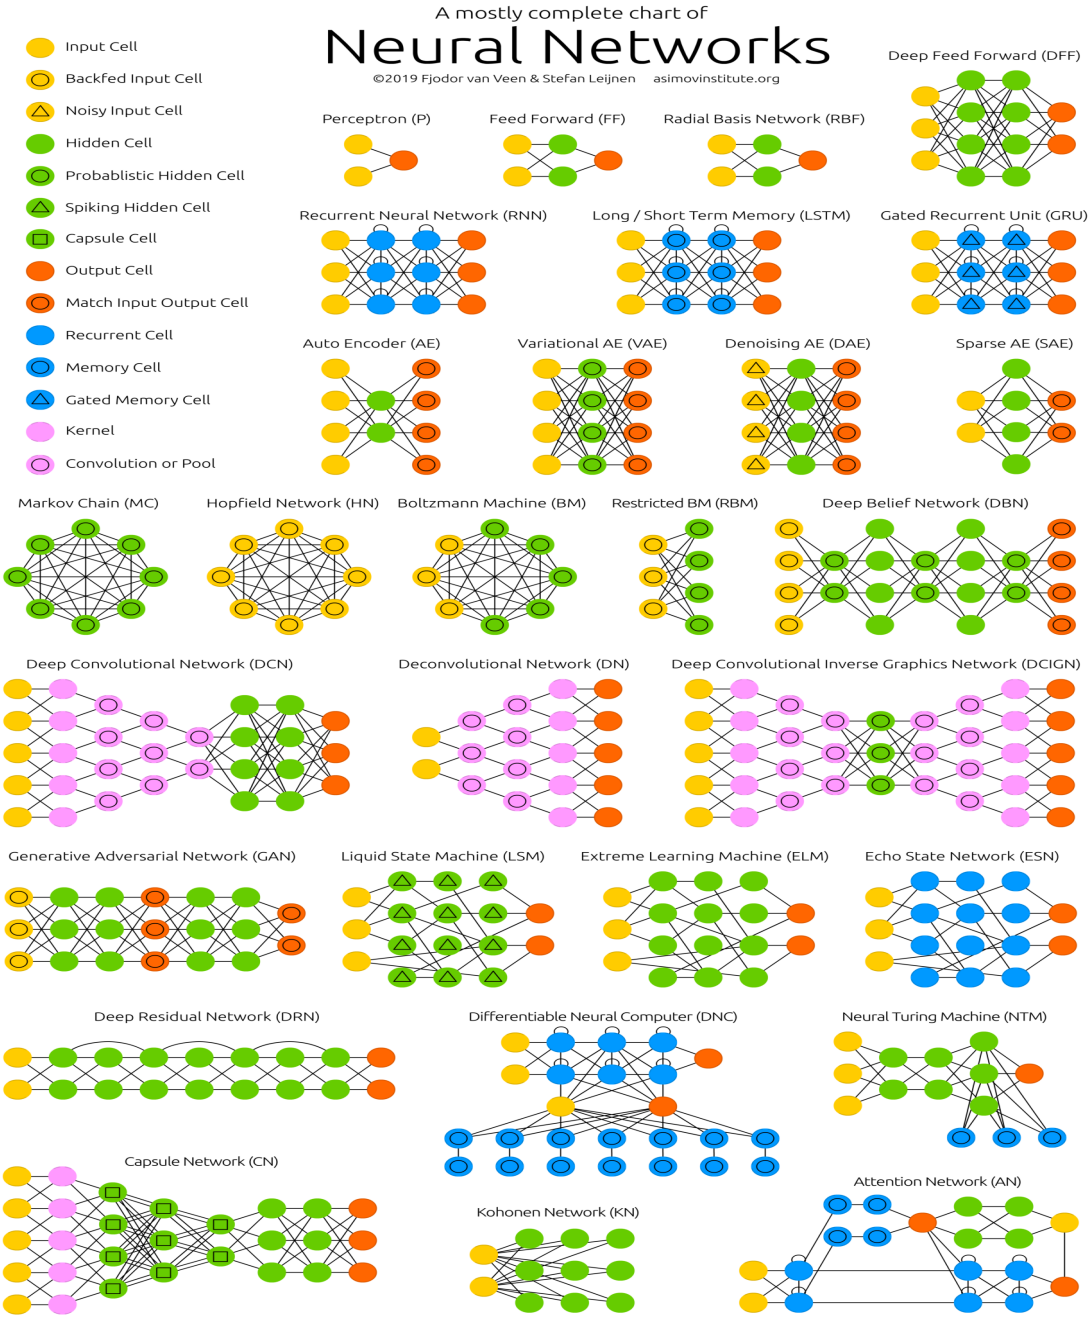


Figura 2.2: *Arquitecturas de Redes Neurales.* Fuente: Asimov

La Figura (2.2) muestra la gran cantidad de variedad de Redes Neuronales creadas hasta la fecha. Para entender su estructura debemos ver los estudios de Rosen-

blatt quién introdujo la definición del *Perceptron* con su artículo *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, de F. Rosenblatt, Psychoological 1958)* [63], presentó por primera vez varias neuronas interconectadas que fue llamado Red Neural, en este artículo fue detallado un caso especial de una red de dos capas que fue usada para realizar operaciones simples como una suma ponderada de entradas. Una versión más sofisticada fue las Redes Neuronales Multicapas presentado en el artículo *Backpropagation through time: what it does and how to do it* [78, 79]. Las Redes Neuronales artificiales representan una clase de modelos de aprendizaje de máquina y fueron inspirados en estudios sobre el sistema nervioso central [26] donde el pensamiento, la memoria y la percepción son resultados del intercambio de miles de señales en esta red. Aquí, cada red se compone de varias neuronas interconectadas, organizadas en capas, que intercambian mensajes cuando ocurren ciertas condiciones [62]. Sus aplicaciones son amplias y bastante utilizadas en diversas áreas. En las matemáticas vienen siendo implementadas para resolver ecuaciones diferenciales parciales como los trabajos detallados en [65], [28], [13].

2.1.2.1. Deep Learning

Deep Learning (DL) es una evolución de las Redes Neuronales, también llamado de Redes Neuronales Artificiales Profundas(RNA) o Aprendizaje Profundo. Los primeros algoritmos de Redes Neuronales Profundas aparecieron com Alexey Grigoryevich Ivakhnenko en su trabajo *Group method of data handling, GMDH* y Valentin Grigorevich con su trabajo *Cybernetics and forecasting techniques* [31]. De manera informal, la palabra profundo es usado para definir la presencia de muchas capas en la Red Neuronal Artificial y son ampliamente utilizados para trabajar con imágenes, sonidos y textos [26]. Con base en sus fundamentos teóricos y matemáticos pueden resolver cualquier problema [12], sin embargo desde el punto de vista computacional pueden ser lentos como por ejemplo al tratar de reconocer patrones, entre otros [18].

La Figura (2.3), ilustra la primera Red Neural Profunda que fue entrenada por Alexey Grigorevich Ivakhnenko en 1965. En resumen *Deep Learning* se caracteriza por usar muchas capas, como mecanismo para que los algoritmos de ML aprendan patrones complejos a partir de datos.

2.1.3. Inteligencia Artificial Generativa

Diferente a los algoritmos de ML e DL que usan las informaciones para analizar e interpretar datos. La Inteligencia Artificial Generativa (GenAI) es un tipo de IA que se enfoca en crear modelos y algoritmos que sean capaces de crear contenido nuevo como: texto, imágenes, música, vídeos entre otros y todo eso a partir de datos de entrada [41]. De esta forma, los modelos y algoritmos son creado con el objetivo aprender e imitar patrones de datos existentes para generar nuevos y únicos resultados. En teoría, los modelos generativos pueden implementarse utilizando una amplia variedad de algoritmos de aprendizaje [2]. Sin embargo, en la actualidad estos algoritmos son construidos con técnicas avanzadas de DL y entrenadas en arquitecturas especializadas como *Transformers* [73], pues ellas son adecuadas para procesar estos datos y entrenar de manera eficiente estos modelos [2]. Estos modelos de IA avanzados son frecuentemente usados por las diversas industrias con el objetivo de crear nuevos contenidos, entre los más usados tenemos los *Large Language Models* (LLMs) o modelos de lenguaje en grande escala que poseen una estructura para trabajar con

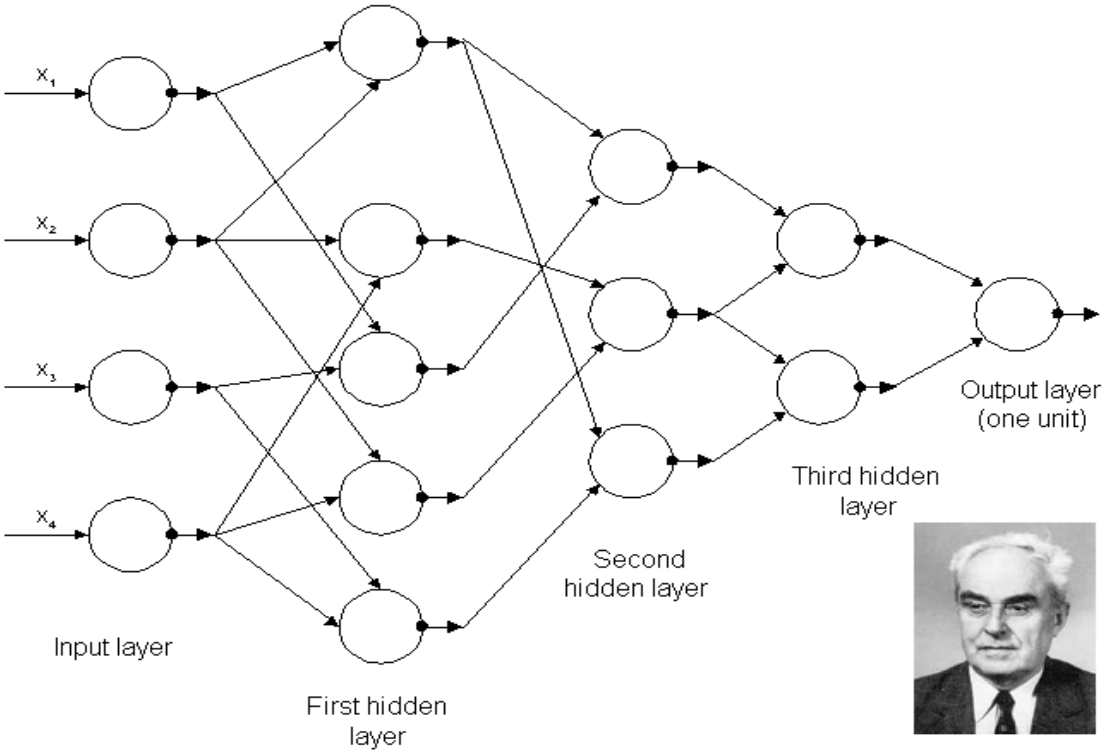


Figura 2.3: *Arquitectura de la primera Red Neural Profunda.* Fuente: DeepLearning-Book

grande volumen de datos. Generalmente estos modelos tienen parámetros en la escala de millones a billones y esto permite capturar la complexidad en los datos. En particular, estos modelos son entrenados por mucho tiempo (días, meses) con diferentes tipos de datos y para ello necesitan los recursos de procesamiento y almacenamiento que poseen los Supercomputadores. Actualmente, los modelos generativos han recibido mucha atención debido a su capacidad para generar contenido que a menudo son indistinguibles por humanos [1].

En la Figura (2.4) podemos visualizar las ramas de GenAI. En la actualidad, se están implementándo en diferentes áreas, como por ejemplo: Entrenar modelos que pueden generar imágenes realistas, crear variaciones de imágenes existentes o incluso completar partes faltantes de una imagen y también entrenar modelos generativos para la traducción de idiomas, resumen de textos y también para crear softwares inteligentes y conversacionales que producen respuestas similares a las humanas como Chat-GPT y Génesis.

2.2. Finanzas

La economía como ciencia nació en 1776, con el trabajo de Adam Smit, cuyo artículo lleva por nombre Causas y Naturaleza de las riquezas de las Naciones [69]. Este trabajo le sirvió a Adam Smit para ser reconocido como padre de la economía. Así, las Finanzas son un sub-campo de la economía y tiene por objetivo estudiar la gestión del dinero. Las Finanzas se dividen en las siguientes categorías principales: Finanzas Personales, Finanzas Corporativas, Finanzas Públicas, Finanzas Internacionales, Finanzas Sociales. En general, las Finanzas estudia el conjunto de actividades que una persona, empresa o gobierno realiza o debe realizar para acumular y generar



Figura 2.4: *Aplicaciones de la IA Generativa.* Fuente: Medium

más riquezas [17]. Un ejemplo claro es el sistema financiero de un país, donde los mercados financieros permiten el flujo de dinero, a través de inversiones públicas o privadas [72].

2.2.1. Inversionista

Un inversionista es una persona o entidad que asigna capital financiero a diferentes activos o proyectos, previo análisis exhaustivo y con el objetivo de obtener un retorno económico sin ese estudio profundo, son llamados de especuladores [25]. Bajo ese contexto los principales tipos de inversionistas son:

- **Independientes:** Un inversionista independiente es capaz de realizar inversiones por su propia cuenta, comprando los diferentes tipos de activos que existen en la Bolsa de Valores, como: *Exchange Traded Fund* (ETF), bonos, materias primas (*commodities*), criptomonedas y otros tipos de inversiones. Aquí, el inversionista independiente, conforme su experiencia con la bolsa de valores, puede crear y planificar sus propias estrategias de inversión.
- **Institucionales:** Es cuando varios inversionistas se asocian según una estrategia preestablecida para invertir, tomando decisiones inteligentes con base en un estudio previo de las empresas con una estrategia de inversión, como Análisis Fundamentalista. Generalmente hay administradores especializados que controlan toda la cuenta. Ejemplo: Fondos de Inversión.

2.2.1.1. Educación Financiera

La educación financiera permite que podamos entender conceptos financieros, aprender a desarrollar habilidades y confianza de nuestros recursos, de tal manera que podamos identificar oportunidades y saber tratar los riesgos que puedan aparecer. Con estos conocimientos y habilidades podremos tomar buenas decisiones financieras.

La educación financiera no tiene edad, esto quiere decir que todos podemos mejorar estos conocimientos en cualquier momento de nuestras vidas. Diversos trabajos [61], [75], [43] han reconocido la importancia de la educación financiera con el desarrollo económico de un país. Una comparación entre países sobre el impacto de la educación financiera y el desarrollo económico de un país puede ser visto en [14]. Así, buenos inversionistas pueden ser formados si la educación financiera pudiese comenzar en la escuela, así como lo hacen diferentes países enseñando principios básicos y buenas prácticas para que las personas sean instruidas sobre asuntos financieros.

2.3. Empresa

Una empresa es una entidad organizada de diferente tipo y tamaños, que se dedica a realizar una actividad productiva con el objetivo de satisfacer necesidades de un público. A cambio de esto, obtiene beneficios o ganancias [15].

2.3.1. Empresas que Cotizan en la Bolsa de Valores

Durante el ciclo de vida de una empresa, algunas empresas buscan recaudar dinero con el objetivo de crecer, expandirse, o algún otro objetivo. Así, algunas empresas entran a la bolsa de valores para vender parte de sus acciones a los inversionistas a cambio de dinero [15]. La primera vez que una empresa aparece en la Bolsa de Valores es llamado de *Initial Public Offering* (IPO) ou oferta pública inicial [60]. Después del IPO las acciones de la empresa comienzan a cotizar en la Bolsa de Valores y cada día esas acciones cambian de valor de acuerdo a la oferta y demanda o por otros factores [51]. Durante el proceso del IPO la empresa obtiene un código o *ticket*, este código es un identificador para que la empresa pueda negociar en la Bolsa de Valores. Así, las empresas recaudan dinero desde sus inicios y durante todo los dias que estén cotizando en la Bolsa de Valores. Un inversionista puede comprar acciones de una empresa conociendo su código o *ticket* de negociación y es necesario contratar una institución que participa de la transacción como intermediario, esta institución debe estar autorizado para realizar la compra y venta de acciones en la Bolsa de Valores. Con el objetivo de supervisar el desempeño de las acciones y analizar la salud financiera de las empresas, identificamos algunas principales categorías de empresas que cotizan en la Bolsa de Valores.

- **Empresas de Crecimiento Lento:** Son empresas que ya han alcanzado un nivel de madurez y que crecen ligeramente, ejemplo: META, NVIDIA, GOOGLE, AMAZON, etc. El punto fuerte de este tipo de empresas son los pagos de dividendos y no la revalorización de sus acciones.

- **Empresa de Crecimiento Moderado:** Son empresas que están tomando posición en la Bolsa de Valores. Ellas son llamadas de *Blue Chips* y son relativamente grandes, además de mostrar confiabilidad y crecimiento moderado.

- **Empresa de Crecimiento Rápido:** Generalmente, son empresas nuevas que iniciaron el IPO o eran pequeñas empresas que están en la bolsa y subieron muy rápidamente debido a algún factor interno o externo. Aquí la atención se centra en la apreciación de las acciones.

- **Empresa Cíclicas:** Estas empresas tienen un comportamiento oscilante, muestran un desempeño que depende de factores externos. Por ejemplo, empresas vinculadas al turismo.
- **Empresa de Recuperación:** Estas empresas también son llamados de *turn around*, ellas son empresas que están en situaciones complicadas, pero que pueden renacer pues están ejecutando algún plan para realizar cambios drásticos y obtener buenos resultados o mejoran por algún factor externo. Un ejemplo es la empresa *GameStop*.
- **Empresa com Activos Ocultos:** Son empresas que están infravaloradas y poseen activos ocultos que por alguna razón pasaron desapercibidos por los analistas. Estos activos no percibidos pueden ser inmuebles, clientes, tecnologías, patentes, entre otros [46]. Aquí, el objetivo es ganar después de la corrección del precio, identificar estas empresas e invertir en ellas puede traer buenos retornos.

2.3.2. Informes Financieros Trimestral de las Empresas

La mayoría de las empresas que cotizan en Bolsa de Valores elaboran sus informes financieros trimestrales, en estos documentos detallan sus ganancias, ingresos netos, beneficios, ventas netas entre otros. En algunos países los informes trimestrales son obligatorios como en Estados Unidos y puede que en otros países no sean obligatorios. Sin embargo, la gran mayoría de las empresas optan por compartir sus resultados financieros trimestrales para facilitar informaciones a los inversionistas .

2.3.2.1. Balance Sheet (Balance Contable)

Es un informe emitido por la empresa que contiene informaciones valiosas y muestra cómo se encuentra la empresa financieramente en ese momento [24], [8], [16].

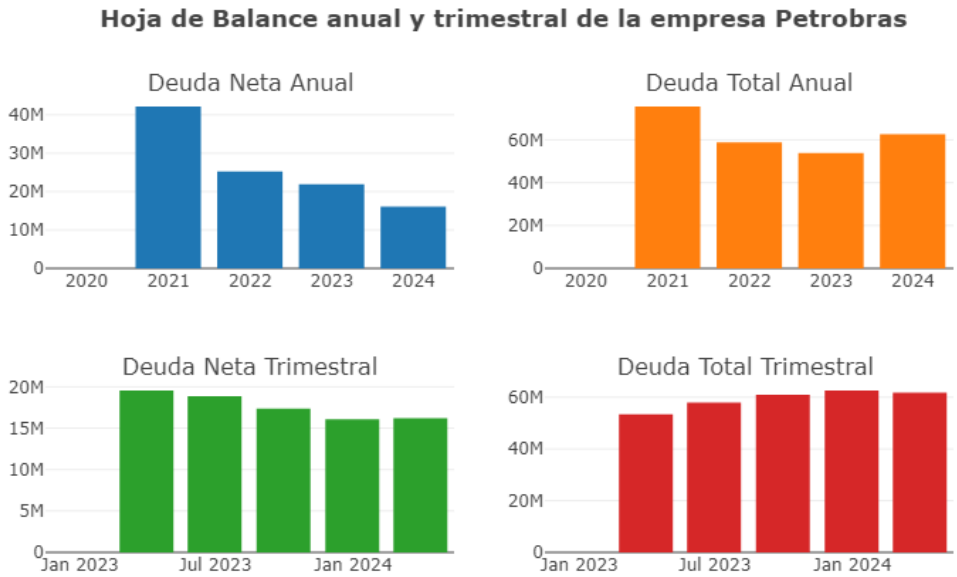


Figura 2.5: *Balance Petrobras (Elaborado por el Autor)*

La Figura (2.5) muestra el balance contable de la empresa Petrobras en millones durante los últimos 4 años y también muestra los resultados trimestrales durante los últimos dos años. Los gráficos contienen información sobre la deuda neta y trimestral.

2.3.2.2. Statement of Income for the Year

Statement of Income for the year significa Estado de Resultados del Año o *Demostração de Resultados do Exercício*(DRE) en portugués. Estos resultados financieros que las empresas entregan trimestralmente son muy importantes para los inversionistas pues contienen informaciones valiosas de la salud financiera de la empresa. Uno de los informes importantes es el EBITDA(*Earnings before interest, taxes, depreciation and amortization*), muestra la suma de las ganancias de una empresa antes de restar intereses, impuestos, depreciación y amortización, entre otros [58], [8], [33].

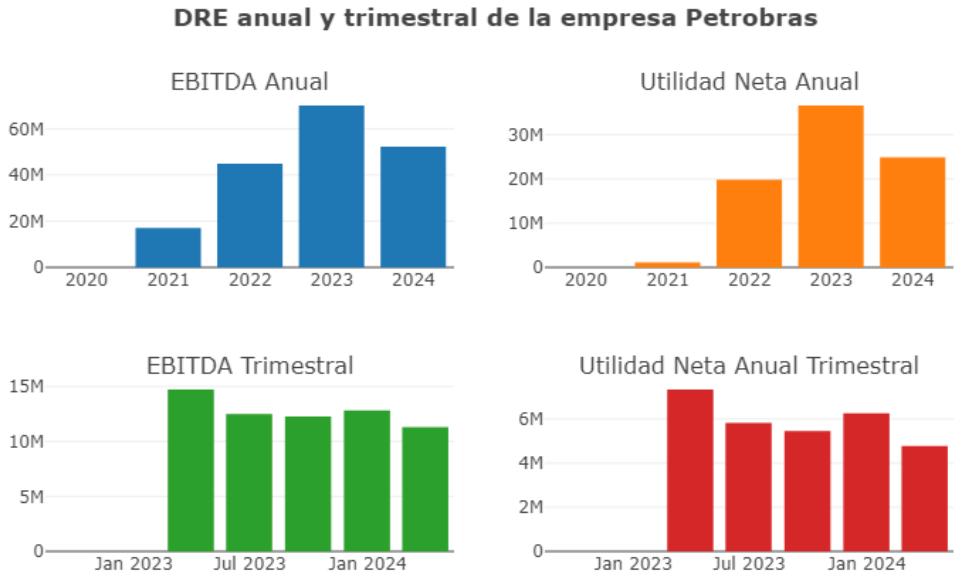


Figura 2.6: *Estado de Resultados de la empresa Petrobras (Elaborado por el Autor*

La Figura (2.6) muestra el EBITDA anual y trimestral de la empresa Petrobras y también muestra la utilidad neta de la empresa durante los últimos 4 años. Los gráficos muestran un aumento y decaimiento del EBITDA y un decaimiento de la utilidad.

2.3.3. Bolsa de Valores de Brasil (B3)

La Bolsa de Valores de Brasil, conocida como B3(*Brasil, Bolsa, Balcão*), es el lugar de comercialización en el que empresas e inversionistas sean individuales o institucionales compran y venden los activos financieros. Actualmente la bolsa de valores de Brasil ofrece alrededor de 400 empresas con acciones en libre negociación https://www.b3.com.br.

2.3.3.1. Indice Bovespa (IBOV)

La variación de un mercado financiero depende de muchos factores, puede variar según los resultados de los balances trimestrales de las empresas, precio de las materias primas, inflación, tasa de desempleo, factores políticos como cambio de un presidente y otros factores. Así, estos factores provocan movimientos en los precios de los activos que cotizan en Bolsa de Valores. Para tener una métrica de como la Bolsa de Valores se esta comportando, existe el Ibovespa (IBOV), que es el principal indicador de rendimiento de las acciones negociadas de la Bolsa de Valores de Brasil. Así, IBOV está conformado por las empresas que hayan negociado en mayor volumen durante el último trimestre. Actualmente IBOV posee 82 empresas en su composición.

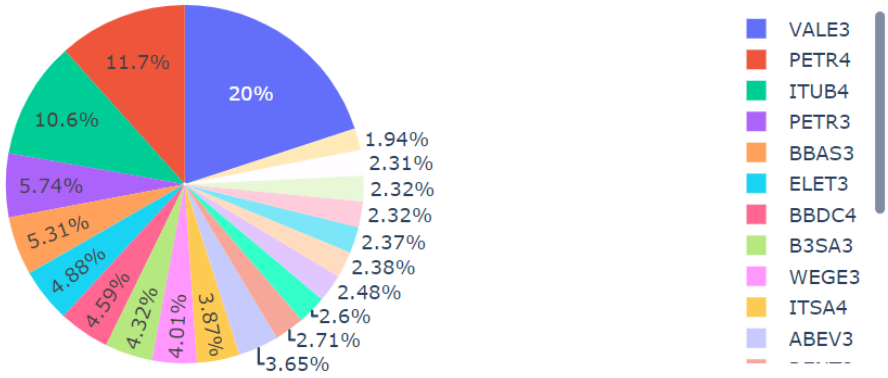


Figura 2.7: *Composición IBovespa (Elaborado por el Autor)*

Para fines didácticos, ilustramos las 20 mayores empresas que componen el IBOV en la Figura (2.7). Este diagrama nos dá la idea de como es la composición del IBOV. Donde un diagrama con las 82 empresas sería la composición total.

2.4. Estrategias de Inversión

En términos generales, inversión significa la aplicación de recursos financieros hacia una entidad o empresa con la expectativa de recibir un beneficio futuro [60], [58]. Al momento de invertir, es importante analizar detalladamente empresas en las que vamos a invertir. Quiere decir, debemos estudiar sus informes trimestrales como: ingresos, beneficios, desempeño pasado, deuda, perspectivas de crecimiento entre otros. Enseguida, debemos elaborar una estrategia de inversión que nos indicara el camino más adecuado que debemos seguir en el mercado financiero. También debemos considere otros factores como: el sector de actuación, el entorno económico, político, tendencias del mercado y noticias relevantes que puedan impactar las inversiones [9]. Así, como inversionistas debemos descubrir *insight* valiosos antes de comprar acciones de una empresa. Hoy en día existen muchas técnicas avanzadas para analizar empresas, como indicadores de una empresa [64]. A seguir detallamos algunas estrategias para encontrar ideas de inversión [11].

2.4.1. Análisis Fundamentalista

El Análisis Fundamental o Fundamentalista es una estrategia de inversión que tiene por objetivo conocer el valor razonable de una empresa. Para ello, es necesario examinar los datos trimestrales publicados por las empresas, generalmente llamado de Fundamentos y es compuesta por las informaciones que vienen en los archivos *Balance Sheet* y *Statement of Income for the year*. Estos documentos contienen informaciones valiosas para los inversionistas, como por ejemplo, volumen, liquidez, factores económicos y financieros relacionados con la empresa [16],[8]. Se trata de evaluar factores como ventajas competitivas, modelo de negocio, historial de los directivos, entre otros [51].

2.4.2. Top-Down (De Arriba Hacia Abajo)

Esta estrategia de inversión usa el enfoque de Análisis Fundamentalista, donde el objetivo es analizar el entorno macro-económico para ver su impacto sobre el mercado de acciones. Son analizados factores como: Producto Bruto Interno(PBI), tasa de desempleo, cambio de presidente, entre otros.

2.4.3. Bottom-Up (De Abajo Hacia Arriba)

Esta estrategia de inversión también usa el enfoque de Análisis Fundamentalista, donde el objetivo es analizar el entorno micro-económico para ver su impacto sobre el mercado de acciones. Son analizados factores como: Variación del precio del producto, preferencias de compra por un consumidor, etc.

2.4.4. Value Investing (Inversión de Valor)

Esta estrategia de inversión consiste en encontrar empresas con ventajas competitivas duraderas en sectores prometedores cuyo precio este por debajo de su valor real [25].

2.4.5. Growth Investing (Inversión en Crecimiento)

Esta estrategia de inversión tiene por objetivo incrementar exponencialmente el capital de un inversionista. Para ello, es necesario identificar empresas que tengan gran capacidad de crecimiento, o factores externos o internos que hagan que el precio de su acciones crezca rápidamente. Por ejemplo, las empresas que durante la pandemia fueron las encargadas por desarrollar la vacuna contra el Covid-19.

2.4.6. Buy and Hold (Compre y Mantenga)

Esta estrategia de inversión nos da la idea de convertirnos en socios de la empresa que compramos. Tiene por objetivo comprar acciones de empresas que entreguen buenos rendimientos y mantenerlas durante un largo período, a lo largo de muchos años, independientemente de las fluctuaciones de precios en el mercado [10].

2.4.7. Análisis Cuantitativo

El Análisis Cuantitativo es otra estrategia de inversión y tiene por objetivo desarrollar modelos matemáticos más complejos, modelos basados en ecuaciones diferenciales parciales y modelos estadísticos. Estos son elaborados para comprender el comportamiento de los precios y valores de las acciones, calcular riesgos y predecir tendencias [36, 59, 74]. En esta estrategia se interactúa bastante con las matemáticas, estadística, probabilidad. Todo esto combinado a la gran diversidad de datos trae nuevos desafíos para profesionales de Computación Científica, Matemática, Estadística, Ciencias de la Computación.

2.4.8. Análisis Técnico

El Análisis Técnico tiene por objetivo comprender los movimientos de precios, identificar patrones de comportamiento de los inversionistas, identificar la oferta y demanda de activos, analizar volumen de las operaciones financieras [42], entre otros. Esto se hace a través de análisis de gráficos durante un intervalo de tiempo.

2.4.9. Swing Trade (Comercio Swing)

El *swing trade* es una estrategia de inversión que se centra en monitorizar las tendencias del mercado y realizar operaciones de compra y venta de activos con el objetivo de capturar las ganancias de una acción en un horizonte de corto a mediano plazo. Para ello, realiza análisis de gráficos y las informaciones históricas del valor de los activos [74].

2.4.10. Tape Reading(Lectura de Cintas)

Tape reading es una técnica usada por los *traders* y tiene por objetivo identificar en corto plazo los puntos de soporte y resistencia, además de la dirección del movimiento de precios, en base al flujo de negociaciones de compra y venta de activos en la Bolsa de Valores [74].

2.4.11. Gradiente Linear

El Gradiente Lineal es una estrategia de inversión utilizada por los *traders* en el mercado financiero y esta relacionado con la gestión de órdenes de compra y venta de activos que realizamos. La idea es garantizar las ganancias y que se agreguen a la cuenta automáticamente cuando el precio del activo alcance o supere el valor predeterminado [4]. En esta estrategia los principales aliados son: *Stop Loss*, que es una orden de venta programada para ejecutarse cuando el precio de un activo alcanza un cierto nivel predefinido por nosotros, generalmente cuando el precio del activo disminuyo, con el objetivo de limitar las pérdidas y *Stop Gain*, que es una orden de venta que se activa cuando el precio de un activo alcanza una valor de beneficio definido por nosotros [42].

2.5. Asset Allocation

Asset Allocation o asignación de activos es una fase importante para un inversionista. Aquí, nosotros decidimos cómo distribuir nuestro dinero entre las diferentes

clases de activos que existen [20]. Por ejemplo, si tenemos un dinero total X, debemos decidir que porcentaje de ese valor vamos a destinar en la compra de los activos de una empresa, pueden ser activos de renta fija, renta variable, activos inmobiliarios, sectores industriales, etc [39],[38] e inclusive inversiones globales [19],[49]. De tal manera, que podamos equilibrar el riesgo y el retorno de nuestra cartera. En esta etapa es importante conocer nuestro perfil de inversionista que pueden ser , conservador, moderado y agresivo. Todos los activos que escogemos componen nuestra cartera de inversiones [6].

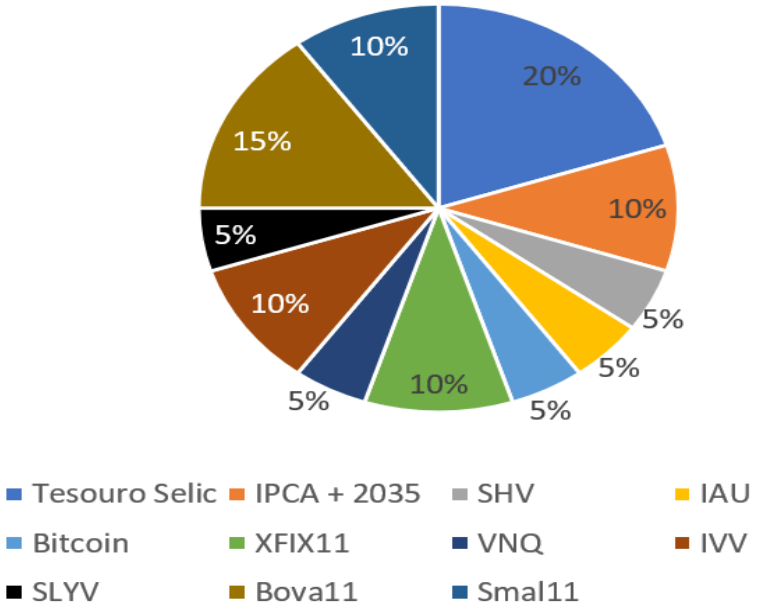


Figura 2.8: *Modelo de Cartera de Inversión* Fuente: HUB

La Figura (2.8) ilustra la composición de una cartera de inversión en Brasil, compuesta por diferentes activos y mostrando sus respectivos porcentajes.

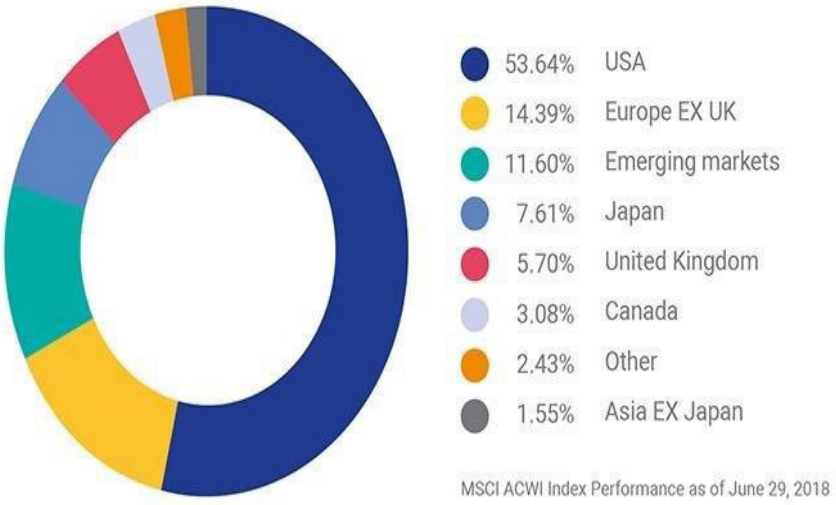


Figura 2.9: *Modelo de Cartera Global* Fuente: MSCI ACWI

La Figura (2.9) ilustra una cartera de inversión global, compuesta por el porcentaje de inversión realizada en cada Bolsa de Valores de cada país.

Capítulo 3

Metodología y Desarrollo de Software para Inteligencia Artificial

Las metodologías de desarrollo de software son un conjunto de técnicas y métodos utilizados para crear software. Dentro de las metodologías de desarrollo de software las más tradicionales son: lenguaje de modelado unificado (UML), Cascada, Desarrollo Ágil, Lean, Scrum, etc. Nuevas metodologías están siendo desarrolladas cuando combinamos *Software* e Inteligencia Artificial [34, 35, 77]. El Laboratorio de Ingeniería de Software de la Universidad Católica de Rio de Janeiro, desarrolló la metodología de *Lean Inception* que combina *Desing Thinking* con Lean *Stardup*, esta metodología ayuda a identificar el producto mínimo viable (MVP) que en nuestro caso es la creación de un aplicativo llamado de FinanzasAI. Donde el objetivo es usar Inteligencia Artificial para encontrar las mejores empresas para invertir. Así, esta aplicación facilitará a los inversionistas a tomar mejores decisiones en el mundo de las Finanzas. También tenemos *PerSpecML* que es una metodología para apoyar las especificaciones de sistemas de softwares inteligentes que requieren IA. Para resumir y conforme las indicaciones en [34] esta metodología contempla 51 preocupaciones agrupadas en 5 perspectivas: Objetivos de *Machine Learning*, Esperiencia del usuario, Infraestructura, modelo y datos. Todo junto sirve para medir la comunicación entre los representantes de negocio, especialistas de dominio, *designer*, ingenieros de *software*, especialistas en *Machine Learning* y científico de datos [76, 77].

3.1. Metodología

En el capitulo de Inteligencia Artificial fue presentado las categorías y diversos métodos de Inteligencia Artificial y en el capítulo de Finanzas fue introducido técnicas para analizar y encontrar potenciales empresas a invertir. Con el objetivo de encontrar mejores empresas, estamos combinando estas dos áreas. Así, colectamos informaciones de datos trimestrales de empresas que cotizan en la Bolsa de Valores de Brasil, especialmente empresas que siguen el indicador IBovespa. A seguir, detallamos nuestro dominio de estudio y las etapas hasta obtener los resultados.

3.1.1. Empresas que hacen parte del Índice Bovespa

El índice Bovespa o Ibovespa(IBOV) es una composición de acciones compuesta de 82 empresas en este año 2024. Este índice indica el desempeño de las acciones que tienen el mayor volumen de negociación en la Bolsa de Valores de Brasil. Por lo tanto, compararemos nuestros resultados con los resultados de esta composición de acciones teórica con el objetivo de ganar a su desempeño usando la Inteligencia Artificial. Los códigos de las empresas que siguen este índice son: ABEV3.SA, ASAI3.SA, AZUL4.SA, B3SA3.SA, BBAS3.SA, BBDC3.SA, BBDC4.SA, BBSE3.SA, BEEF3.SA, BPAC11.SA, BRAP4.SA, BRDT3.SA, BRFS3.SA, BRKM5.SA, BRML3.SA, BTOW3.SA, CCRO3.SA, CIEL3.SA, CMIG4.SA, COGN3.SA, CPFE3.SA, CPLE6.SA, CRFB3.SA, CSAN3.SA, CSNA3.SA, CVCB3.SA, CYRE3.SA, ECOR3.SA, EGIE3.SA, ELET3.SA, ELET6.SA, EMBR3.SA, ENBR3.SA, ENEV3.SA, ENGI11.SA, EQTL3.SA, EZTC3.SA, FLRY3.SA, GGBR4.SA, GNDI3.SA, GOAU4.SA, GOLL4.SA, HAPV3.SA, HGTX3.SA, HYPE3.SA, IGTA3.SA, IRBR3.SA, ITSA4.SA, ITUB4.SA, JBSS3.SA, JHSF3.SA, KLBN11.SA, LAME4.SA, LCAM3.SA, LREN3.SA, MGLU3.SA, MRFG3.SA, MRVE3.SA, MULT3.SA, NTCO3.SA, PCAR3.SA, PETR3.SA, PETR4.SA, PRIO3.SA, QUAL3.SA, RADL3.SA, RAIL3.SA, RENT3.SA, SANB11.SA, SBSP3.SA, SULA11.SA, SUZB3.SA, TAEE11.SA, TIMS3.SA, TOTS3.SA, UGPA3.SA, USIM5.SA, VALE3.SA, VIVT3.SA, VVAR3.SA, WEGE3.SA, YDUQ3.SA.

Todos los *tickets* están guardados en una lista llamada empresas_ibov, el siguiente código puede ser utilizado para descargar informaciones de estas empresas.

Listing 3.1: Código Python para obtener informaciones de las Empresas

```
  # bibliotecas:
  import yfinance as yf
  import numpy as np
  import pandas as pd
  # Loop For
for nome in empresas_ibov:
    company = yf.Ticker(nome)
    print(company.info)
```

El código (3.1) muestra como descargar informaciones financieras de las empresas, usando su *tickets* de identificación en la Bolsa de Valores de Brasil.

3.2. Construcción de una Base de Datos con las Informaciones Fundamentalistas de las Empresas

Para usar nuestro modelo de Inteligencia Artificial debemos construir nuestra Base de Datos, seguiremos las etapas del flujo de trabajo de modelos de aprendizaje de máquina ilustrado en [3]. Tenemos etapas orientadas a los datos, por ejemplo recopilación, limpieza y etiquetado y otras están orientadas a los modelos como requisitos del modelo, ingeniería de características, entrenamiento, evaluación, implementación y monitoreo.

- **Data Collection:** Para descargar las informaciones fundamentalistas de las empresas que siguen la composición IBovespa, usamos el siguiente repositorio de datos financieros llamado Fundamentus. Usando los códigos de las empresas

presentadas en la sección anterior conseguiremos descargar el histórico de estas informaciones.

- **Data Cleaning:** En esta etapa nos enfocamos en la limpieza de datos colectados en la etapa anterior, eliminamos datos incorrectos y faltantes. Durante este etapa informaciones de algunas empresas no fueron encontrado y eso pudo haber pasado por varios motivos como ser una empresa que recién este entrando en la Bolsa de Valores o por otros factores. Para nuestro análisis decidimos eliminar estas empresas sin datos fundamentalistas. Finalmente, solo quedamos con 72 empresas a analizar, también estandarizamos los datos en sus tipos *int* ou *float* y transformamos los días que estaban en formato *string* para formato *datetime* y eliminamos datos duplicados dentro de nuestro conjunto de datos.

- **Data Labeling:** Para nuestra base de datos usamos las mismas informaciones fundamentalistas para etiquetar nuestra informaciones. También creamos dos nuevas etiquetas, una de ellas para indicar el precio de la acción en el día que la empresa entrega sus datos trimestrales y otro para el resultado de nuestra decisión de comprar o vender.

- **Feature Engineering:** En esta etapa seleccionamos, manipulamos y transformamos los datos para identificar características que podamos usar en nuestro modelo.

3.3. Selección de Modelos

Una vez construida la Base de Datos con los datos fundamentalistas de las empresas, empezaremos a experimentar con varios modelos. Iniciaremos con el modelo básico o modelo *Dummy* y luego seguiremos con los modelos llamados *AdaBoost*, *Decision Tree*, *Random Forest*, *ExtraTree*, *Gradient Boost*, *K Nearest Neighbors (KNN)*, *Logistic Regression*, *Naive Bayes*, *Support Vector Machine (SVM)*, *Rede Neural*. Usando las métricas como: *precision*, *recall* y *F1-Score* evaluamos el desempeño de nuestros modelos. En este trabajo elegimos la precisión pues esta métrica nos indica de todo lo que mi modelo dijo para comprar cuantas realmente acertó. A continuación, detallamos algunos pasos importantes.

- **Model Training:** Esta es la etapa en la que se entrena el algoritmo ML usando la Base de Datos construida. Aquí, es donde inicia el proceso de aprendizaje de nuestra Inteligencia Artificial.

- **Model Evaluation:** Utilizaremos métricas para evaluar nuestro modelo de IA. Las métricas más usadas son precisión y *recall*. En las finanzas es más importante seguir la métrica de la precisión.

- **Parameter Tuning:** En esta etapa los algoritmos de Inteligencia Artificial poseen opciones para mejorar sus parámetros e hiperparámetros. Aquí, los parámetros del modelo se ajustan internamente con los datos durante el entrenamiento. Los hiperparámetros los definimos externamente y podemos modificarlos para optimizar nuestros modelos.

- **Model Deployment:** Es el proceso de integración del modelo en un entorno de producción. Aquí, el modelo recibe y procesa nuevos datos y, después de

analizarlos, devolverá una respuesta al usuario. De esta forma, el modelo ya entrenado se pone a disposición de otros usuarios.

- **Model Monitoring:** El monitoreo de modelos es un proceso continuo, que viene despues de la integración del modelo en su entorno de producción. La idea es hacer un seguimiento al modelo, analizando y evaluando su rendimiento y comportamiento del modelos en el mundo real, es decir su entorno de producción. Aquí, debemos analizar detalladamente para garantizar que los modelos sigan siendo precisos, confiables y efectivos a lo largo del tiempo.

3.4. Análisis Fundamentalista a Nuestra Base de Datos

Una vez construida nuestra base de datos con los Fundamentos de las empresas que cotizan en la Bolsa de Valores y con base en el Análisis Fundamentalista explicado en la sección de Finanzas , podemos formular los criterios para que nuestra IA pueda identificar patrones importantes. En nuestro caso identificar las mejores empresas para invertir. Detallamos a continuación los criterios usados para que la IA pueda tomar decisiones. La idea es analizar las informaciones que están en nuestra Base de Datos. Para ello, necesitamos entender como fue su evolución histórica de esos datos para cada empresa. Como son informaciones trimestrales, podemos cuantificar la variación en cada trimestre y calcular en términos de porcentaje.

$$Incremento\,\% = 100 \cdot \frac{Final - Inicial}{|Inicial|}, \tag{3.1}$$

$$Disminución\,\% = 100 \cdot \frac{Inicial - Final}{|Inicial|}. \tag{3.2}$$

Las ecuaciones (3.1) y (3.2) son fórmulas para calcular el crecimiento o decrecimiento en términos de porcentaje. Nuestra Base de Datos contiene **Fundamentos** trimestrales de las empresas y también el valor de **Cotización** de la empresa en la Bolsa de Valores. Para aplicar estas ecuaciones a nuestra BD, definamos 3 categorías. Anterior, Actual y Futuro. Así, dado una línea de tiempo para los fundamentos y cotizaciones, sea i un instante de tiempo de la discretización de la línea, definimos: $f_{i-1}, f_i, f_{i+1}, c_{i-1}, c_i, c_{i+1}$ donde $fundamento_trimestral_anterior = f_{i-1}$, $fundamento_trimestral_actual = f_i$, $fundamento_trimestral_futuro = f_{i+1}$ y hacemos lo mismo para las cotizaciones. Finalmente, detallamos a continuación los criterios para tomar decisiones con base en estas informaciones trimestrales.

$$Fundamento\,\% = 100 \cdot \frac{f_i - f_{i-1}}{|f_{i-1}|}, \tag{3.3}$$

$$Cotización\,\% = 100 \cdot \frac{c_{i+1} - c_i}{|c_i|}. \tag{3.4}$$

El objetivo de la IA es identificar que empresas comprar. Para conseguir eso, estas ecuaciones son aplicadas e interpretadas de la siguiente manera. Aplicando la ecuación (3.3) a los Fundamentos, quiere decir dado un instante i conocemos todos los Fundamentos del pasado de una Empresa y con eso podemos calcular en porcentaje

de cuanto creció el Fundamento en relación al Fundamento anterior. Para validar, si nuestra decisión de compra o venta de un activo fue buena, utilizaremos la ecuación (3.4). Estos son criterios importantes que el modelo de IA usará para encontrar las mejores empresas para invertir.

3.5. Evaluación de Modelos de Inteligencia Artificial

El rendimiento de los modelo de IA en especial los de clasificación, pueden ser evaluados usando la matriz de error, más conocido como Matriz de Confusión. Esta matriz es cuadrada para N clases y tiene dimensión NxN. En esta matriz se coloca el número de predicciones correctas e incorrectas que obtuvo el modelo por cada clase. Así, la Matriz de Confusión nos da informaciones para calcular los errores cometidos por el modelo y también ayuda a evaluar y hacer comparaciones con otros modelos. Al mismo tiempo, las métricas identifican y nos dicen que tan bien el modelo esta haciendo su trabajo. Los componentes principales de la Matriz de confusión son: *True Positives (TP)* o verdaderos positivos, indica la cantidad de instancias que un modelo predijo correctamente como positivas; *True Negatives (TN)* o verdaderos negativos, indica la cantidad de instancias que un modelo predijo correctamente como negativas; *False Positives (FP)* o falsos positivos, también conocido como error de tipo I, indica la cantidad de instancias que un modelo predijo incorrectamente como positivas; *False Negatives (FN)* o falsos negativos, conocido como error de tipo II, indica la cantidad de instancias que un modelo predijo incorrectamente como negativo. Usando todo eso, es posible representar en términos de tasas. Tenemos, *True Positive Rate*(TPR) o tasa de verdaderos positivos es la relación entre *TP/(TP+FN)*, donde *(TP+FN)* es el número total total de positivos. Nos indica la proporción de casos positivos que están bien detectadas por el modelo también conocido como *Recall* o *Sensivity*; *False Negative Rate*(FNR) o tasa de falsos negativos es la relación *FN/(TP+FN)*, donde *(TP+FN)* es el número total de positivos. Nos indica la proporción de casos positivos que el modelo detecto como negativo; *True Negative Rate*(TNR) o tasa de verdaderos negativos es la relación entre *TN/(TN+FP)*, donde *(TN+FP)* es el número total de negativos. Nos indica la proporción de casos negativos que son bien detectadas por el modelo, conocido como *Specificity* ; *False Positive Rate*(FPR) o tasa de falsos positivos, es la relación entre *FP/(TN+FP)*, donde *(TN+FP)* es el número total de negativos. Nos indica la proporción de casos negativos que el modelo detecta como positivos. A seguir ilustramos la Matriz de Confusión.

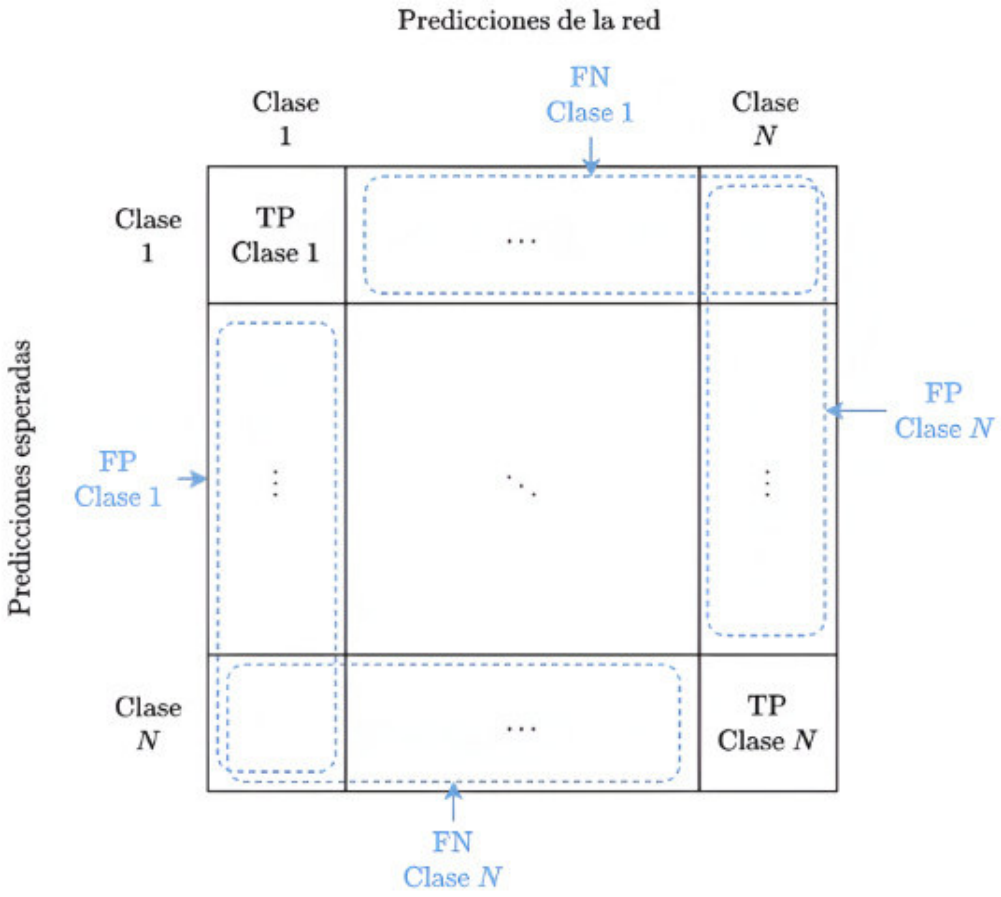


Figura 3.1: *Matriz de Confusión para N Clases*, Fuente: [57]

La Figura (3.1) ilustra la forma general de una Matriz de Confusión para N Clases. Para nuestro caso, tenemos las clases de comprar y vender. Entonces, nuestra matriz se convierte en una matriz cuadrada.

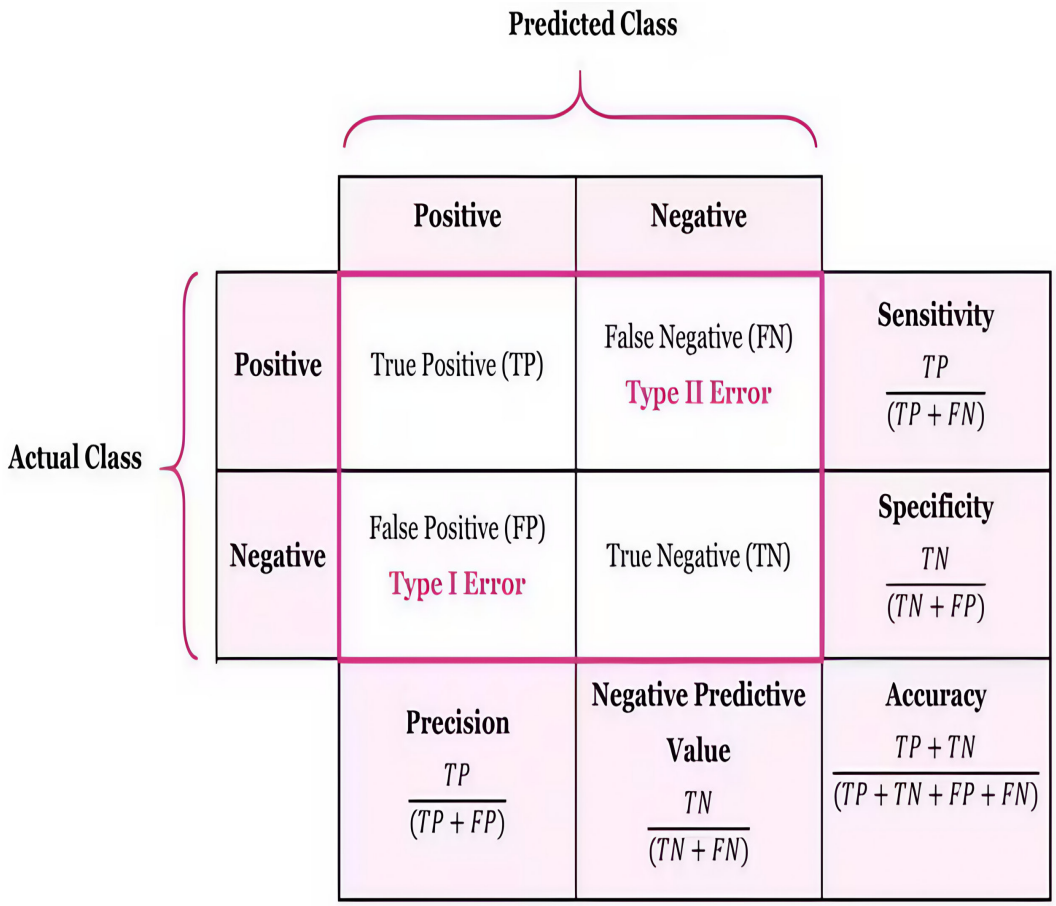


Figura 3.2: *Matriz de Confusión para 2 Clases*, Fuente: Medium

La Figura (3.2) ilustra a la Matriz de Confusión, esta matriz es un caso particular del caso general que está ilustrado en la Figura (3.1). Cuando se tienen 2 clases definidas como positiva y negativa tenemos una matriz cuadrada de tamaño 2x2 y para nuestro caso la clase positiva y negativa representan las opciones de vender y comprar respectivamente. La matriz cuadrada de tamaño 2x2 posee otras métricas importantes que detallamos a continuación: *Accuracy* ou exactitud, sirve para saber la proporción de predicciones que el modelo clasificó correctamente. Este valor es informativo y no es confiable cuando tenemos clases muy desbalanceadas; *Precision* es otra métrica y nos indica, de todo lo que dijo mi modelo que era positivo, cuantos realmente acertó mi modelo. Por eso, esta métrica es importante cuando queremos encontrar mejores empresas para invertir; Finalmente tenemos otra métrica llamada de *F1-score* ou puntuación F1, esta métrica indica el rendimiento predictivo de un modelo. Se calcula usando *precision* y *recall*. Por lo expuesto, en este trabajo nos enfocamos en evaluar y comparar los modelos en función de la precisión.

Capítulo 4

Resultados

En este capítulo, presentamos los resultados de los diferentes modelos. Nuestra BD, construida con los Fundamentos de las empresas que cotizan en la Bolsa de Valores, es utilizada para el entrenamiento de modelos de IA. La idea es entrenar nuestro conjunto de datos con el objetivo de entender los Fundamentos de las empresas y en base a esto poder identificar las mejores empresas para invertir. Los resultados de esta etapa llegan a la creación de un software de IA con reglas y estructuras de datos específicas.

- **Modelo Dummy**: El modelo de clasificación llamado *Dummy* es un modelo simple y básico que se usa para realizar comparaciones con otros modelos de clasificación más elaborados. Este clasificador para realizar sus predicciones se basa en las siguientes opciones para clasificar como: el valor más frecuente, aleatorio, uniforme, constante, entre otros. Los resultados obtenidos con esta estrategia son presentados en la siguiente Matriz de Confusión:

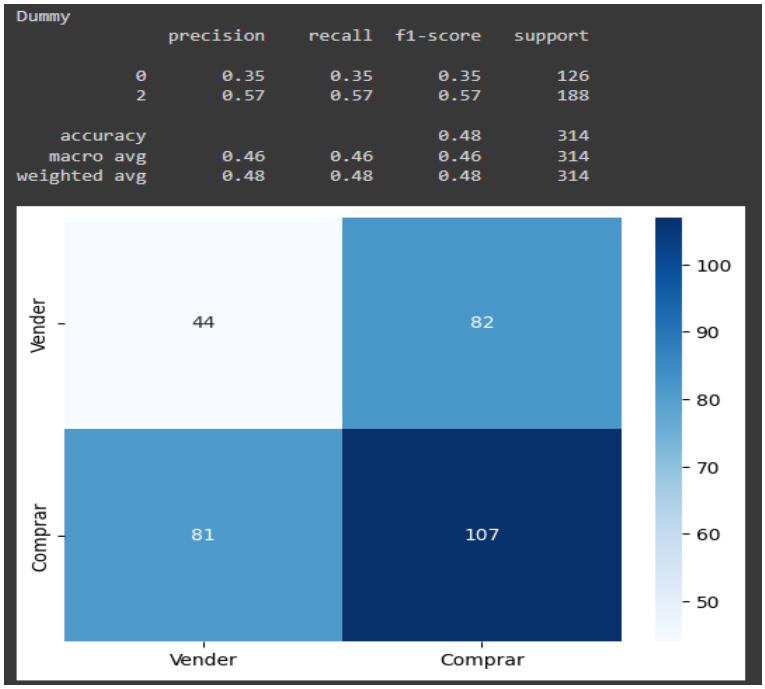


Figura 4.1: *Resultados del Modelo Dummy*

Los resultados del clasificador *Dummy* pueden ser visualizados en la Figura (4.1) que muestra el resultado de la Matriz de Confusión. Estos resultados lo

interpretamos de la siguiente manera: TP[44]: Indica la cantidad de instancias que un modelo predijo correctamente como vender(positivas) TN[107]: Indica la cantidad de instancias que un modelo predijo correctamente como comprar(negativas) FP[81]: Indica la cantidad de instancias que un modelo predice incorrectamente como vender(positivas) FN[82]:Indica la cantidad de instancias que un modelo predice incorrectamente como comprar(negativo). Con esos valores son calculados las métricas mencionadas y obtenemos un valor de 0.57 de precisión para este clasificador.

- **Modelo Decision Tree**: Un árbol de decisiones es una estructura de datos compuesta por nodo raíz, ramas, nodos internos y nodos hoja. Usando varios cálculos matemáticos el algoritmo crea una representación de las características que están en nuestro conjunto de datos y los transforma en una estructura de árbol jerárquica. En nuestro caso puede ser interpretado como un árbol binario, pues estamos interesados en comprar y vender un activo de una empresa.

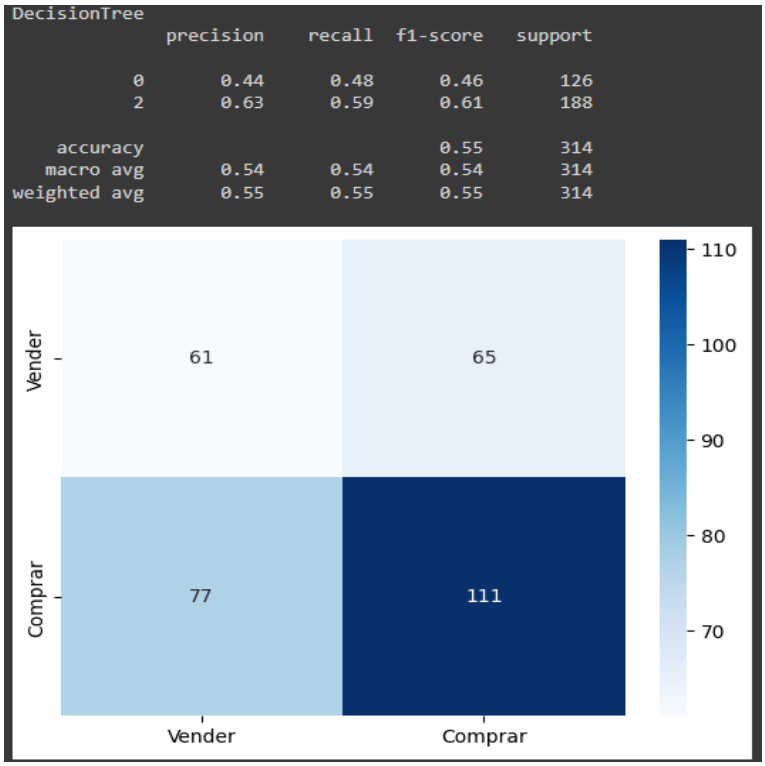


Figura 4.2: *Resultados del Modelo Decision Tree*

Los resultados de este modelo son ilustrados en la Figura (4.2). La Matriz de Confusión nos entrega un valor de 0.63 de precisión.

- **Modelo AdaBoost**: Para entender *Adaboost* debemos entender los algoritmos de clasificación débil y se dice débil pues es un algoritmo mejor que un algoritmo que simplemente nos da respuestas aleatorias. Así, *Adaboost* utiliza varios algoritmos de clasificación débil y consigue obtener un mejor modelo combinándolos. Los parámetros más importantes son: *base_estimator* es el algoritmo utilizado para entrenar modelos débiles, *n_estimators* es la cantidad de modelos que utilizará para el entrenamiento, *learning_rate* es la tasa de aprendizaje.

  La clase classificador *AdaBoost* usa la BD y parámetros de entrada para realizar la clasificación. Como modelo predeterminado utiliza árboles de decisión y

podemos modificar los parámetros con otro tipo de especificaciones.

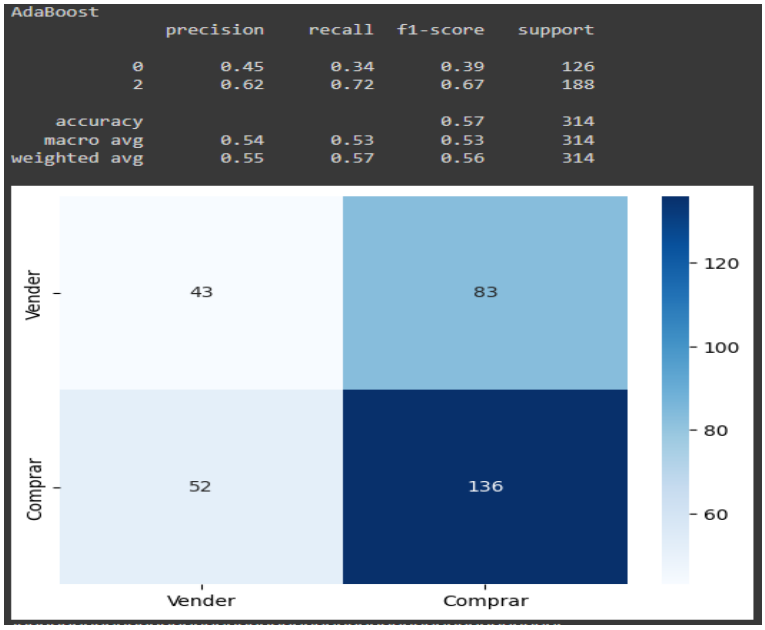


Figura 4.3: *Resultados del Modelo AdaBoost*

La matriz de confusión del modelo *Adaboost* se muestra en la Figura (4.2). Se obtuvo un valor de precisión de 0.62.

- **Modelo Random Forest**: El modelo *Random Forest* tiene la característica de ser un algoritmo robustos y complejo, y por esos suele ser computacionalmente más costoso.

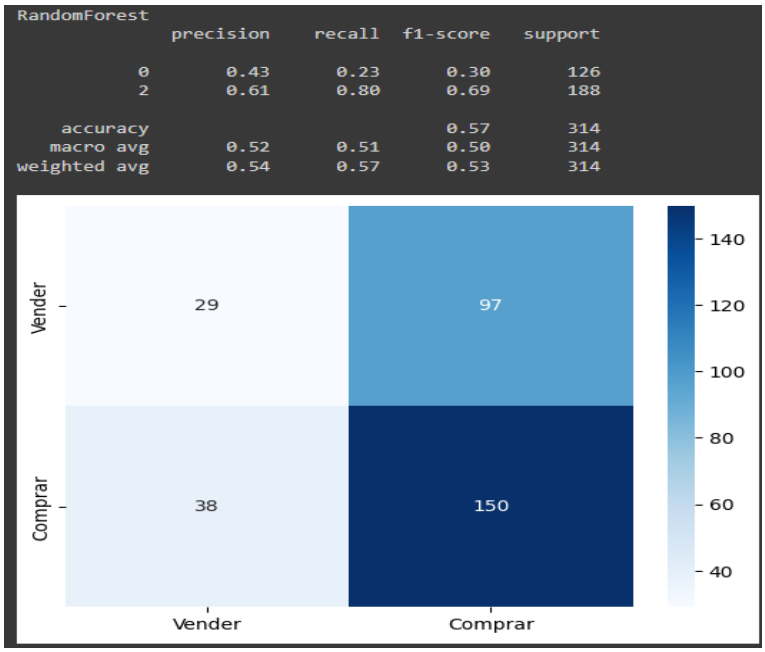


Figura 4.4: *Resultados del Modelo Random Forest*

La estructura de *Random Forest* consiste en crear de forma aleatoria muchos árboles de decisión para obtener un único resultado. A este conjunto de árboles

se le llama bosque y la respuesta del algoritmo en una especie de votación obtenida a través de la decisión de cada árbol. Con este modelo obtuvimos una precisión de 0.61 y los resultados son presentados en la Figura (4.4).

- **Modelo ExtraTree**: El modelo *ExtraTree* crea árboles de decisión de forma aleatoria, de la misma forma que el modelo *Random Forest*. La diferencia entre los dos radica en la cantidad de procesos aleatorios utilizados en cada algoritmo llamado de factor de aleatoriedad.

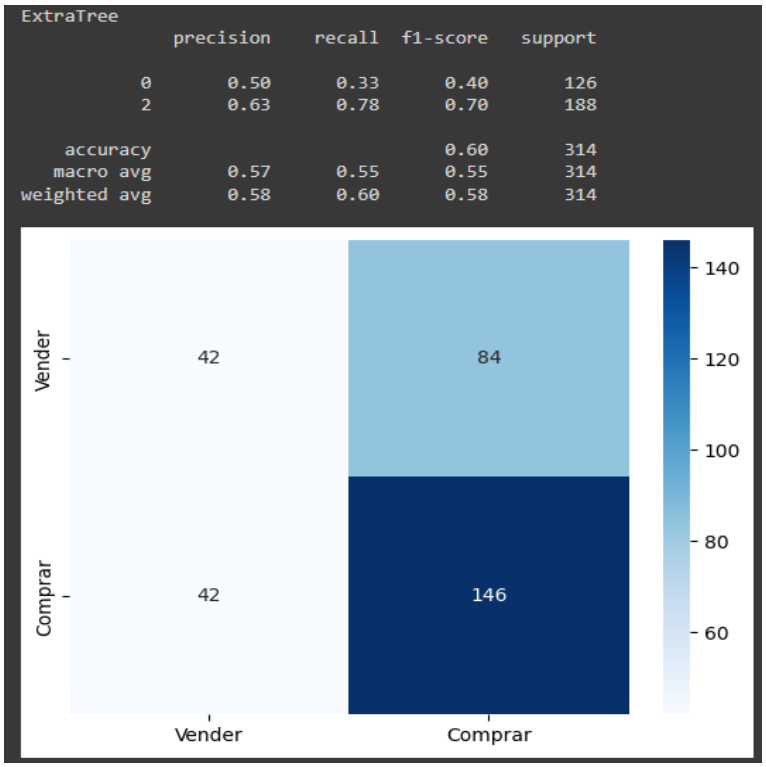


Figura 4.5: *Resultados del Modelo ExtraTree*

Con este modelo obtuvimos una precisión de 0.63 y es ilustrada en la Figura 4.5).

- **Modelo Gradient Boost**: El modelo *Gradient Boost* realiza su clasificación ensamblando otros modelos de clasificación, generalmente son árboles de decisión. Dentro de su estructura, tiene por objetivo combinar modelos débiles para crear modelos fuertes. En conjuntos de datos grandes y complejos el modelo *Gradient Boost* se destaca por su velocidad y precisión de predicción.

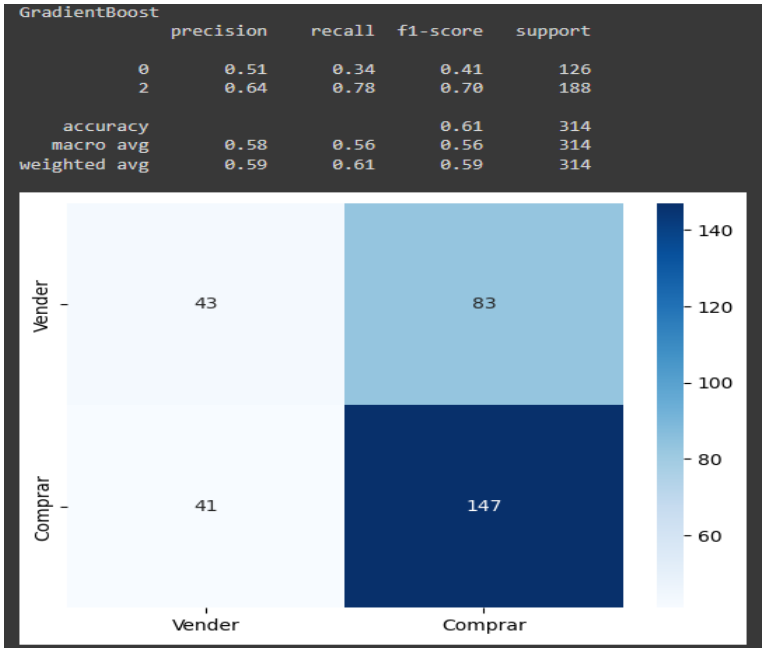


Figura 4.6: *Resultados del Modelo Gradient Boost*

Para nuestro conjunto de datos el modelo *Gradient Boost* obtuvo una precisión de 0.64 conforme muestra el gráfico en la Figura (4.6).

- **Modelo K-Nearest-Neighbors (KNN)**: El modelo KNN es un clasificador donde el aprendizaje se basa en similitud. La idea es identificar qué tan similar es un dato a otro. Generalmente se trabaja en la formada vectores n-dimensionales para luego usar cálculos matemáticos y medir la distancia entre ellos. Finalmente son agrupados los datos en función de distancias.

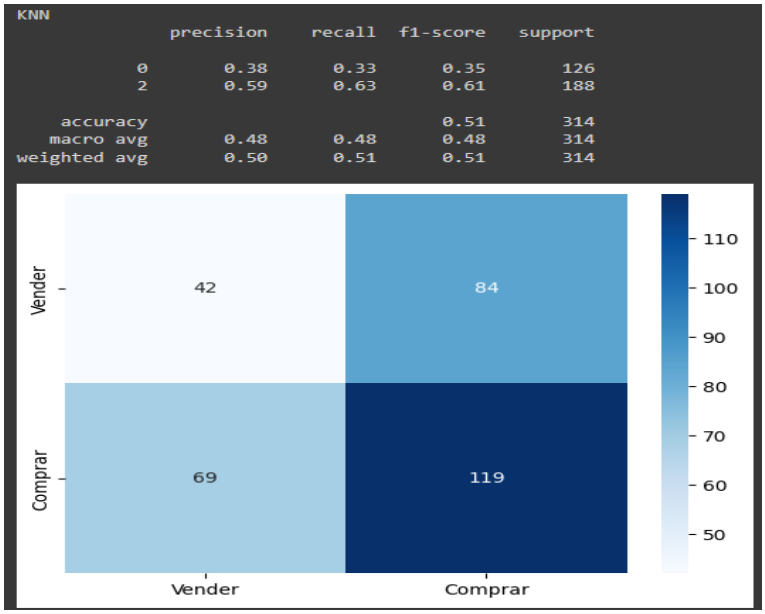


Figura 4.7: *Resultados del Modelo K-Nearest-Neighbors (KNN)*

La Figura (4.7) ilustra el valor de 0.59 de precisión obtenida por el modelo KNN .

- **Modelo Logistic Regression:** El modelo de clasificación *Logistic Regression* o Regresión Logística analiza la relación entre dos factores de datos para predecir la probabilidad de que una instancia pertenezca o no a una clase determinada.

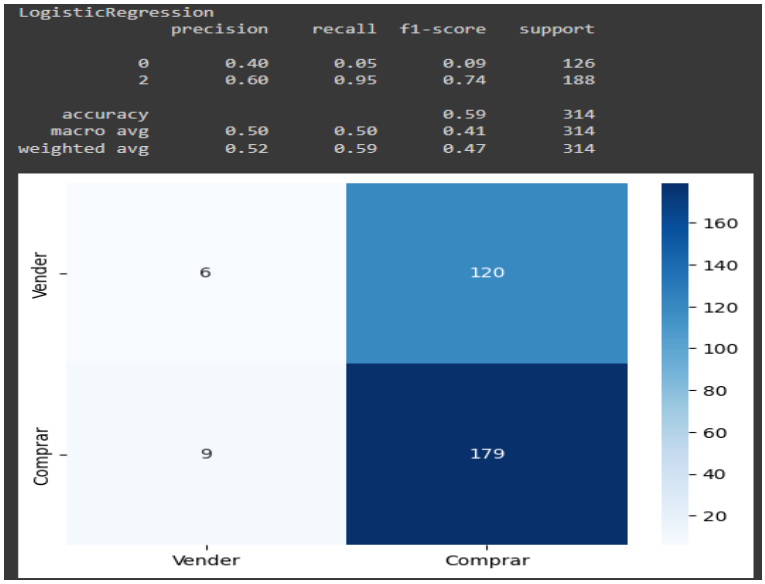


Figura 4.8: *Resultados del Modelo Logistic Regression*

La Regresión Logística es un modelo estadístico que se utiliza para analizar y predecir resultados binarios y en nuestro caso el hecho he comprar y vender una acción puede ser visto como la forma de predecir un resultado binario. En base a esto obtuvimos una precisión de 0.60 e ilustramos en la Figura (4.8).

- **Modelo Naive Bayes:** El modelo *Naive Bayes* hace parte de otros algoritmos que usan el teorema de Bayes. Este algoritmo supone independencia de características y todas son igualmente importantes para el resultado y de esa forma analiza las características de los datos y por eso es llamado de clasificador *Naive* o ingenuo.

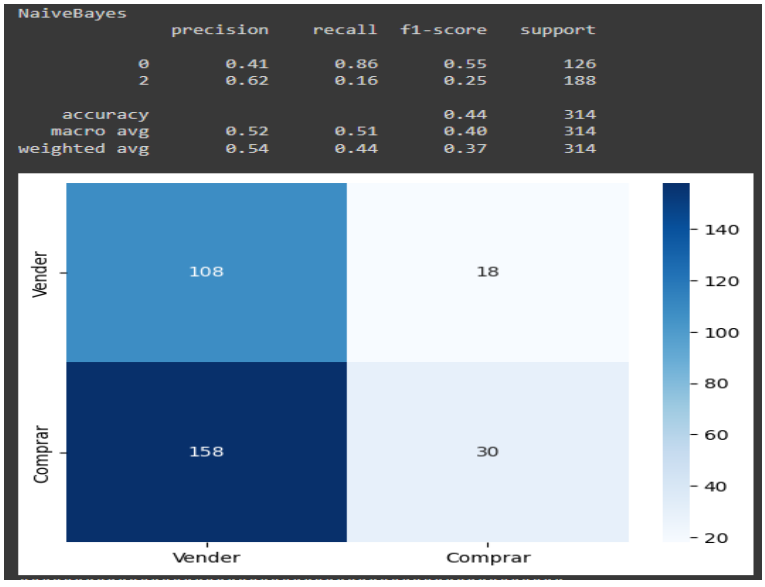


Figura 4.9: *Resultados del Modelo Naive Bayes*

Este modelo es bastante utilizado para problemas de clasificación por su velocidad para clasificar gran cantidad de datos. Para nuestro caso este modelo obtuvo una precisión de 0.62 e ilustramos los resultados en la Figura (4.9).

- **Modelo Support Vector Machine (SVM):** El modelo *Support Vector Machine* es un potente algoritmo y es bastante usado para clasificar datos. Su objetivo de este algoritmo es encontrar el hiperplano óptimo que pueda separar los puntos de datos en diferentes clases.

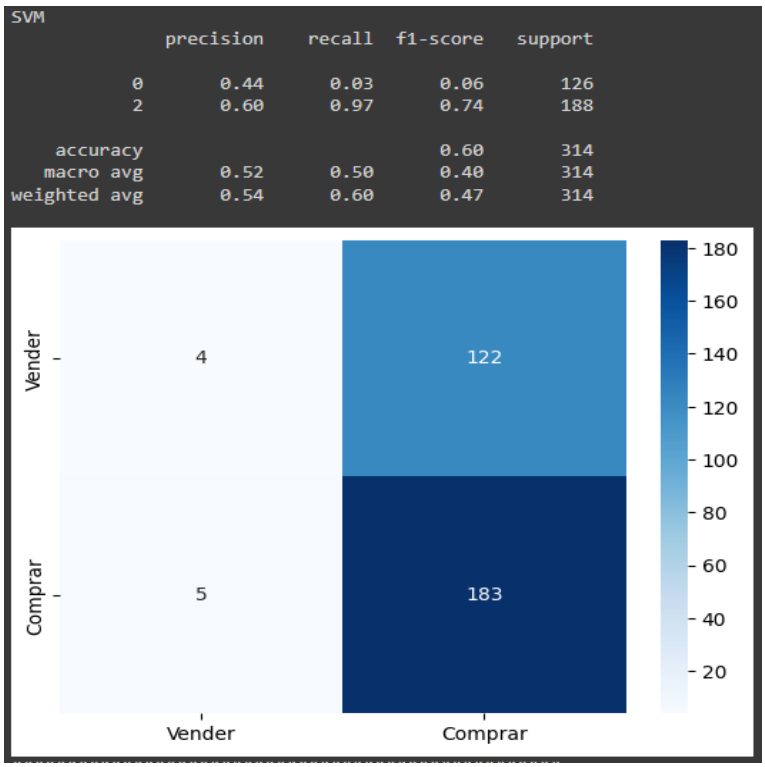


Figura 4.10: *Resultados del Modelo Support Vector Machine (SVM)*

El modelo SVM en nuestro caso puede ser interpretado como encontrar el hiperplano que divida y clasifique empresas a comprar o vender, como solo tenemos dos clases para nuestro caso el hiperplano seria una línea que divida estas dos clases. Los resultados con este modelo son ilustrados en la Figura (4.10). Así, obtuvimos una precisión de 0.60.

- **Modelo Red Neural**: Los modelos de Redes Neurales pueden trabajan con diferentes tipos de datos y modelan relaciones no lineales complejas entre las características de entrada y las etiquetas de salida. Por eso, los modelos de RN realizan clasificaciones complejas. Como fue explicado en la sección de Inteligencia Artificial existen varias arquitecturas de RNs. Una de ellas es un tipo especial de Red Neuronal *feedforward* o también denominado perceptrón multicapas (MLPs). Los MLPs constan de al menos tres capas, una capa de entrada, una capa de salida y una ou varias capas de procesamiento donde todas las neuronas estan completamente conectadas y utilizan una función de activación. Los parámetros importantes de la clase MLPclassifier son la función de activación, función de optimización, tasa de aprendizaje, número de iteraciones y número máximo de iteraciones.

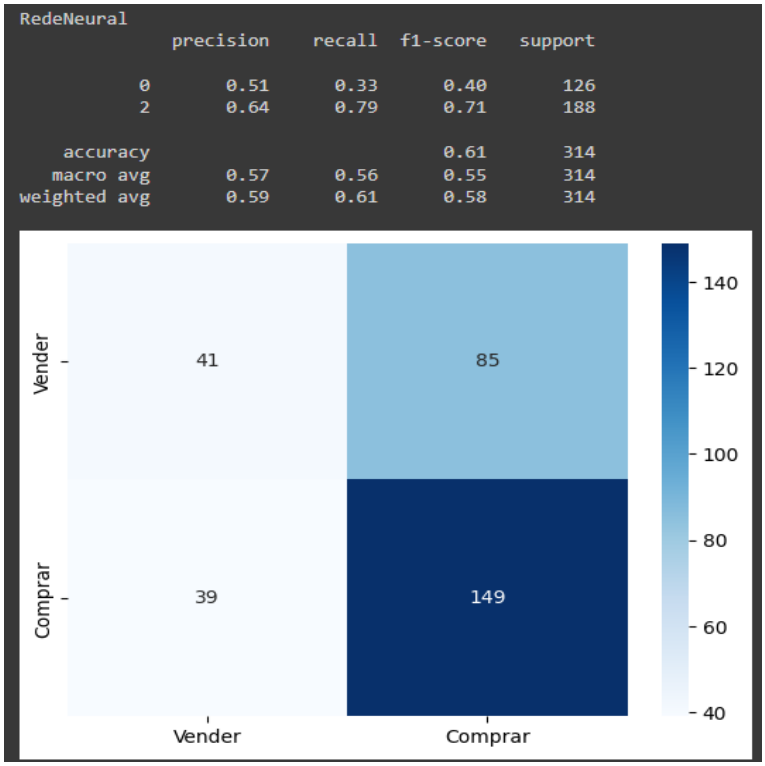


Figura 4.11: *Resultados del Modelo Red Neural*

Los resultados de la Matriz de Confusión para el modelo de Red Neural es ilustrado en la Figura (4.11), donde obtuvimos un valor de 0.64 de precisión.

4.1. Comparando los Modelos

Existen varias métricas para evaluar el desempeño de los modelos de IA. Para nuestra caso estamos interesados en encontrar el mejor modelo que predijo más empresas para invertir. Así, la métrica precisión nos indica de todo lo que mi modelo dijo para comprar cuantos empresas realmente acertó mi modelo. A continuación, mostramos los resultados en la siguiente tabla.

Description	**Precisión**
IA_Dummy	0.57
IA_AdaBoost	0.62
IA_ Decision_Tree	0.63
IA_Random_Forest	0.61
IA_ExtraTree	0.63
IA_Gradient_Boost	**0.64**
IA_KNN	0.59
IA_Logistic_Regression	0.60
IA_Naive_Bayes	0.62
IA_SVM	0.60
IA_Red_Neural	**0.64**

Cuadro 4.1: Tabla de comparacíon de de precisión de los Modelos de IA

La Tabla (4.1) muestra la precisión que obtuvieron los modelos de IA. Observamos que los modelos implementados con *GradientBoostingClassifier* y *MLPClassifier* obtuvieron una precisión de **0.64**.

4.2. Validación

Para validar nuestro modelo, simularemos las recomendaciones de activos de empresas que nos recomienda la IA en el día 2023-09-29 y validamos con el histórico IBovespa después de 3 meses, exactamente en el día 2023-12-28. Escogemos estos días pues son días laborables de la bolsa de valores y para fines didácticos llamaremos a estos días de d1 e d2. Los resultados serán validados con el indicador IBOV explicado en la sección de Finanzas.



Figura 4.12: Evolución Ibovespa- Fuente: TradinView

Mostramos en la Figura (4.12) el comportamiento del indicador IBOV durante los últimos años Podemos observar que este índice tuvo una caída después del día inicial y a finales de diciembre aumento. Para comparar si nuestra Inteligencia Artificial recomendó buenas empresas para comprar usaremos el siguiente código.

Listing 4.1: Código para calcular la ganancia obtenida por la IA

```
cartera = []
cartera_inicial = []
d1 = "2023-09-29"
d2 = "2023-12-28"
inversion = 10000
cont=0
for i, empresa in enumerate(lista_empresas):
    if recomendacion_IA[i] == 2:
        cont=cont+1
        nome = empresa+'.SA'
        print("=====>",cont,empresa)
        cartera_inicial.append(inversion)
        precio = precios[empresa]["Adj Close"]
        precio_inicial = precio.loc[d1]
        precio_final = precio.loc[d2]
        porcentaje = precio_final/precio_inicial
        cartera.append(inversion*porcentaje)

saldo_inicial = sum(cartera_inicial)
saldo_final = sum(cartera)
print(saldo_inicial,saldo_final)
print(saldo_final/saldo_inicial)
```

El código mostrado en (4.1) sirve para validar nuestra recomendación. En el dia inicial es realizado la compra de las empresas recomendadas por la IA y en el último día obtenemos de la bolsa de valores el valor actualizado de los activos. Luego calculamos la variación del precio del IBOV en el día inicial y en el día final. Finalmente comparamos nuestra variación con la variación del IBOV. Los resultados son presentados en la siguiente tabla.

Descripcíon	**IBOV**	**IA_Gradient_Boost**	**IA_Red_Neural**	**Ganancia**
Porcentaje	15.116 %	16.495 %	16.203 %	1.379 %

Cuadro 4.2: Tabla comparativa de resultados

La Tabla (4.2) indica el porcentaje de variación en el intervalo de tiempo d1 y d2. La columna IBOV compuesta por 82 empresas tuvo una variación de 15.116 %. La segunda columna IA_Gradient_Boost recomendó 48 empresas para comprar en el día d1. Así, esta recomendación tuvo un crecimiento de 16.495 %. La tercera columna IA_Red_Neural recomendó comprar 40 empresas en el día d1 y tuvo un crecimiento de 16.203 %. Calculando la diferencia entre la mayor recomendación hecha por la IA con la del IBOV mostramos que pudimos ganarle a este índice en 1.379 %.

Capítulo 5

Conclusiones y Trabajos Futuros

5.1. Conclusiones

En este trabajo usamos la Inteligencia Artificial para analizar los Fundamentos de las empresas. Especialmente nos enfocamos en empresas que cotizan en la Bolsa de Valores de Brasil y que podemos extender para cualquier otro país. La recomendación de la Inteligencia Artificial llega a ganar al IBovespa en 1.379 % a más. Creemos que aún podemos mejorar el modelo colectando más informaciones actualizadas, adicionando al modelo las empresas que fueron descartadas por falta de fundamentos y también podemos considerar otros factores como situación económica del país, licitaciones que la empresa está consiguiendo y oportunidades que la empresa tiene para crecer.

5.2. Trabajos Futuros

Como trabajos futuros podemos mejorar los parámetros de los modelos presentados en esta tesis usando técnicas de ensamblaje de modelo como [70, 56], donde el modelo final será resultado de una combinación lineal de los demás modelos. También podemos usar la técnica de combinación de especialistas [32], cuyo objetivo es identificar modelos especializados y elegirlos en función de una distribución de probabilidad. Si tenemos informaciones privadas y sensibles podemos usar técnicas como *Federal Learning* [44] para entrenar modelos y usar las mismas técnicas que mencione. También podemos entrenar modelos de IA usando Aprendizaje por Refuerzo donde nuestro ambiente seria el mercado financiero [45] y una recompensa para nuestra IA sería cuando compra un activo y este se valoriza en un intervalo de tiempo, una recompensa mala seria el caso contrario. Creemos en el potencial de extender este trabajo y analizar una mayor cantidad de empresas combinando Finanzas y *Large Language Models* [81].

Referencias Bibliográficas

[1] I. Almeida. Responsible ai in the age of generative models: Governance, ethics and risk management (byte-sized learning. *Now Next Later*, page 362, 2024.

[2] Valentina Alto. *Modern Generative AI with ChatGPT and OpenAI Models: Leverage the capabilities of OpenAI's LLM for productivity and innovation with GPT3 and GPT4*. Packt Publishing Ltd, 2023.

[3] Saleema Amershi, Andrew Begel, Christian Bird, Robert DeLine, Harald Gall, Ece Kamar, Nachiappan Nagappan, Besmira Nushi, and Thomas Zimmermann. Software engineering for machine learning: A case study. In *2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE-SEIP)*, pages 291–300. IEEE, 2019.

[4] autoTrend. *Gradiente Linear Automatico: Manual de Configuração*. autoTrend, 2023.

[5] Slađana Benković, Aleksandra Labus, and Miloš Milosavljević. *Digital Transformation of the Financial Industry: Approaches and Applications*. Springer Nature, 2023.

[6] Simon Benninga. *Financial modeling*. MIT press, 2014.

[7] Christopher M Bishop. Pattern recognition and machine learning. *Springer google schola*, 2:1122–1128, 2006.

[8] Mary Buffett and David Clark. *Warren Buffett and the interpretation of financial statements: The search for the company with a durable competitive advantage*. Simon and Schuster, 2008.

[9] Mary Buffett and David Clark. *Warren Buffett and the interpretation of financial statements: The search for the company with a durable competitive advantage*. Simon and Schuster, 2008.

[10] Mary Buffett and David Clark. *The Warren Buffett Stock Portfolio: Warren Buffett Stock Picks: why and when He is Investing in Them*. Simon and Schuster, 2011.

[11] Sean Buffett, Mary; Seah. *7 Secrets to Investing Like Warren Buffett*. Simon Schuster UK, 2019, 2019.

[12] Darren Cook. *Practical machine learning with H2O: powerful, scalable techniques for deep learning and AI*. .º'Reilly Media, Inc.", 2016.

[13] Guillaume Coulaud and Régis Duvigneau. *Physics-Informed Neural Networks for Multiphysics Coupling: Application to Conjugate Heat Transfer*. PhD thesis, Université Côte d'Azur, Inria, CNRS, LJAD, 2023.

[14] Kristof De Witte, Oliver Holz, and Kenneth De Beckker. *Financial education: Current practices and future challenges*. Waxmann Verlag, 2020.

[15] Carlos Alberto Debastiani and Felipe Augusto Russo. *Avaliando empresas, investindo em ações: a aplicação prática da análise fundamentalista na avaliação de empresas*. Novatec Editora, 2008.

[16] Carlos Alberto Debastiani and Felipe Augusto Russo. *Avaliando empresas, investindo em ações: a aplicação prática da análise fundamentalista na avaliação de empresas*. Novatec Editora, 2008.

[17] Michael Joseph Dempsey. *Stock Markets and Corporate Finance: A Primer*. World Scientific, 2022.

[18] Dipayan Dev. *Deep learning with hadoop*. Packt Publishing Ltd, 2017.

[19] Mebane Faber and Kindle Edition. Global asset allo-cation: A survey of the world's top asset allocation strategies, 2016.

[20] Frank J Fabozzi and Harry M Markowitz. *The theory and practice of investment management: Asset allocation, valuation, portfolio construction, and strategies*, volume 198. John Wiley & Sons, 2011.

[21] Peter Flach. *Machine learning: the art and science of algorithms that make sense of data*. Cambridge university press, 2012.

[22] Rosario Girasa. *Artificial intelligence as a disruptive technology: Economic transformation and government regulation*. Springer Nature, 2020.

[23] Benjamin Graham, David Le Fevre Dodd, Sidney Cottle, and Charles Tatham. *Security analysis: Principles and technique*. McGraw-Hill New York, 1951.

[24] Benjamin Graham, Charles McGolrick, and Spencer B Meredith. *The interpretation of financial statements*, volume 4. Harper New York, 1937.

[25] Benjamin Graham and Bill McGowan. *The intelligent investor*. HarperBusiness Essentials New York, 2003.

[26] Antonio Gulli and Sujit Pal. *Deep learning with Keras*. Packt Publishing Ltd, 2017.

[27] Peter Harrington. *Machine learning in action*. Simon and Schuster, 2012.

[28] Ali Hasan, João M Pereira, Robert Ravier, Sina Farsiu, and Vahid Tarokh. Learning partial differential equations from data using neural networks. In *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 3962–3966. IEEE, 2020.

[29] Stiw Herrera, Larissa Miguez da Silva, Paulo Ricardo Reis, Anderson Silva, and Fabio Porto. Managing sparse spatio-temporal data in savime: an evaluation of the ph-tree index. In *Anais do XXXVI Simpósio Brasileiro de Bancos de Dados*, pages 337–342. SBC, 2021.

[30] Yves Hilpisch. *Financial theory with Python*. .º'Reilly Media, Inc.", 2021.

[31] Alexey Grigorevich Ivakhnenko, Valentin Grigorevich Lapa, et al. Cybernetics and forecasting techniques. *(No Title)*, 1967.

[32] Albert Q Jiang, Alexandre Sablayrolles, Antoine Roux, Arthur Mensch, Blanche Savary, Chris Bamford, Devendra Singh Chaplot, Diego de las Casas, Emma Bou Hanna, Florian Bressand, et al. Mixtral of experts. *arXiv preprint arXiv:2401.04088*, 2024.

[33] PD Jonathan Berk. Fundamentos de finanzas corporativas. *PD Jonathan Berck, FUNDAMENTOS DE FINANZAS CORPORATIVAS*, 2010.

[34] Marcos Kalinowski, Tatiana Escovedo, Hugo Villamizar, and Hélio Lopes. *Engenharia de Software para Ciência de Dados: Um guia de boas práticas com ênfase na construção de sistemas de Machine Learning em Python*. Casa do Código, 2023.

[35] Marcos Kalinowski, Hélio Lopes, Alex Furtado Teixeira, Gabriel da Silva Cardoso, André Kuramoto, Bruno Itagyba, Solon Tarso Batista, Juliana Alves Pereira, Thuener Silva, Jorge Alam Warrak, et al. Lean r&d: An agile research and development approach for digital transformation. In *Product-Focused Software Process Improvement: 21st International Conference, PROFES 2020, Turin, Italy, November 25–27, 2020, Proceedings 21*, pages 106–124. Springer, 2020.

[36] Chris Kelliher. *Quantitative Finance with Python: A Practical Guide to Investment Management, Trading, and Financial Engineering*. Chapman and Hall/CRC, 2022.

[37] Alex Kim, Maximilian Muhn, and Valeri V Nikolaev. Financial statement analysis with large language models. *Chicago Booth Research Paper Forthcoming, Fama-Miller Working Paper*, 2024.

[38] William Kinlaw, Mark P Kritzman, and David Turkington. *A practitioner's guide to asset allocation*. John Wiley & Sons, 2017.

[39] William Kinlaw, Mark P Kritzman, and David Turkington. *Asset allocation: from theory to practice and beyond*. John Wiley & Sons, 2021.

[40] A Harry Klopf. *Brain function and adaptive systems: a heterostatic theory*. Air Force Cambridge Research Laboratories, Air Force Systems Command, United . . . , 1972.

[41] Akshay Kulkarni, Adarsha Shivananda, Anoosh Kulkarni, and Dilip Gudivada. Applied generative ai for beginners. *Apress, Berkeley, CA*, 2023.

[42] FLAVIO ALEXANDRE CALDAS DE ALMEIDA LEMOS. *Análise técnica dos mercados financeiros*. Saraiva Educação SA, 2017.

[43] Jay Liebowitz. *Financial literacy education: Addressing student, business, and government needs*. CRC Press, 2018.

[44] Ji Liu, Tianshi Che, Yang Zhou, Ruoming Jin, Huaiyu Dai, Dejing Dou, and Patrick Valduriez. Aedfl: efficient asynchronous decentralized federated learning with heterogeneous devices. In *Proceedings of the 2024 SIAM International Conference on Data Mining (SDM)*, pages 833–841. SIAM, 2024.

[45] Xiao-Yang Liu, Hongyang Yang, Qian Chen, Runjia Zhang, Liuqing Yang, Bowen Xiao, and Christina Dan Wang. Finrl: A deep reinforcement learning library for automated stock trading in quantitative finance. *arXiv preprint arXiv:2011.09607*, 2020.

[46] Peter Lynch and John Rothchild. *Beating the street*. Simon and Schuster, 1994.

[47] Xiaodong Ma. *Methodology for Digital Transformation: Implementation Path and Data Platform*. Springer Nature, 2023.

[48] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5:115–133, 1943.

[49] Robert T McGee. *Applied financial macroeconomics and investment strategy: a practitioner's guide to tactical asset allocation*. Springer, 2016.

[50] Len Mei. *Fintech Fundamentals: Big Data/Cloud Computing/Digital Economy*. Mercury Learning and Information, 2022.

[51] John Moschella. *Financial Modeling For Equity Research: A Step-by-Step Guide to Earnings Modeling*. Gutenberg Research Publishing Company, 2017.

[52] Andreas C Müller and Sarah Guido. *Introduction to machine learning with Python: a guide for data scientists*. .ºReilly Media, Inc.", 2016.

[53] Bostrom Nick. *Superintelligence: Paths, dangers, strategies*. Oxford University Press, Oxford, 2014.

[54] Theobald Oliver. Machine learning for absolute beginners. *A Plain English Introduction*, 2017.

[55] Carla Osthoff, Stiw Herrera, Thiago Teixeira, Micaella Coelho, Mateus Melo, Gabriel Costa, Frederico Cabral, Maria E Welter, Bruno Fagundes, André Carneiro, et al. A arquitetura do supercomputador sdumont e os desafios da pesquisa brasileira na área de computação de alto desempenho. In *Anais da XI Escola Regional de Alto Desempenho de São Paulo*, pages 1–5. SBC, 2020.

[56] Rafael Pereira, Yania Souto, Anderson Chaves, Rocio Zorilla, Brian Tsan, Florin Rusu, Eduardo Ogasawara, Artur Ziviani, and Fabio Porto. Djensemble: A cost-based selection and allocation of a disjoint ensemble of spatio-temporal models. In *Proceedings of the 33rd International Conference on Scientific and Statistical Database Management*, pages 226–231, 2021.

[57] I Pérez Borrero and ME Gegúndez Arias. Deep learning. fundamentos, teoría y aplicación, 2021.

[58] Paul Pignataro. *Financial modeling and valuation: a practical guide to investment banking and private equity*, volume 876. John Wiley & Sons, 2013.

[59] Hayden Van Der Post. *Financial Analyst: A Comprehensive Applied Guide to Quantitative Finance in 2024: A Holistic Guide to: Python for Finance, Algorithmic Options Trading*. Reactive Publishing; 4th edition, 2024.

[60] Alexandre Povoa. *Valuation*. Elsevier Brasil, 2012.

[61] OECD. Publishing, Organisation for Economic Co-operation, and Development. *Financial education for youth: The role of schools*. OECD Publishing, 2014.

[62] Brandon Reagen, Robert Adolf, Paul Whatmough, Gu-Yeon Wei, David Brooks, and Margaret Martonosi. *Deep learning for computer architects*. Springer, 2017.

[63] Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, 1958.

[64] Manuel Chu Rubio. *El ROI de las decisiones del marketing: un enfoque de rentabilidad*. Ediciones de la U, 2021.

[65] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *nature*, 323(6088):533–536, 1986.

[66] Stuart J Russell and Peter Norvig. *Artificial intelligence: a modern approach*. Pearson, 2016.

[67] Arthur L Samuel. Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3):210–229, 1959.

[68] David L Shrier and Alex Pentland. *Global Fintech: Financial Innovation in the Connected World*. MIT Press, 2022.

[69] Adam Smith. Riqueza de las naciones (1776). *Madrid: Alianza*, 37:67–72, 1994.

[70] Yania Molina Souto, Rafael Pereira, Rocío Zorrilla, Anderson Chaves, Brian Tsan, Florin Rusu, Eduardo Ogasawara, Artur Ziviani, and Fabio Porto. Djensemble: On the selection of a disjoint ensemble of deep learning black-box spatiotemporal models. *arXiv preprint arXiv:2005.11093*, 2020.

[71] Richard S Sutton and Andrew G Barto. *Reinforcement learning: An introduction*. MIT press, 2018.

[72] Nico Van Der Wijst. *Finance: a quantitative introduction*. Cambridge University Press, 2013.

[73] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.

[74] Raja Velu. *Algorithmic trading and quantitative strategies*. Chapman and Hall/CRC, 2020.

[75] Riccardo Viale, Shabnam Mousavi, Barbara Alemanni, and Umberto Filotto. *The behavioural finance revolution: A new approach to financial policies and regulations*. Edward Elgar Publishing, 2018.

[76] Hugo Villamizar, Marcos Kalinowski, and Hélio Lopes. Towards perspective-based specification of machine learning-enabled systems. In *2022 48th Euromicro Conference on Software Engineering and Advanced Applications (SEAA)*, pages 112–115. IEEE, 2022.

[77] Hugo Villamizar, Marcos Kalinowski, Hélio Lopes, and Daniel Mendez. Identifying concerns when specifying machine learning-enabled systems: a perspective-based approach. *Journal of Systems and Software*, 213:112053, 2024.

[78] Paul J Werbos. Backpropagation through time: what it does and how to do it. *Proceedings of the IEEE*, 78(10):1550–1560, 1990.

[79] Paul John Werbos. *The roots of backpropagation: from ordered derivatives to neural networks and political forecasting*, volume 1. John Wiley & Sons, 1994.

[80] Gio Wiederhold and John McCarthy. Arthur samuel: Pioneer in machine learning. *IBM Journal of Research and Development*, 36(3):329–331, 1992.

[81] Hongyang Yang, Xiao-Yang Liu, and Christina Dan Wang. Fingpt: Open-source financial large language models. *arXiv preprint arXiv:2306.06031*, 2023.