

Universidad Nacional de Córdoba

Facultad de Ciencias Económicas

Licenciatura en Administración

Orientación en Finanzas

Seminario de Aplicación

Trabajo Final de Licenciatura

Funcionamiento del *trading* algorítmico en los mercados de capitales

Coordinador de cátedra

Dr. Juan Manuel Bruno

Director

Mgter. Argos Rodríguez Machado

Tutor

Dr. Diego Carlos Rezzónico

Autores

Castro, Francisco Javier

Gervasoni, Lucía Florencia

Giannelli, Agostina Belén

Vogel Dotta, Maria Sol

Córdoba, Marzo del 2022



Funcionamiento del trading algorítmico en los mercados de capitales por Castro, Francisco Javier; Gervasoni, Lucía Florencia; Giannelli, Agustina Belén; Vogel Dotta, Maria Sol se distribuye bajo una [Licencia Creative Commons Atribución-NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/).

Agradecimientos

En primer lugar, queremos agradecer a nuestras familias y amigos, por ser un pilar fundamental durante el transcurso de esta etapa de nuestras vidas. Gracias por confiar en nosotros y brindarnos su apoyo en todo momento. Damos gracias también a los docentes que nos compartieron sus conocimientos, experiencias, valores y por sobre todo por formarnos como personas y profesionales brindándonos la posibilidad de un futuro mejor.

A nuestro director, el Mgter. Argos Rodriguez Machado, por su predisposición desde el primer día, brindándonos su apoyo; a nuestro tutor, el Mgter. Diego Rezzonico por su completa dedicación para ayudarnos con la realización del trabajo y por todos sus comentarios y sugerencias que nos permitieron un mejor aprendizaje; y al Dr. Juan Manuel Bruno, por su compromiso, su entusiasmo para enseñar y transmitir sus conocimientos.

Agradecemos también a la Facultad de Ciencias Económicas y a la Universidad Nacional de Córdoba, por darnos la oportunidad de estudiar una carrera de grado con enseñanza de calidad y permitir nuestro desarrollo integral.

Por último, queremos hacer una mención especial a los siguientes profesionales que nos transmitieron su pasión por lo que hacen y su compromiso como profesionales y personas colaborando en la inclusión y educación financiera. Por el tiempo dedicado a las entrevistas que ayudaron a la realización de este trabajo. Estos profesionales son: Lic. Nicolás Lino, Cr. Es. Diego Collivadino, Nicolás Emiliano Alcaraz, Ing. Juan Pablo Pisano, Lic. Hernan Lauro y Lic. Agustin Arreguy.

Resumen estructurado

Propósito: este trabajo tiene como finalidad exponer información acerca del *trading* algorítmico y su relación con el mercado de capitales, el análisis técnico y fundamental, los activos financieros y sus derivados para todo aquel interesado en interiorizarse en el mundo de las finanzas.

Metodología: se realizó una revisión sistemática de literatura, relevando 572 artículos acerca del *trading* algorítmico, publicados en el periodo 2015-2022. En la búsqueda se aplicaron criterios de exclusión, quedando un total de 29 artículos. Su análisis pertinente permitió contestar las preguntas de investigación y desarrollar la temática elegida. Además, se efectuaron entrevistas semi-estructuradas a personas trabajando en la operatoria de *trading*.

Conclusiones: El *trading* algorítmico posee ventajas excepcionales sobre el *trading* discrecional. Entre ellas se destaca la capacidad de procesamiento superior que tiene una computadora que simplifica toda operación y reduce los tiempos empleados y por otro lado, elimina el lado emocional de la toma de decisiones del proceso de inversión.

Limitaciones: En el protocolo de investigación se estableció la condición de seleccionar solo artículos de libre acceso y aceptar únicamente los artículos que hayan sido redactados en inglés o el español. Los idiomas de los textos que fueron dejados de lado son francés, alemán, portugués y ucraniano.

Originalidad-Valor: El valor del trabajo radica en que se aborda una temática novedosa en el campo de las finanzas por medio de dos metodologías que aportan por un lado información de calidad y con respaldo científico y por otro lado la experiencia y conocimientos de los profesionales entrevistados que actualmente trabajan con esta herramienta.

Palabras Clave: *trading* algorítmico, activos financieros, análisis técnico, mercados, estrategias, inteligencia artificial.

Índice

Introducción	1
Objetivos	2
Marco Conceptual	3
<i>Activos financieros</i>	3
<i>Análisis técnico y fundamental</i>	3
<i>Mercados bursátiles</i>	3
<i>Trading algorítmico y high frequency trading</i>	4
<i>Inteligencia Artificial y Machine Learning</i>	4
Metodología	5
Modalidad	5
Metodología	5
Revisión Bibliográfica	5
Preguntas de investigación	5
Protocolo de investigación	6
Palabras Clave	6
Búsqueda de Palabras Clave	6
Periodo de búsqueda de la bibliografía	7
Base de Datos	7
Búsqueda de literatura	7
Búsqueda Preliminar	7
Evaluación de los documentos obtenidos	7
Selección final de documentos	11
Entrevistas	12
Resultados y Aplicaciones	12
Funcionamiento del Trading Algorítmico dentro del mercado de capitales	12
Señales e indicadores del análisis técnico más utilizados con esta herramienta	14
Activos financieros más adecuados para operar con trading algorítmico	16
Estrategias más utilizadas en el trading algorítmico	17
Ventajas del trading algorítmico sobre el trading discrecional	21
Desventajas del trading algorítmico sobre el trading discrecional	21
El trading algorítmico en Argentina	22
Conclusiones/Implicaciones/Limitaciones	23
Conclusiones	23
Implicaciones	25
Limitaciones	26

Referencias bibliográficas	27
Anexos	32
Anexo 1	32

Índice de tablas

Tabla 1. Resultados generales de Búsqueda Preliminar	7
Tabla 2. Resultados generales luego de exclusiones	9
Tabla 3. Resultados de SJR	10
Tabla 4. Resultados de CIRC	11
Tabla 5. Selección de final de artículos por pregunta	11

Índice de figuras

Figura 1. Funcionamiento del <i>trading</i> algorítmico	13
Figura 2. Principales hallazgos	23

I. Introducción

Hoy en día lo único constante es el cambio, y todo aquel que no se adapta queda fuera del juego. En la actualidad, los inversores o instituciones de inversión cuentan con una herramienta de financiación por múltiples canales, es decir, acciones, bonos, materias primas, divisas, opciones y futuros, etc. Sin embargo, la alta no linealidad¹ propia de los mercados financieros y el conocimiento profesional necesario, dificultan la toma de decisiones de inversión correctas con prontitud (Li et al., 2009).

A su vez, las grandes cantidades de datos e información hace a las personas incapaces de hacer los complejos cálculos de optimización que se espera de ellas bajo la teoría financiera estándar (Useche Arévalo, 2014). Debido a esto, muchos investigadores han desarrollado métodos y algoritmos computacionales para dar soporte a la toma de decisiones. Estos no solo permiten tener un análisis más exhaustivo de los activos financieros, sino también acelerar los procesos de compra y venta de los mismos. Además, marcan un ritmo y velocidad en las operaciones en los mercados de capitales que es superior a lo que un humano puede llegar a lograr (Cavalcante et al., 2016).

Esto último se explica a partir de un fenómeno tecnológico surgido en los últimos años que es la *Inteligencia Artificial (IA)*. La *IA* es la habilidad de las máquinas para utilizar algoritmos, analizando los datos y tomando decisiones, aplicando lo aprendido de la misma manera que lo haría el ser humano. Sin embargo, a diferencia de este, los dispositivos basados en *IA* pueden analizar una gran cantidad de información de manera continua sin necesidad de descansar. Cabe destacar que la proporción de errores es menor en las máquinas que en los humanos al realizar las mismas tareas (Rouhiainen, 2018).

A su vez, a partir de la *IA*, surge una disciplina conocida como *Machine Learning (ML)*. El *ML* es “un conjunto de métodos que utilizan las computadoras para realizar y mejorar predicciones o comportamientos basados en datos” (Molnar, 2020, p. 13). Las técnicas de *ML* se han aplicado con éxito en el modelado y la predicción de series de tiempo financieras ayudando a determinar el comportamiento del mercado.

La aplicación de estas herramientas en el mercado de capitales, tanto de valores negociables como de divisas, permite adoptar estrategias de negociación de diferente naturaleza, a través del *Trading Algorítmico (TA)*. El mismo consiste en “el uso de algoritmos computacionales para tomar

¹ Un cambio no lineal es aquel que no se basa en una simple relación proporcional entre causa y efecto, sino que refiere a cambios bruscos, inesperados y difíciles de prever.

decisiones de compraventa, emitir órdenes al mercado y gestionarlas después de su emisión, de forma totalmente automatizada” (Hendershott y Riordan, 2009, p. 2).

Es necesario destacar que el TA solo puede ser utilizado en ciertos tipos de operaciones, y “tiene ventajas respecto al *trading* manual realizado por las personas, ya que no se afecta por las emociones al momento de tomar las decisiones” (Navia-Rodríguez et al., 2020, p. 338). Además, se quita la responsabilidad del *trader* de vigilar los cambios en los precios y los gráficos en tiempo real, o de realizar los pedidos manualmente. El algoritmo de *trading* realiza estas tareas de forma constante, identificando correctamente la oportunidad, según las reglas previamente establecidas en su programación.

Según Pádraig Belton, reportero especializado en tecnología para asuntos económicos de *British Broadcasting Corporation* (BBC), cerca de tres cuartas partes de los intercambios en la Bolsa de Valores de Nueva York y Nasdaq son llevados a cabo por algoritmos. Ese *trading* realizado por robots está afectando profundamente al mundo de las inversiones, desde fondos de cobertura internacionales hasta inversiones de individuos (BBC, 2018). Esto es una demostración de la evolución en las formas de operar en los mercados y a partir de ello, se propone analizar en profundidad *¿Cómo funciona el Trading Algorítmico en los mercados de capitales?*

II. Objetivos

El Objetivo General del Trabajo Final de Licenciatura (TFL) consiste en determinar cómo es el funcionamiento del *trading* algorítmico en el Mercado de Capitales.

Los Objetivos Específicos planteados para el TFL serán:

- ❖ Identificar las señales e indicadores más frecuentes del análisis técnico y su utilidad.
- ❖ Relevar qué tipo de activos financieros son los más adecuados para este tipo de modalidad.
- ❖ Definir las estrategias más eficientes de *trading* algorítmico.

III. Marco Conceptual

Activos financieros

Para comenzar, es importante definir a los activos financieros, los cuales son: “títulos, valores o documentos que otorgan al inversor una serie de derechos económicos. Constituyen los instrumentos financieros que utiliza el sistema financiero para canalizar el ahorro hacia la inversión, y son negociables en los mercados monetarios y de capitales” (García Campo, 2015, p. 17). En cuanto a estos últimos, se puede decir que, comprenden todas las operaciones de colocación y financiación a largo plazo y a las instituciones que efectúan principalmente estas operaciones (Calvo et al., 2018).

Análisis técnico y fundamental

Numerosas herramientas se han desarrollado para intentar predecir los movimientos de las acciones, pero hay dos muy tradicionales: el análisis técnico y el fundamental.

El análisis técnico consiste en registrar, generalmente de forma gráfica, el historial real de negociación (cambios de precio, volumen de transacciones, etc.) de un valor determinado o en los promedios, y luego deducir de ese historial ilustrado la tendencia futura probable (Edwards et al., 2021).

Por otro lado, el análisis fundamental permite mediante la utilización de diferentes herramientas aproximarse mejor a la valoración de acciones, determinando si están infravaloradas o sobrevaloradas. Este análisis no tiene en cuenta comportamientos pasados en el precio de las acciones, sino que intenta predecir cómo van a evolucionar los beneficios de la compañía, los mercados, los tipos de interés o la economía (Scherk, 2011).

Mercados bursátiles

Un mercado bursátil resulta de los elementos económicos, jurídicos y técnicos desarrollados a partir de la segunda mitad del siglo XX. La bolsa es un mercado que, como tal, funciona como un procedimiento para concertar ofertas y demandas sobre los activos e instrumentos financieros. En el mercado bursátil importa definitivamente la simetría de la información, que produce eficiencia en la formación de los precios y satisface el interés general detrás del funcionamiento correcto del mercado (Gabaldon Codesido, 2016).

Los mercados bursátiles han avanzado tecnológicamente a tal punto, que han logrado automatizar la toma de decisiones para la compra o venta de estos activos financieros, mediante el *trading* automático o también llamado *trading* algorítmico (Rodríguez et al., 2020).

El mercado se segmenta según los diferentes tipos de productos subyacentes que pueden negociarse. Los segmentos más populares son: los productos básicos (metales, productos agrícolas), la energía (petróleo, gas), acciones (acciones de diferentes empresas), bonos de tasa de interés (cupones que obtiene a cambio por la deuda, que devenga intereses, de ahí el nombre) y divisas (tipos de cambio en efectivo entre monedas de diferentes países) (Donadio y Ghosh, 2019).

Trading algorítmico y high frequency trading

Trading es la palabra en inglés usada como la acción de comprar y vender activos financieros (como divisas, índices, acciones, bonos, entre otros) en un mercado bursátil. Esta acción es realizada por *traders*, que son las personas que participan en estos mercados comprando y vendiendo dichos activos financieros (Navia-Rodríguez et al., 2020).

El *trading* algorítmico (TA), *trading* automático o *black-box trading*, consiste una modalidad de *trading* que opera mediante plataformas virtuales vinculadas a los mercados financieros con estrategias automáticas que se programan con anterioridad y que se activarán atendiendo a la variables tiempo, precio y/o cantidad (Pérez Santos, 2014).

El *high frequency trading* o *trading* de alta velocidad (HFT) es considerado como una subcategoría más específica del TA. A pesar de todas las distintas variantes que este sistema tiene, se lo puede definir como una estrategia de inversión donde instrumentos financieros son comprados, mantenidos durante segundos o incluso milisegundos, y vendidos inmediatamente después, normalmente con el fin de obtener un beneficio (Riordan et al., 2014).

Inteligencia Artificial y Machine Learning

Esto puede perfeccionarse con el uso de la Inteligencia Artificial (IA) y el *Machine Learning* (ML). La IA es el conjunto de teorías y de algoritmos que permiten que las computadoras lleven a cabo tareas que, típicamente, requieren capacidades propias de la inteligencia humana (*Financial Stability Board [FSB]*, 2017). Un algoritmo es una lista completa de pasos secuenciales y una descripción de datos necesarios para resolver un problema. El mismo debe ser: realizable, es decir que el número de pasos sea finito, comprensible y preciso (Barrera González, 2013).

Por último, se encuentra el ML, el cual es una subárea de la IA que construye un modelo matemático basado en datos de muestra para hacer predicciones o decisiones sin estar programado explícitamente para realizar la tarea (Zhang, 2020).

IV. Metodología

Modalidad

La modalidad asumida para alcanzar los objetivos del Trabajo Final de Licenciatura es la investigación cualitativa, cuyo fin es lograr descripciones detalladas de los fenómenos estudiados, particularmente en este caso sobre el *trading* algorítmico.

Metodología

En un principio, se efectuó una revisión y un análisis de la literatura existente, al ser una parte crucial de toda investigación. El objetivo de esto es ir depurando conceptualmente las categorías que se van encontrando al realizar el análisis de la información generada y recogida en el transcurso del proceso de investigación (Quintana y Montgomery, 2006).

Para llevar a cabo el proceso de revisión, se siguieron los lineamientos propuestos por el equipo docente de la cátedra, sumado al apoyo conceptual de profesores de la Facultad de Ciencias Económicas de la Universidad Nacional de Córdoba, complementándose con los artículos: “Revisiones bibliográficas sistematizadas: Procedimientos generales y *Framework* para Ciencias Humanas y Sociales” (Codina, 2018) y “*Trading* Algorítmico para la Predicción de Series de Tiempo Financieras: Una Revisión Sistemática” (Navia-Rodríguez et al., 2020).

El siguiente paso consistió en recabar datos primarios mediante la realización de 4 entrevistas. La selección de los entrevistados se realizó mediante un muestreo teórico por perfiles a personas que se encuentran trabajando con la operatoria del *trading* algorítmico.

Las entrevistas fueron individuales, semiestructuradas y se utilizó un cuestionario guía, el cual cumplió la función de asegurar que el investigador abarque correctamente la temática abordada y de direccionar y delimitar el discurso, haciéndolo de igual manera con cada entrevistado (Quintana y Montgomery, 2006).

A. Revisión Bibliográfica

1. Preguntas de investigación

Se efectuaron una serie de preguntas con el fin de obtener respuestas que permitan definir una guía para la investigación, las cuales tienen una estrecha relación con el objetivo general y específicos presentados en los incisos anteriores. Las preguntas planteadas son:

P1: ¿Cómo es el funcionamiento del *trading* algorítmico?

Esta pregunta permitirá conocer la operatoria del *trading* algorítmico, identificando la manera en que se producen las principales operaciones a través del mismo, las cuales deben ser tenidas en cuenta por toda persona que utilice esta herramienta para realizar operaciones en los mercados.

P2: ¿Qué señales e indicadores del análisis técnico son los más utilizados con esta herramienta?

Esta pregunta permitirá conocer los principales indicadores que se formulan para analizar las señales que brinda el mercado, para poner en práctica las estrategias más adecuadas según las situaciones que se presenten.

P3: ¿Qué tipos de activos financieros son más adecuados para operar con *trading* algorítmico?

Esta pregunta permitirá definir los activos financieros con los que comúnmente se trabaja en esta operatoria y la razón por la cual los usuarios adquieren o deciden operar con esta clase de activos.

P4: ¿Cuáles son las estrategias más utilizadas en el *trading* algorítmico?

La respuesta a esta pregunta nos brindará información acerca de las estrategias que se utilizan para operar en esta modalidad, dónde se originan y qué las sustenta. Adicionalmente, nos dará información acerca de otros beneficios del uso del *trading* algorítmico.

2. Protocolo de investigación

a. Palabras Clave

Se definieron palabras claves para poder realizar la búsqueda de bibliografía pertinente al tema abordado en la investigación, entre ellas “*financiamiento*”, “*market*”, “*trading*”, “*algorithmic*”. En su forma singular y plural y en idioma castellano e inglés. A su vez, se definieron palabras claves para cada pregunta de investigación en particular, las cuales son:

- P2: “*Technical*”; “*analysis*”
- P3: “*Assets*”
- P4: “*Strategies*”

b. Búsqueda de Palabras Clave

La búsqueda de palabras claves se centró en el título y *abstract* de los artículos para facilitar su procesamiento e identificación. En etapas posteriores, se aplicaron distintas condiciones que permitieron depurar y seleccionar aquellos artículos que ayudan a comprender mejor y a responder las preguntas de investigación, las cuales se detallarán en la etapa de búsqueda de literatura.

c. Periodo de búsqueda de la bibliografía

De la bibliografía disponible, se ha elegido aquella publicada en los últimos años (2015-2022), aunque en ciertas ocasiones se recurrió a información más antigua pero necesaria para el desarrollo del tema, en cuya situación se aclaró la utilización de la misma.

d. Base de Datos

Las bases de datos utilizadas para recabar la bibliografía pertinente fue *Scopus*. Adicionalmente, se complementó con la herramienta de *Google Scholar* a modo de obtener la mayor cantidad de artículos que cumplan con la calidad y los requisitos definidos para la búsqueda.

3. Búsqueda de literatura

a. Búsqueda Preliminar

De acuerdo al protocolo de investigación y la metodología planteada, se llevó a cabo la primera búsqueda. En base a esta, se enlistó una serie de artículos potenciales para ser utilizados en la investigación, categorizados por pregunta de investigación. Los resultados obtenidos se exponen en la tabla 1 a continuación:

Tabla 1. Resultados generales de Búsqueda Preliminar

Preguntas	P1	P2	P3	P4	Total
Resultados	339	28	48	157	572

Fuente: Elaboración propia.

Ésta búsqueda, arrojó un total de 572 resultados. Como se puede observar, la pregunta 1 (P1) concentró el 59,27% de los resultados, seguido por la pregunta 4 (P4), con el 27,45%; lo que nos da una pauta de la cantidad de artículos e información que hay respecto a los temas de la investigación como así también el interés en los mismos. Las preguntas 2 y 3 (P2 y P3) devolvieron la menor cantidad de resultados, por lo que se puede suponer que son temáticas de menor interés y desarrollo.

Respecto a las palabras clave por búsqueda, se identificaron los conceptos más relevantes de cada una de las preguntas formuladas. En el caso de la P1, las palabras clave utilizadas fueron: “*financial*”, “*market*”, “*trading*”, “*algorithmic*”, con 339 resultados. Para la P2, se añadieron las palabras claves “*technical*” y “*analysis*” a las anteriores, arrojando 28 resultados. Respecto a P3, se utilizaron las palabras clave de la P1 junto con “*assets*”, obteniendo 48 resultados. En el caso de P4, se agregó la palabra clave “*strategies*” arrojando 157 resultados.

b. Evaluación de los documentos obtenidos

En la fase de evaluación se busca asegurar que los documentos recuperados

cumplan con los criterios de inclusión/exclusión y que merecen formar parte del banco de documentos, sobre el cual se procederá al análisis. Este merecimiento está basado en dos aspectos:

- Criterios pragmáticos, es decir, evalúa la adecuación de los documentos encontrados a los temas y objetivos de la investigación (Codina, 2018).

- Criterios de calidad de la investigación, se utilizan para que los documentos finalmente seleccionados correspondan a trabajos que han sido llevados a cabo siguiendo procedimientos generalmente admitidos de calidad. El hecho de utilizar como núcleo principal artículos de revistas evaluadas, y bases de datos como Scopus implica un primer filtro de calidad muy importante (Codina, 2018).

Criterios pragmáticos de exclusión:

Primero, se analizaron los artículos según su disponibilidad de texto completo. Se excluyeron todos aquellos que no brindaban libre acceso o que el texto completo no estaba disponible. Esta exclusión, se la denominó “**1° Exclusión**” en la tabla 2.

En segunda instancia, se decidió seleccionar aquellos artículos más recientes a modo de poder trabajar con artículos actualizados que hayan sido publicados entre el año 2015 hasta 2022. Se excluyó entonces según fecha de publicación, y en este caso se la señaló como “**2° Exclusión**” en la tabla 2.

Luego se excluyó artículos que no se relacionaban al área de investigación, seleccionando los artículos relacionados de las siguientes áreas: “*Computer Science*”; “*Business, Management and Accounting*”; “*Decision Sciences*”; “*Economics, Econometrics and Finance*”. Este motivo se lo visualiza como “**3° Exclusión**” en la tabla 2.

En cuarto lugar, se excluye todo artículo cuyo idioma principal no haya sido el inglés o el español. Esta es la “**4° Exclusión**” de la tabla 2.

Por último, se volvió a seleccionar palabras claves más específicas para obtener resultados más precisos en relación al tema de investigación para descartar aquellos documentos recuperados no relevantes. Estas palabras claves se distinguieron para cada pregunta y fueron las siguientes:

P1: *Algorithmic Trading*.

P2: *Algorithmic Trading and Technical Analysis*.

P3: *Algorithmic Trading and Financial Market*.

P4: *Algorithmic Trading and Trading Strategies*.

Esta última exclusión denominada se visualiza como “5° exclusión” en la tabla 2.

Tabla 2. Resultados generales luego de exclusiones

Preguntas	P1	P2	P3	P4
Resultados	339	28	48	157
1° Exclusión	101	7	13	48
2° Exclusión	78	7	8	39
3° Exclusión	63	6	7	37
4° Exclusión	63	6	7	37
5° Exclusión	33	5	6	24

Fuente: Elaboración propia.

Luego de aplicar las 5 exclusiones explicadas anteriormente, el resultado de artículos a analizar por pregunta son: 33 para la primera, 5 para la segunda, 6 para la tercera y 24 para la cuarta. El resultado obtenido es parcial dado que para lograr la selección definitiva de artículos se establecieron criterios de calidad.

Sin embargo, cabe destacar que el total de artículos son 36 pero algunos de ellos se usaron para diferentes preguntas y otros solo para una en particular.

Criterios de calidad de la investigación:

Con el objetivo de utilizar artículos que correspondan a trabajos que han sido realizados siguiendo procedimientos admitidos de calidad, se llevaron a cabo dos evaluaciones:

En primer lugar, se utilizaron 5 preguntas generales propuestas por Dixon-Woods (2006):

1. ¿Los propósitos y objetivos de la investigación están claramente establecidos?
2. ¿El diseño de la investigación está claramente especificado y es apropiado para los fines y objetivos de la investigación?
3. ¿Los investigadores proporcionan una explicación clara del proceso por el cual obtuvieron los hallazgos que vamos a reproducir?
4. ¿Los investigadores muestran suficientes datos para respaldar sus

interpretaciones y conclusiones?

5. ¿El método de análisis es apropiado y está adecuadamente explicado?

Fuente: Dixon-Woods et al., 2006

En segundo lugar, se evaluaron las revistas que publicaron los artículos haciendo uso de las calificadoras CIRC (Clasificación Integrada de Revistas Científicas) y SJR (Scimago Journal & Country Rank).

La selección parcial de artículos consta de 36 trabajos publicados en 28 revistas distintas, lo que brindó un mayor abanico de perspectivas y fuentes de información a la investigación. Se analizó la calificación de las revistas donde fueron publicados y se ordenaron los resultados obtenidos en orden descendente respecto a la escala propuesta por la evaluadora.

Como resultado de la búsqueda se encontró que un 32% de los artículos seleccionados pertenecen a revistas que poseen calificación (Q1 de SJR), es decir, el valor máximo de esta clasificadora. A priori es una buena señal acerca del nivel y calidad de la información a utilizar para responder las preguntas de investigación.

Tabla 3. Resultados de SJR

SJR		
Calificación	Cantidad	Porcentaje sobre total
Q1	9	32,14%
Q2	7	25,00%
Q3	4	14,29%
Q4	3	10,71%
No indexado	5	17,86%
Total	28	100%

Fuente: Elaboración propia.

Por otro lado la calificadora CIRC utiliza (A+), por lo que es interesante ver como los resultados en base a esta calificadora se concentran entre la segunda categoría (A) y lo no indexado, en un 71%. Cabe aclarar que los resultados de la fila “No Indexado” corresponden a aquellos artículos cuyas revistas no están indexadas dentro de la

calificadora.

Tabla 4. Resultados de CIRC

CIRC		
Calificación	Cantidad	Porcentaje sobre total
A +	1	3,57%
A	7	25,00%
B	3	10,71%
C	3	10,71%
D	1	3,57%
No indexado	13	46,43%
Total	28	100%

Fuente: Elaboración propia.

Por último, es importante destacar que la calidad general de los artículos seleccionados es muy buena. Sin embargo, para que la investigación alcance los niveles de calidad requeridos para una investigación, se decidieron excluir aquellas revistas que no se encuentren indexadas simultáneamente en ambas calificadoras.

c. Selección final de documentos

Luego de filtrar los artículos seleccionados en base a los criterios pragmáticos y calidad, quedaron seleccionados finalmente un total de 29, algunos de ellos se utilizarán para una pregunta y otros para más de una, el detalle de títulos y autores pueden verse en el “Anexo 1”. Los artículos que se utilizaron son: 27 para la pregunta 1, 3 para la pregunta 2, 4 para la pregunta 3 y 21 para la pregunta 4.

Tabla 5. Selección de final de artículos por pregunta

Preguntas	P1	P2	P3	P4
Resultados	27	3	4	21

Fuente: Elaboración propia.

B. Entrevistas

En esta etapa se procedió a entrevistar a cuatro personas cuyos conocimientos acerca del Mercado de Capitales, los activos financieros, y más específicamente del *trading* algorítmico contribuyeron a la realización de este TFL. Los entrevistados fueron:

- Nicolás Lino, licenciado en ciencias de la computación, *CEO & Founder* de TradeSpark, fintech desarrolladora de ArQuants, la primera plataforma de *trading* algorítmico SaaS de Argentina y Latinoamérica.
- Diego Collivadino, contador público, especialista en administración financiera gubernamental y *trader* de futuros, bonos, acciones y criptomonedas.
- Juan Pablo Pisano, ingeniero industrial, escritor y autor del Libros Python para finanzas y matemáticas, y desarrollador *full stack*.
- Emiliano Alcaraz, ingeniero desarrollador *full stack* y estudiante de la tecnicatura en ciencia de datos en inteligencia artificial.

Las entrevistas tuvieron una duración aproximada de una hora, y las preguntas fueron las siguientes:

- ❖ ¿Cómo es el funcionamiento del *trading* algorítmico en el Mercado de Capitales?
- ❖ ¿Cuáles son los principales activos financieros que operan a través del *trading* algorítmico?
- ❖ ¿Qué estrategias de *trading* son más utilizadas en el *trading* algorítmico?
- ❖ ¿Qué indicadores son más utilizados a la hora de programar un bot?
- ❖ ¿Qué ventajas y desventajas tiene el *trading* algorítmico sobre el *trading* discrecional?

V. Resultados y Aplicaciones

En esta sección se expondrán los resultados de ambas metodologías utilizadas para esta investigación. Para ello, se resumieron los principales hallazgos para cada una en los siguientes apartados:


- Funcionamiento del *Trading* Algorítmico dentro del mercado de capitales

Para comprender el funcionamiento del *trading* algorítmico (TA), es necesario entender que la actividad de *trading* puede verse como la gestión de una cartera, que es un conjunto de activos que incluye diversas acciones, bonos, materias primas, divisas, entre otros. Dentro de esta gestión se

realizan operaciones de compra y venta que son simplemente intercambios de efectivo y acciones (Théate y Ernst, 2021).

A su vez, el *trader* interactúa con el mercado de valores a través de un libro de órdenes, que contiene todo el conjunto de órdenes de compra (ofertas) y órdenes de venta (demandas). Una orden representa la disposición de un participante del mercado a negociar y se compone del precio, cantidad y el lado, que puede ser oferta o demanda. Para que ocurra una operación, se requiere una coincidencia entre las órdenes de oferta y demanda. Entonces, un *trader* se enfrenta a una tarea muy difícil para generar ganancias: qué, cuándo, cómo, a qué precio y en qué cantidad negociar (Théate y Ernst, 2021). En este punto toma relevancia la herramienta del TA para determinar automáticamente los parámetros de las órdenes, incluidos: inicio de la negociación, tiempo, precio y modificación/cancelación de órdenes, sin intervención humana (McGroarty et al., 2018).

Figura 1. Funcionamiento del *trading* algorítmico



Fuente: Elaboración propia.

Los sistemas de TA, a menudo denominados "*bots de trading*" o simplemente "algoritmos" desempeñan las funciones que tradicionalmente realizaban los *traders* humanos con la diferencia de que son capaces de analizar grandes cantidades de datos y reaccionar en pequeñas fracciones de tiempo (Cliff, 2018). Por ejemplo, una persona puede analizar tres acciones y predecir la tendencia pero si tiene que examinar mil acciones carece de capacidad para procesar toda esa información en un periodo acotado de tiempo.

El correcto funcionamiento del TA se logra a partir de equipos de trabajo. Es importante que existan diferentes perfiles trabajando en conjunto, ya que normalmente los algoritmos llevan demasiado tiempo de desarrollo. Estos equipos generalmente son: de investigación, de desarrollo, de testeo, de puesta en marcha y de mantenimiento.

A su vez, no solo dentro de la empresa, sino a la hora de salir al mercado hay muchos actores que participan dentro del *trading* algorítmico. Dentro de ellos tenemos: los agentes implementadores, el mercado como regulador de los algoritmos, los centros reguladores como la Comisión Nacional de Valores (CNV) de Argentina, y las empresas proveedoras de tecnología, es decir los oferentes de una plataforma que facilita la ejecución de algoritmos en el mercado.

Por otro lado, es importante comprender que existen distintos tipos de TA. Uno de ellos es el *High Frequency Trading* (HFT) que difiere de otros debido a su uso de tecnología para el procesamiento de información que admite una ejecución más rápida, y su implementación a través de estrategias de *trading* resultan en una gran cantidad de transacciones que se realizan a diario (Brogaard et al., 2014).

El HFT se caracteriza por una dependencia de programas informáticos sofisticados y de alta velocidad. Un desarrollo relacionado al mismo es el espectro de errores de software en Operaciones

HFT que conducen a pérdidas dramáticas, rápidas e irrecuperables. Los ejemplos incluyen el “*flash crash*”² de mayo de 2010 (Kirilenko et al., 2014) y la falla del software de *Knight Capital*³ en 2012 que causó pérdidas de US\$460 millones en microsegundos. Estos problemas crearon la necesidad de una supervisión regulatoria para asegurar que la adopción de innovaciones tecnológicas no dañaran la calidad general de los mercados (Kauffman et al., 2015). Es por ello que en cada mercado funcionan reglas propias de cada país y de esa manera se restringe la libertad de una entidad para programar un algoritmo, con el fin de garantizar operatorias avaladas dentro del marco de la ley.

- Señales e indicadores del análisis técnico más utilizados con esta herramienta

Detrás de todo algoritmo hay una *trader* que determina una estrategia utilizando el análisis técnico o el análisis fundamental. En el análisis técnico se pueden utilizar una gran variedad de indicadores. Éstos son fórmulas que miden diferentes aspectos de un conjunto de datos financieros dados (Kampouridis y Otero, 2016). A su vez, se utilizan para identificar los puntos de entrada y salida apropiados para los algoritmos de *trading*, es decir, funcionan como una señal para que se ejecute una orden (Sezer et al., 2017).

Por otro lado, se pueden utilizar estos indicadores para realizar una evaluación cuantitativa del rendimiento de una estrategia de TA. El objetivo central de la misma es ser rentable, y es por ello que su desempeño debe estar vinculado a la cantidad de dinero generado. Sin embargo, dicho razonamiento omite considerar el riesgo asociado a la actividad que debe ser mitigado de manera eficiente. En general, se prefiere una estrategia que logra una ganancia pequeña pero estable a una que logra una gran ganancia de una manera muy inestable después de sufrir múltiples pérdidas. Eventualmente depende del perfil del inversionista y la voluntad de asumir riesgos adicionales para ganar más potencialmente (Théate y Ernst, 2021).

Hay muchos indicadores y osciladores famosos y cualquiera de ellos puede ser utilizado para programar un algoritmo. A modo de ejemplo, se destacan los siguientes:

- (1) **Índice de fuerza relativa (*Relative Strength Index* o **RSI**):** es un oscilador construido sobre un promedio de velas⁴ que cierran al alza o a la baja, es decir una media móvil con segmentación de las velas que cierran positivo y negativo, en base a eso se hace una media móvil de cada una y construis un oscilador con esas dos. Es un oscilador acotado, va entre 0 y 100 (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).
- (2) **MACD (*Moving Average Convergence Divergence*):** en su traducción al español, Media Móvil de Convergencia/Divergencia, es otro indicador muy utilizado. El mismo es una construcción que resta dos medias móviles, y después oscila sobre la media móvil de esa resta (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).
- (3) **Bandas de *Bollinger*:** son una media móvil con más o menos un desvío, dependiendo si el límite es superior o inferior. El indicador está en la banda superior de la banda

² Desplome veloz e inesperado, que puede ser seguido de una recuperación, en el valor de cotización de una moneda.

³ Compañía de inversión que se dedica a la compra-venta de acciones en la bolsa de Wall Street.

⁴ Las velas ofrecen información sobre la cotización de una acción u otros productos del mercado bursátil. Muestran cuatro precios en la misma figura, es muy utilizado en el análisis técnico bursátil.

de *Bollinger* cuando se encuentra más de dos desvíos sobre la media móvil, entonces supone que va a rebotar hacia abajo, si se sobre-vendió va a subir o si se sobre-compró va a corregir para abajo (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

(4) **Promedio móvil (MA):** Permite a los *traders* observar cualquier cambio en la tendencia de los precios de una acción. Normalmente, cuando una media móvil a corto plazo supera una media móvil a largo plazo indica un impulso alcista (Kampouridis, 2016).

(5) **Trade Break Out (TBR):** Para comprender mejor este indicador, primero debemos explicar dos términos: soporte y resistencia. El soporte es el punto en el que el precio deja de bajar, mientras que la resistencia es el punto en el que el precio no sube más. El análisis técnico sugiere que las tendencias de precios a la baja tienden a revertirse en los puntos de soporte, mientras que las tendencias al alza tienden a revertirse en los puntos de resistencia. Sin embargo, cuando se superan estos puntos de ruptura (*break out*), quizás debido a alguna nueva información sobre el mercado, es probable que el precio continúe en la misma dirección. Por lo tanto, los *traders* tienden a observar estas rupturas y cuando una acción supera su punto de resistencia, compran; cuando, por otro lado, el precio de las acciones cae por debajo de su punto de soporte, los *traders* venden (Kampouridis, 2016).

(6) **Filtro (FLR):** Este indicador se utiliza para indicar acciones de compra o venta, dependiendo de si el movimiento del precio va en la dirección opuesta en un porcentaje predefinido. Por ejemplo, si el precio se revierte de una tendencia a la baja y aumenta en un porcentaje específico desde el precio bajo que tenía anteriormente, entonces el operador realizará una acción de "compra" (Kampouridis, 2016).

(7) **Volatilidad (Vol):** Un período de mayor volatilidad podría indicar un cambio de tendencia o fuertes tendencias a la baja. Por lo tanto, esto le daría una indicación a un *trader* de que debe ser cauteloso. Por el contrario, cuando hay un período de volatilidad decreciente, esto indica tendencias alcistas y los operadores deberían comprar (Kampouridis, 2016).

(8) **Momentum (Mom):** Cuando este indicador es positivo indica una tendencia al alza. Si el Mom comienza a disminuir, esto podría ser una indicación de que habrá una reversión en la tendencia alcista anterior y, por lo tanto, los *traders* deben ser cautelosos. Finalmente, cuando el Mom es negativo, esto indica una tendencia a la baja (Kampouridis, 2016).

(9) **Momentum Moving Average (MomMA):** Finalmente, desde Mom también podemos calcular su promedio móvil (MA), lo que permite obtener resúmenes de los movimientos de Momentum (Kampouridis, 2016).

Por otro lado, se puede se pueden diferenciar dos grandes ramas de indicadores:

❖ **Indicadores de *following*, de *trend following*, de tendencia, o de *momentum*:** son indicadores tardíos, de todas construcciones sobre medias móviles. En general, los que más funcionan son cruces de muchas velas porque se ingresa a la tendencia cuando ya está desarrollada o está desarrollándose (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

❖ **Indicadores *contrarians*:** indicadores que tratan de anticipar un cambio de tendencia rápidamente (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

También se programan muchos algoritmos en base a datos de análisis fundamental, no todo está basado en análisis técnico. Por ejemplo con datos estadísticos, con la cantidad de ventas de viviendas de primera o segunda mano, datos de empleo, reservas de petróleo, reservas naturales, cómo van variando los stock del petróleo, de la cantidad de barriles del petróleo, entre otros datos que pueden ser utilizados a la hora de programar un algoritmo (D. Collivadino, comunicación personal, 25 de noviembre de 2021).

Otro ejemplo muy interesante son los indicadores de sentimiento, que buscan rastrear en las redes sociales datos acerca de pensamientos positivos o negativos con respecto a una determinada empresa. Si se quisiera rastrear la acción de Coca-Cola, analizo en *Twitter* las menciones Coca-Cola o KO, que es su símbolo, cada cierto rango de tiempo y durante un periodo de un mes por ejemplo, para calcular un promedio de menciones diarias y armar un indicador.

A su vez, es posible construir otros indicadores con datos de la economía real, si contamos con acceso a cierta información sobre la misma. A pesar de que no tenga relación directa con la bolsa en algún momento esos datos se van a reflejar dentro del mercado, afectando el precio de los activos financieros. A modo de ejemplo, si una empresa vende más y esto se puede anticipar, evidentemente, cuando presente balance, se tendrá cierta ventaja de haber tenido esa información antes y siempre que la misma sea obtenida mediante medios públicos y legales. También existen muchas APIs ⁵e información accesible que se encuentra correlacionada, por ejemplo, hay muchas empresas de entretenimiento, que les incide la información del clima, por eventos, viajes y vuelos.

- Activos financieros más adecuados para operar con *trading* algorítmico

Las estrategias de *trading* algorítmico son adecuadas para aplicar en diferentes mercados. Las acciones se pueden negociar en los mercados bursátiles, el comercio FOREX⁶ se refiere a divisas extranjeras, o un *trader* podría invertir en futuros de productos básicos, por solo citar algunos. El reciente auge de las criptomonedas, como Bitcoin, también ofrece nuevas e interesantes posibilidades (Théate y Ernst, 2021).

Los mercados financieros globales actuales están fuertemente poblados por sistemas de *trading* algorítmico automatizados, estos sistemas computarizados reemplazan en gran medida a los *traders* humanos en el punto de ejecución. A través de estos sistemas, se comercializan diversos tipos de activos negociables como acciones, divisas, materias primas, contratos de deuda de renta fija y contratos de derivados (Cliff, 2018).

Otros activos financieros que operan con *Trading* Algorítmico fuera del mercado de capitales son las criptomonedas, entre ellas: Bitcoin, Ethereum, Cardanos, XRP. La complejidad es alta debido a que la capacidad y probabilidad de acertamiento no siempre es alta, por lo que se debe tener en consideración cuestiones como el monto a invertir, los impuestos, el tiempo, la alta variabilidad.

Es importante destacar que todos los activos financieros pueden operar con *trading* algorítmico. Cada activo posee un nivel de riesgo distinto, lo que provoca que no sea tan sencillo efectuar una operación, y es por eso que con el *trading* algorítmico se busca simplificar el proceso. Por lo tanto, según la estrategia utilizada, se van a definir los activos sobre los que se quiere operar. Como por ejemplo:

⁵ Una API o interfaz de programación de aplicaciones es un conjunto de definiciones y protocolos que se usa para diseñar e integrar el software de las aplicaciones

⁶ Mercado mundial y descentralizado en el que se negocian divisas

- *Market making*: en Argentina principalmente lo vemos en lo que son futuros de dólar. Estos algoritmos son particulares porque tienen una manera de trabajar en los cuales se debe ir cubriendo una posición, básicamente lo que se busca es comprar barato y vender caro.

- Operaciones de mesa: se operan cauciones y tasas día a día, que buscan ganarle a la inflación.

- Estrategias más utilizadas en el *trading* algorítmico

Para tener éxito en el mercado financiero, cada participante determina una estrategia de *trading* en función de su aversión al riesgo y el horizonte temporal en el que está dispuesto a invertir. Se tiene en cuenta la identidad personal; para un inversor, una estrategia puede funcionar muy bien, pero para otro, la misma estrategia puede ser absolutamente inaceptable (Lebedev et al., 2018).

Por otro lado, el desempeño de una estrategia también depende de las estrategias de otros *traders* en los mercados. Sin embargo, resulta difícil saber qué estrategias siguen los algoritmos de otros *traders*, ya que esta información es confidencial a modo de que la misma continúe siendo rentable (Wray et al., 2021).

El TA se basa en reglas, lo que significa que las decisiones de inversión se toman de acuerdo a un conjunto de reglas, que son definidas por la estrategia de *trading*. En términos técnicos, una estrategia de este tipo puede verse como una política programada, ya sea determinista o estocástica, que genera una acción de acuerdo con la información disponible para el *trader* en un lapso de tiempo (Théate y Ernst, 2021).

En primer lugar se debe definir un plan de *trading*. En este plan se definen indicadores, osciladores y una estrategia específica. Luego en base a ello, se puede comenzar a programar el algoritmo. Por último, y una de las etapas más importantes a la hora de desarrollar un algoritmo, es la realización de pruebas de *backtesting*⁷. Esto permite obtener una visión anticipada de los resultados que se pueden obtener con ese algoritmo antes de lanzarlo a operar en el mercado de capitales. Estos datos sirven para una retroalimentación y en base a ello se va mejorando el algoritmo hasta el punto que la probabilidad de falla no sea significativa (D. Collivadino, comunicación personal, 25 de noviembre de 2021).

Todas las estrategias de *trading* discrecional⁸ se pueden transformar en algoritmos. En el siguiente apartado se describen algunas de las estrategias más utilizadas según los especialistas entrevistados y la bibliografía consultada:

- **Automatizaciones:** Este tipo de estrategia también se conoce como *trading* automático, se basa en la automatización de procesos y es una de las más utilizadas. Consiste en programar un algoritmo para que realice operatorias complejas en un menor lapso de tiempo. En Argentina, esto lo podemos ejemplificar con el CCL⁹, cada vez que tenemos estas escaladas de este tipo de dólar, numerosos inversores tratan de girar plata desde Argentina

⁷ Consiste en testear una estrategia para saber qué hubiera pasado si hubiésemos actuado de una determinada manera en un tiempo pasado. De esta manera se pueden simular condiciones pasadas con datos históricos.

⁸ El trading discrecional es la operación basada en el propio criterio e intuición del trader sin unas reglas a seguir de forma sistemática.

⁹ Dólar contado con liquidación.

hacia el exterior, lo que genera que los *brokers*¹⁰ tengan una demanda muy fuerte en este tipo de operatoria. Si eso se ejecuta manualmente, un *trader* debería estar buscando los precios en pantalla, sacando cuentas entre dos productos, algo que es tedioso, lento y esto directamente se puede delegar a través de algoritmos. Lo que quita trabajo al operador dándole la posibilidad de ejecutar esas operaciones de una manera automática, eficiente, rápida y sin pérdidas de tiempo (N. Lino, comunicación personal, 23 de noviembre de 2021).

- **Comprar y mantener o *buy and hold*:** normalmente actúa como punto de referencia para los algoritmos de *trading*. El principio de esta estrategia se basa en la opinión de que, a largo plazo, los mercados financieros dan una buena tasa de rendimiento a los inversores. Por lo tanto, en esta estrategia, un inversor compra un activo y lo mantiene durante mucho tiempo, sin preocuparse por los movimientos de precios a corto plazo (Kampouridis y Otero, 2016).

- **Arbitraje:** En mercados poco líquidos, como el de Argentina, ocurren desarbitrajes constantes, es decir, diferencia de precios de un mismo activo en diferentes mercados. Existen algoritmos que están programados para captar y aprovecharse de estas diferencias en el lapso de tiempo hasta que sean corregidos. Los algoritmos de arbitraje en mercados muy líquidos en donde los precios se mueven muy rápido, como los mercados de EEUU, no se ven presentes dado que para poder hacer un arbitraje deberían operar al microsegundo.

Una de las razones por las que se efectúa el arbitraje es porque posee nulo riesgo direccional. El algoritmo está entrenado para buscar dónde conviene comprar, y dónde conviene vender con el fin de salir ganando en todas las alternativas presentes. Tiene sus riesgos de descalce, pero a grandes rasgos son operaciones libres de riesgo.

El aporte de los algoritmos es garantizar que los mercados estén equilibrados o ajustados, haciéndolos más eficientes. A mayor cantidad de algoritmos que funcionen bajo esta estrategia, más justos serán los precios en los diferentes mercados (N. Lino, comunicación personal, 23 de noviembre de 2021).

- **Market Making:** Una situación que sucede cotidianamente en los mercados, es que un activo cotice a un precio, como por ejemplo \$10, y los compradores están dispuestos a pagar \$9,50 mientras que los vendedores desean vender en \$10,50. Esto genera una diferencia, que se conoce como *spread*. Esta diferencia depende de la profundidad y liquidez general del mercado, mientras mayor sean ambas, menor será el *spread* debido a la gran competencia. En mercados chicos e ilíquidos, como por ejemplo el de acciones argentinas, el *spread* puede ser muy elevado y llegar hasta un 5%, lo cual lo hace poco atractivo para inversores.

Es aquí donde toma relevancia la estrategia de *market making*, aquella en la cual los operadores, o en este caso el algoritmo, hace de intermediario entre compradores y vendedores, definiendo el precio del activo con el objetivo de reducir el *spread*. En el ejemplo anterior, el algoritmo se ofrecería a comprar en \$10,40 y vender en \$9,60 de modo de ir cerrando el *spread*.

Cabe destacar que cuando el mercado ya está arbitrado con market makers, los *spreads* son más pequeños y hasta pueden fijarse reglas o condiciones para los mismos, lo que reduciría el

¹⁰Persona o una empresa que intermedia en la compra-venta de productos financieros cargando una comisión al inversor una vez se ejecuta la operación.

beneficio que pueden llegar a obtener (N. Lino, comunicación personal, 23 de noviembre de 2021).

- **Tracking ETF o un fondo común de inversión:** Lo que se busca en esta estrategia es replicar un índice, por ejemplo el Nasdaq¹¹, y con ese fin se seleccionan una determinada cantidad de acciones más representativas, es decir, que mayor correlación con el índice tengan.

Se busca comprar y vender acciones para que la cartera ¹² siga al índice lo mejor posible. Aunque suelen existir diferencias dado que no se puede estar todo el tiempo reposicionando, pero se busca hacerlo de una manera bastante precisa o parecida con un *tracking* ETF. Para eso se programa al algoritmo de manera tal que se pueda alcanzar la mayor correlación posible (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

- **Órdenes iceberg:** Suele ser utilizada por fondos comunes de inversión cuando tienen que colocar una orden común para ellos y sean órdenes muy grandes y puedan causar distorsiones en los precios. Entonces, por lo general cuando los grandes fondos tienen que comprar una acción que no es muy líquida, tienen que hacer un algoritmo que segmente esa orden de gran tamaño en numerosas órdenes de menor tamaño, con un plazo de tiempo límite. Por ejemplo, en lugar de colocar una sola orden de 2 millones de dólares, se coloca una gran cantidad de órdenes pequeñas, cada un tiempo determinado, como podrían ser cinco minutos (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

- **Limit order:** En determinadas situaciones, se busca colocar una orden de compra sin límite de cantidad de activos para esa orden pero sí con un límite en el precio de cada activo que compone esa orden, es decir, se fija un límite de precio por cada acción u orden. Por ejemplo, si un cliente quiere comprar hasta un millón de dólares en acciones, pero no quiere pagar por cada una más de U\$D 9,44. En estos casos, el algoritmo tiene que estar programado para comprar hasta ese precio máximo, y en caso de que el precio del activo aumente, tiene que esperar y dejar que vuelva a bajar para poder seguir operando (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

- **Operaciones de mesa:** Son instrumentos de *money market*¹³, de gran liquidez y que el *broker*, o en este caso el algoritmo, debe estar todo el tiempo optimizando al cierre rueda¹⁴ ya que los valores son muy volátiles. A su vez debe asegurarse de tener la mayor cantidad de dinero invertido, siempre garantizando un cierto margen por si algún inversor quiere salir rápidamente y usar el capital para otro fin. Por ejemplo, hoy en Argentina con las altas tasas de interés que tenemos, la mayoría de los agentes de bolsa ofrecen a los clientes que la plata que tienen líquida, es decir los pesos que tienen en su cuenta comitente sin usar, la coloquen automáticamente en algún tipo de instrumento de caución o de tasa día a día. Este tipo de

¹¹ Segunda bolsa de valores electrónica automatizada más grande de Estados Unidos. Comprende empresas de alta tecnología en electrónica, informática, telecomunicaciones, biotecnología, entre otros.

¹² Grupo de activos que tiene un inversor o una sociedad de inversión

¹³ Cuenta de ahorros que gana intereses, pero con los beneficios de las cuentas de cheques que te permiten utilizar los fondos más libremente.

¹⁴ Es la sesión diaria en la que se negocian los valores.

inversiones son las que lleva a cabo el algoritmo que sigue esta estrategia, con el fin último de evitar de esa manera la desvalorización del dinero del inversor (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

- **Minoristas:** Estas estrategias son utilizadas por inversores individuales, que buscan obtener una rentabilidad mayor que el promedio del mercado. En estos casos se realiza determinada estrategia algorítmica contraria a lo que se conoce como *buy and hold*,¹⁵ es decir comprar hoy y esperar 5 años para vender. Se programa al algoritmo para automatizar diferentes operaciones en el corto plazo que ya han sido testeadas y han superado con éxito el rendimiento promedio de ciertos índices descriptivos del mercado.

Por ejemplo, si la acción de una empresa tiene un rendimiento del 8% anual, a través de esta estrategia se buscará obtener un mayor rendimiento anual, como podría ser un 11% (J. P. Pisano, comunicación personal, 4 de diciembre de 2021).

- **Inteligencia Artificial:** En el último grupo tenemos a los algoritmos cuya estrategia está creada con inteligencia artificial (IA). Existen múltiples diferencias entre estos algoritmos y los que no poseen IA. Un algoritmo programado con IA va a aprender de cuándo una operatoria arrojó un resultado deseado o no deseado, y lo va a poder utilizar en futuras oportunidades. En cambio, un algoritmo que no tiene IA, está programado para hacer determinadas operatorias según los parámetros fijados y lo va a seguir haciendo, más allá del resultado obtenido. Otro aspecto fundamental es que si se realiza un cambio dentro del mercado, el algoritmo que no tiene IA, va a dejar de funcionar de cierta forma, porque sus parámetros no son compatibles con la situación actual. En cambio un algoritmo con IA está entrenado con todos los datos y va a poder actuar en los diferentes escenarios (N. Lino, comunicación personal, 23 de noviembre de 2021).

La IA trabaja con un método científico, es decir tiene un procedimiento para alcanzar el mejor resultado posible. Al programar un algoritmo que tiene IA, se definen los indicadores que te dan una mayor probabilidad de acertamiento para los activos definidos dentro del mercado que se busca operar, y después el algoritmo va aprendiendo solo. A su vez, te permite día a día ir mejorando para cada vez llegar a tener un porcentaje de acertamiento mayor. Eso es una ventaja de la utilización de la IA, mientras más datos y pruebas tengas, mejor porque el algoritmo se retroalimenta de todas estas entradas (E. Alcaraz, comunicación personal, 29 de noviembre de 2021).

Dentro del campo de la IA podemos encontrar la participación del aprendizaje profundo o más conocido como *Deep Learning (DP)*. La aplicación del DP está destinada explícitamente para manejar cantidades significativas de datos, detectando patrones complejos que permiten incrementar la precisión de un algoritmo. El beneficio de DL es que no requiere mucho esfuerzo humano para proporcionar resultados que antes se consideraban imposibles para los humanos. Efectivamente, la IA no dio más inteligencia, sino más capacidad de predicción (Vicari y Gaspari, 2020).

¹⁵ Filosofía de inversión a largo o muy largo plazo basada en la compra de acciones y mantenerlas a lo largo del tiempo.

- Ventajas del *trading* algorítmico sobre el *trading* discrecional

Las ventajas del *trading* algorítmico sobre el *trading* discrecional son abundantes. Por un lado, se simula lo que puede llegar a hacer un *trader* en un día, pero se ejecuta en todo momento, permanentemente. El ser humano nunca va a poder superar la capacidad de procesamiento que tiene una computadora, y gracias al *trading* algorítmico se simplifica toda operación permitiendo procesar enormes cantidades de información, traducirlas en una estrategia y posteriormente elaborar un plan de *trading*.

Al tratarse de seres humanos, en el *trading* discrecional se encuentra una parte psicológica, donde se debe lidiar con los sentimientos, los cuales pueden jugar en contra o a favor, viéndose influenciado por los mismos. Mientras que, lógicamente, el robot no tiene emociones, sino que aprende y hace lo que tiene que hacer en el momento en que se presenta la oportunidad, lo que da una ejecución, entrada y salida al mercado a un mejor precio y de una manera más efectiva. En cambio, en un algoritmo esas cuestiones se dejan de lado.

Otro beneficio importante es que la estrategia seleccionada para un algoritmo puede ser probada con datos históricos, como por ejemplo con una prueba retrospectiva que simula qué tan bien le habría ido a la estrategia en el pasado. Si bien el rendimiento probado no garantiza resultados futuros, puede ser muy útil al evaluar posibles estrategias (Berutich et al., 2016). Esto podría permitir saber la probabilidad de que un precio suba o baje, por lo que el *trader* tiene el poder de decisión de elegir qué porcentaje de acertamiento le parece suficiente para que el algoritmo efectúe una operación.

En último lugar, otra ventaja es que, con los algoritmos, el mercado se torna más líquido, con una mejor formación de precios. Los productos van a ser más líquidos por el hecho de que los proveedores poseen liquidez, como es el caso de los *brokers*, bancos que mueven gran volumen. En el caso de fondos automatizados con *trading* algorítmico, la principal ventaja es la transparencia, la seguridad que otorga al permitir que robots operen con plata de distintos fondos, por lo que la inversión es mejor para el usuario (N. Lino, comunicación personal, 23 de noviembre de 2021).

- Desventajas del *trading* algorítmico sobre el *trading* discrecional

Las desventajas del TA, como cualquier tipo de automatización, son que posee ciertos riesgos. Se presentan algunos eventos como los grandes *flash crash* que han sucedido en el mundo, a raíz de que algoritmos descontrolados comenzaron a chocar uno con otro, generando una caída de precios de los activos de una manera muy veloz. Sin embargo, en la actualidad, se reduce la probabilidad de ocurrencia de este tipo de riesgos dado que los mercados cuentan con regulaciones para los algoritmos. Entre ellas, se destacan precios máximos y mínimos de operatoria a partir del último precio operado, banda de precios para limitar sus movimientos, *switches* de seguridad, entre otras normativas que permiten mantener el correcto funcionamiento de los algoritmos.

A pesar de las normativas hacia los algoritmos, siguen ocurriendo casos de mala parametrización. Esto puede ocasionar desarbitrajes en los precios ya que, por ejemplo, un algoritmo está vendiendo a un precio muy bajo. Esto provoca pérdidas de mayor magnitud y con mayor rapidez

que cuando ocurre un error humano. Los algoritmos están preparados para enviar miles de órdenes en segundos y eso puede generar una caída/alza en un precio. Lo que se convierte en una gran desventaja debido a que puede generar un impacto muy fuerte en el mercado.

Otra de las desventajas es que hay aprendizajes que el algoritmo, en específico los que operan con IA, adquiere por su propia cuenta. Esto lleva a que la persona que dirige el algoritmo, pierda esa capacidad de poder entender qué hace ese algoritmo que trabaja con autonomía guiado por la IA.

También cabe destacar que los algoritmos no son útiles en determinadas operaciones que no requieren mucha capacidad de procesamiento, pero sí una capacidad de análisis cualitativo. Por ejemplo, frente a un determinado nivel de euforia o pánico en el mercado por algún evento, ante el cual se detectan comportamientos extraños, un operador humano tiene experiencia frente a los mismos y puede reaccionar de manera correcta, pero es difícil programar un algoritmo para saber responder a estas situaciones. Existen conocimientos humanos que no son meramente cuantitativos o numéricos y son difíciles de transferir al algoritmo.

Otra cuestión es que el *trading* algorítmico parece simple y atractivo, pero hay que llevarlo a cabo, mantenerlo, y mejorarlo. El algoritmo que no sea supervisado, puede generar grandes inconvenientes. Hay que dedicarle tiempo para asegurar su correcto funcionamiento y la paciencia se convierte en un factor clave para el éxito.

- El *trading* algorítmico en Argentina

Al analizar el *Trading* Algorítmico (TA) en Argentina, nos encontramos con un escenario más simplificado en relación al resto del mundo. Son los intermediarios o participantes del mercado, como las ALYCs¹⁶, bancos, y fondos de inversión, quienes operan directamente en los mercados y contratan plataformas de TA o contratan sus propios desarrolladores internos para poder desarrollar y ejecutar algoritmos. Hay escasez de inversores individuales que operen con esta herramienta.

En cuanto a los tipos de activos financieros que operan con TA, se observa que hay una gran variedad de activos que van rotando según la normativa, pero los que toman mayor relevancia son los que están ligados al dólar ya que se asocia al mercado argentino con una “gran casa de cambio”. Cada vez que aparece una nueva regulación al dólar por parte de la CNV, surge también una nueva manera de evadir esa regulación, lo que conlleva a que vayan migrando los tipos de operatoria y los tipos de activos financieros que se van operando con el TA. Por otro lado, existen empresas que están utilizando al TA como herramienta de cobertura.

La implementación del TA en Argentina se da a finales del año 2019 y principios del 2020, es por ello que aún no se conoce mucho acerca de esta herramienta y está menos regulada. Existen algoritmos que se están ejecutando para arbitrar el mercado pero al ser un mercado de poco volumen e ilíquido, no tiene la atractividad para explotar el TA (N. Lino, comunicación personal, 23 de noviembre de 2021).

¹⁶ Los Agentes de Liquidación y Compensación (ALyC) son las partes intervinientes en la liquidación y compensación de operaciones (colocación primaria y negociación secundaria), ya sea para ellos mismos o para sus clientes.

Figura 2. Principales hallazgos

Funcionamiento del <i>trading</i> algorítmico dentro del mercado de capitales	Señales e indicadores del análisis técnico más utilizados con esta herramienta	Activos financieros más adecuados para operar con <i>trading</i> algorítmico	Estrategias más utilizadas en el <i>trading</i> algorítmico
<ul style="list-style-type: none"> • Permite determinar automáticamente los parámetros de las órdenes. • Desempeñan las funciones que tradicionalmente realizaban los <i>traders</i> humanos. • Son capaces de analizar grandes cantidades de datos y reaccionar en pequeñas fracciones de tiempo. • El correcto funcionamiento del TA se logra a partir de equipos de trabajo para su puesta en marcha, ejecución y tareas de mantenimiento. 	<ul style="list-style-type: none"> • Fórmulas que miden diferentes aspectos de un conjunto de datos financieros dados • Utilizados para identificar los puntos de entrada y salida apropiados para los algoritmos de <i>trading</i>, es decir, funcionan como una señal para que se ejecute una orden. • A través de los mismos se puede realizar una evaluación cuantitativa del rendimiento de una estrategia de TA. • Existe una gran cantidad de indicadores y osciladores reconocidos y cualquiera de ellos puede ser utilizado para programar un algoritmo. 	<ul style="list-style-type: none"> • Todos los activos financieros pueden operar con <i>trading</i> algorítmico. • Según la estrategia utilizada, se van a definir los activos sobre los que se quiere operar. 	<ul style="list-style-type: none"> • Cada participante determina una estrategia de <i>trading</i> en función de su aversión al riesgo y el horizonte temporal en el que está dispuesto a invertir. • Se debe definir un plan de <i>trading</i>. En este plan se definen indicadores, osciladores y una estrategia específica. • Todas las estrategias de <i>trading</i> discrecional se pueden transformar en algoritmos. • Algunas de las más utilizadas son: Automatizaciones, <i>Buy and Hold</i>, Arbitraje, <i>Market Making</i>, <i>Tracking ETF</i>, Órdenes <i>iceberg</i>, <i>Limit order</i>, Operaciones de mesa, Minoristas e Inteligencia Artificial.

Fuente: elaboración propia

VI. Conclusiones/Implicaciones/Limitaciones

Conclusiones

La tecnología está revolucionando el mundo de las finanzas, y el ser humano debe ser capaz de aprovechar el poder de la misma. En particular, en el mundo del *trading*, las operaciones se están automatizando y se vuelve imprescindible aprender acerca de la herramienta del *trading* algorítmico, no necesariamente para aplicarlo pero si para entender acerca de qué trata.

Se observa que el TA tiene un funcionamiento similar al trading discrecional, pero con un enfoque en tareas que requieren una mayor capacidad de procesamiento y con mayor rapidez que un humano. Tiene la capacidad de analizar grandes cantidades de datos y reaccionar en pequeñas fracciones de tiempo, hecho que se vuelve relevante en un mundo que está avanzando en su compromiso con la ciencia de datos e inteligencia artificial.

El trading algorítmico es el uso de algoritmos informáticos para determinar automáticamente los parámetros de las órdenes de compra o venta de un activo financiero. Es a través de datos que se generan estas señales de compra y venta que se constituyen en una regla que el algoritmo debe cumplir. Estos datos son indicadores que se utilizan para identificar los puntos de entrada y salida apropiados para los algoritmos y para evaluar el rendimiento de una estrategia. Existe una extensa variedad de indicadores que se pueden utilizar, pero en este trabajo se resumieron solo algunos a modo de ayuda para una mejor comprensión del tema. Luego de analizar la información recabada, se encontró que no existen indicadores que den mejores resultados sino que la utilización de los

mismos depende de la estrategia del *trader* que esté programando o participando en la programación de su algoritmo.

Una situación similar a lo explicado anteriormente, sucede con los activos financieros. No existen activos financieros que no puedan operar bajo esta modalidad, ni tampoco alguno que sea más eficiente. Se observa que la utilización de un tipo particular de activo financiero con esta herramienta depende de la estrategia del *trader* y del mercado en el que se opere. En el caso particular de Argentina, los activos vinculados al dólar son los que poseen mayor presencia al momento de operar en el mercado de capitales.

En los mercados funcionan reglas propias de cada país para poder regular, controlar, e imponer límites a la hora de programar un algoritmo y lanzarlo al mercado. Esto sucede por el potencial que tienen los algoritmos para influir en el comportamiento del mercado. Además, un algoritmo puede llevar a pérdidas dramáticas, rápidas e irreversibles si no se realiza un control adecuado. A modo de ejemplo, se puede mencionar los eventos conocidos como “*Flash Crash*” y “*Knight Capital*” en 2010 y 2012 respectivamente.

A pesar de lo anterior, el *trading* algorítmico posee ventajas excepcionales sobre el *trading* discrecional. Entre ellas se destaca la capacidad de procesamiento superior que tiene una computadora que simplifica toda operación y reduce los tiempos empleados. Esto conduce a poder automatizar diversas tareas sin importar la complejidad de las mismas. Por otro lado, elimina la toma de decisiones emocionales del proceso de inversión, dado que un *trader* puede verse influido por las emociones, distorsionando decisiones racionales y aumentando la probabilidad de equivocarse.

Otro aspecto importante a destacar es que la estrategia seleccionada para un algoritmo puede ser probada con datos históricos, como por ejemplo con una prueba retrospectiva que simula qué tan bien le habría ido a la estrategia en el pasado. Estas pruebas son llevadas a cabo en la etapa de *backtesting* y permiten saber las probabilidades de falla que tiene el algoritmo antes de lanzarlo al mercado. Si bien el rendimiento probado no garantiza resultados futuros, ayuda a probar la efectividad de la estrategia.

A la hora de analizar las desventajas del *Trading* Algorítmico, la más destacada es el hecho de que pueden dañar la calidad general de los mercados, lo que genera necesidad de una supervisión regulatoria. Además, los algoritmos llevan demasiado tiempo de desarrollo y requieren actividades de mantenimiento y mejora, por lo que se necesita de equipos de trabajo comprometidos y atentos a toda innovación que deba ser tenida en cuenta para no quedar en obsolescencia.

Al hacer referencia a las estrategias, se puede mencionar que cada participante determina una estrategia de *trading* en función de su aversión al riesgo y el horizonte temporal en el que está

dispuesto a invertir. Resulta de vital importancia tener previamente definido un plan de *trading*, con sus indicadores y estrategias correspondientes a la hora de ejecutar el algoritmo.

Todas las estrategias de *trading* discrecional se pueden transformar en algoritmos. Algunas de las estrategias más utilizadas en la TA según los especialistas entrevistados son: automatización, arbitraje, *market making*, *tracking* ETF o un fondo común de inversión, órdenes *iceberg*, *limit order*, operaciones de mesa, minoristas e inteligencia artificial.

Implicaciones

Con este trabajo se espera que las personas interesadas en los mercados de capitales y aquellas que trabajan en los mismos, puedan comprender el funcionamiento del trading algorítmico. Se propone dar a conocer esta nueva modalidad de operar en los mercados con la finalidad de dotar a las personas de los conocimientos necesarios para favorecer su inclusión social y digital en el mundo de las finanzas.

Además, se busca informar al lector acerca de las ventajas y desventajas de la utilización de esta herramienta, y que éste pueda entender las estrategias con las que es conveniente su implementación y los activos financieros pertinentes para utilizarla. Asimismo, se espera que este trabajo funcione como punto de partida para realizar posteriores investigaciones y/o incluir esta herramienta en la toma de decisiones de inversores e instituciones interesadas en el tema.

Por otro lado, observamos que en el mercado de valores se ve cada vez más este tipo de *trading*. Y al ser tan versátil y adaptarse a distintos activos debe ser tenida en cuenta al momento de operar en el mercado como una gran oportunidad. Todo el conocimiento en *trading* discrecional puede potenciarse con el uso de algoritmos. Las personas pueden dejar de lado ciertas tareas repetitivas y aprovechar su tiempo para desarrollar estrategias más rentables que le permitan sacar un mejor provecho de sus inversiones.

Consideramos importante que inversores, tanto mayoristas como minoristas, puedan perder su aversión al riesgo con respecto a esta herramienta y empezar a utilizarla sacando provecho de las ventajas de la tecnología. Hoy en día existen muchos proveedores de plataformas de *trading* algorítmico que facilitan los primeros pasos con el uso de esta herramienta.

Por último, se procurará captar a programadores que posean conocimiento técnico para la construcción de algoritmos, buscando que se interesen en el tema, logrando complementar sus habilidades con conocimientos en finanzas, y de esta manera optimizar el funcionamiento y dinamismo del mercado de capitales.

Limitaciones

La primera limitante del trabajo y una de las más importantes, en la revisión bibliográfica, fueron los criterios del protocolo de investigación, más específicamente, la condición de seleccionar solo artículos de libre acceso. Esto generó que artículos de calidad y validez puedan haber sido dejados de lado.

Además de esa limitación, otra importante es el idioma, en el protocolo de investigación se estableció la condición de aceptar únicamente los artículos que hayan sido redactados en inglés o el español. Esto implica que, si bien puede haber documentos de calidad en otro idioma, estos no fueron tenidos en cuenta para esta investigación. Los idiomas de los textos que fueron dejados de lado son francés, alemán, portugués y ucraniano.

Por último, otra de las restricciones limitantes fue el hecho de no llegar a la saturación de información con las entrevistas, por una cuestión de tiempo y cantidad de páginas a redactar, solamente se realizaron 4 entrevistas y en ninguna de ellas se repitieron las mismas respuestas.

VII. Referencias bibliográficas

Aldrich, E. M., Demirci, H. A., & Vargas, K. L. (2020). An oTree-based flexible architecture for financial market experiments. *Journal of Behavioral and Experimental Finance*, 25, 100205. <https://doi.org/10.1016/j.jbef.2019.03.007>

Alfonso, G., Carnerero, A. D., Ramirez, D. R., & Alamo, T. (2021). Receding horizon optimization of large trade orders. *IEEE Access*, 9, 63865-63875. <https://doi.org/10.1109/ACCESS.2021.3075700>

Aloud, M. (2021). Designing Strategies for Autonomous Stock Trading Agents using a Random Forest Approach. *International Journal of Advanced Computer Science and Applications*, 12 (7), 781-791. <https://pdfs.semanticscholar.org/6dd9/0b152dcb5cda46e3640e3648e46d28838372.pdf>

Aloud, M. E. & Alkhamees, N. (2021). Intelligent Algorithmic Trading Strategy Using Reinforcement Learning and Directional Change. *IEEE Access*, 9, 114659-114671. <https://doi.org/10.1109/ACCESS.2021.3105259>

Bada, O., Kneip, A., Liebl, D., Mensinger, T., Gualtieri, J., & Sickles, R. C. (2022). A wavelet method for panel models with jump discontinuities in the parameters. *Journal of Econometrics*, 226(2), 399-422. <https://doi.org/10.1016/j.jeconom.2021.09.006>

Bakhach, A., Chinthapati, V. L. R., Tsang, E. P., & El Sayed, A. R. (2018). Intelligent dynamic backlash agent: A trading strategy based on the directional change framework. *Algorithms*, 11(11), 171. <https://doi.org/10.3390/a11110171>

Bakhach, A. M., Tsang, E. P., & Raju Chinthapati, V. L. (2018). TSFDC: A trading strategy based on forecasting directional change. *Intelligent Systems in Accounting, Finance and Management*, 25(3), 105-123. <https://doi.org/10.1002/isaf.1425>

Barrera González, L. (16 - 20 de septiembre de 2013). *Algoritmos y programación para la enseñanza y aprendizaje de la matemática escolar* [Resumen de presentación de la conferencia]. Congreso Iberoamericano de Educación Matemática, Montevideo, Uruguay. <http://funes.uniandes.edu.co/18563/1/Barrera2013Algoritmos.pdf>

BBC Mundo (6 de febrero de 2018). "Trading algorítmico": cómo funcionan y qué tienen que ver los algoritmos con la caída de la bolsa de Wall Street. *British Broadcasting Corporation*. <https://www.bbc.com/mundo/noticias-42960565>

Berutich, J. M., López, F., Luna, F., & Quintana, D. (2016). Robust technical trading strategies using GP for algorithmic portfolio selection. *Expert Systems with Applications*, 46, 307-315. <https://doi.org/10.1016/j.eswa.2015.10.040>

Brogaard, J., Hendershott, T., & Riordan, R. (2014). High-frequency trading and price discovery. *The Review of Financial Studies*, 27(8), 2267-2306. <https://doi.org/10.1093/rfs/hhu032>

Calvo, A., Parejo, J. A., Rodríguez, L., & Cuervo, Á. (2014). *Manual del sistema financiero español*. Editorial Ariel. https://static0planetadelibroscom.cdnstatics.com/libros_contenido_extra/29/28771_Manual_Sistema_Financiero.pdf

Carta, S. M., Consoli, S., Podda, A. S., Recupero, D. R., & Stanciu, M. M. (2021). Ensembling and dynamic asset selection for risk-controlled statistical arbitrage. *IEEE Access*, 9, 29942-29959. <https://doi.org/10.1109/ACCESS.2021.3059187>

Cauas, D. (2015). “Definición de las variables, enfoque y tipo de investigación”. *Bogotá: biblioteca electrónica de la universidad Nacional de Colombia*, vol. 2, pp. 1-11

Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., y Oliveira, A. L. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55, 194-211. <https://www.sciencedirect.com/science/article/abs/pii/S095741741630029X?via%3Dihub>

Codina, L. (2018). *Revisiones bibliográficas sistematizadas: procedimientos generales y Framework para ciencias humanas y sociales* [Tesis de Maestría, Universitat Pompeu Fabra]. Repositorio Institucional - Universitat Pompeu Fabra

Dixon-Woods, M., Cavers, D., Agarwal, S., Annandale, E., Arthur, A., Harvey, J., ... & Sutton, A. J. (2006). Conducting a critical interpretive synthesis of the literature on access to healthcare by vulnerable groups. *BMC medical research methodology*, 6(1), 1-13. <https://link.springer.com/article/10.1186/1471-2288-6-35>

Donadio, S. y Ghosh, S. (2019). *Learn Algorithmic Trading*. Editorial Packt.

Dzalbs, I., & Kalganova, T. (2018). Forecasting price movements in betting exchanges using cartesian genetic programming and ANN. *Big data research*, 14, 112-120. <https://doi.org/10.1016/j.bdr.2018.10.001>

Edwards, R. D., Magee, J., & Bassetti, W. H. C. (2021). *Análisis técnico de las tendencias de los valores*. Profit Editorial.

Fister, D., Perc, M. & Jagrič, T. (2021). Two robust long short-term memory frameworks for trading stocks. *Applied Intelligence*, 51(10), 7177-7195. <https://link.springer.com/article/10.1007/s10489-021-02249-x>

Financial Stability Board (2017). Artificial intelligence and machine learning in financial services: Market developments and financial stability implications. *Financial Stability Board*, 45. <https://www.fsb.org/wp-content/uploads/P011117.pdf>

García Campo, M. I. (2015). *Gestión administrativa para el asesoramiento de productos y servicios financieros de pasivo*. Ediciones Paraninfo.

Gabaldón Codesido, E. (2016). *La regulación de la venta en corto en el mercado bursátil* [Tesis de Doctorado, Universidad Complutense de Madrid]. Repositorio Institucional - Universidad Complutense de Madrid.

Ha, Y., & Zhang, H. (2020). Algorithmic trading for online portfolio selection under limited market liquidity. *European Journal of Operational Research*, 286(3), 1033-1051. <https://doi.org/10.1016/j.ejor.2020.03.050>

Hendershott, T., & Riordan, R. (2009). *Algorithmic trading and information* [Archivo PDF] https://archive.nyu.edu/bitstream/2451/29506/2/Hendershott_Riordan_09-08.pdf

Kampouridis, M., & Otero, F. E. (2017). Evolving trading strategies using directional changes. *Expert Systems with Applications*, 73, 145-160. <https://doi.org/10.1016/j.eswa.2016.12.032>

Kauffman, R. J., Liu, J., & Ma, D. (2015). Innovations in financial IS and technology ecosystems: High-frequency trading in the equity market. *Technological Forecasting and Social Change*, 99, 339-354. <https://doi.org/10.1016/j.techfore.2014.12.001>

Li, X., Deng, Z., & Luo, J. (2009). Trading strategy design in financial investment through a turning points prediction scheme. *Expert Systems with Applications*, 36(4), 7818-7826. <https://doi.org/10.1016/j.eswa.2008.11.014>

Li, Y., Zheng, W., & Zheng, Z. (2019). Deep robust reinforcement learning for practical algorithmic trading. *IEEE Access*, 7, 108014-108022. <https://doi.org/10.1109/ACCESS.2019.2932789>

Manahov, V., & Zhang, H. (2019). Forecasting financial markets using high-frequency trading data: Examination with strongly typed genetic programming. *International Journal of Electronic Commerce*, 23(1), 12-32. <https://doi.org/10.1080/10864415.2018.1512271>

McGroarty, F., Booth, A., Gerding, E., & Chinthapati, V. L. (2019). High frequency trading strategies, market fragility and price spikes: an agent based model perspective. *Annals of*

Operations Research, 282(1), 217-244. <https://link.springer.com/article/10.1007/s10479-018-3019-4>

Molnar, C. (2020). *Interpretable machine learning*. Leanpub.

Navia-Rodríguez, J. R., Cobos-Lozada, C. A., & Mendoza-Becerra, M. E. (2020). Trading Algorítmico para la Predicción de Series de Tiempo Financieras: Una Revisión Sistemática. *Revista Ibérica de Sistemas e Tecnologías de Informação*, 38, 337-357. https://www.researchgate.net/profile/Carlos-Cobos-5/publication/348728100_Trading_for_Financial_Time_Series_Prediction_A_Systematic_Review/links/600ceda7299bf14088b8e83b/Trading-for-Financial-Time-Series-Prediction-A-Systematic-Review.pdf

Nickolaevich, L. I., Igorevna, G. I., & Grigorievich, R. D. (2020). Generating a Multi-Timeframe Trading Strategy based on Three Exponential Moving Averages and a Stochastic Oscillator. *International Journal of Technology*, 11(6), 1233-1243. <https://doi.org/10.14716/ijtech.v11i6.4445>

Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). Efficient stock-market prediction using ensemble support vector machine. *Open Computer Science*, 10(1), 153-163. <https://doi.org/10.1515/comp-2020-0199>

Park, D. Y., & Lee, K. H. (2021). Practical algorithmic trading using state representation learning and imitative reinforcement learning. *IEEE Access*, 9, 152310-152321. <https://doi.org/10.1109/ACCESS.2021.3127209>

Pérez Santos, V. M. (2014). *Robotrader: sistemas algorítmicos de trading en los mercados financieros* [Tesis de Grado, Universidad de La Laguna]. Repositorio Institucional - Universidad de La Laguna

Rouhiainen, L (2018). *Inteligencia artificial. 101 cosas que debes saber hoy sobre nuestro futuro*. Editorial Planeta. https://static0planetadelibroscom.cdnstatics.com/libros_contenido_extra/40/39308_Inteligencia_artifigebra_Apcial.pdf

Saifan, R., Sharif, K., Abu-Ghazaleh, M., & Abdel-Majeed, M. (2020). Investigating algorithmic stock market trading using ensemble machine learning methods. *Informatica*, 44(3). <https://doi.org/10.31449/inf.v44i3.2904>

Scherk, A. (2011). *Manual de Análisis Fundamental*. Inversor Ediciones.

Srivastava, P. R., Zhang, Z. J., & Eachempati, P. (2021). Deep neural network and time series approach for finance systems: predicting the movement of the Indian stock market. *Journal of*

Organizational and End User Computing (JOEUC), 33(5), 204-226.
<https://doi.org/10.4018/JOEUC.20210901.0a10>

Terentiev, O., Prosiankina-Zharova, T., Savastiyarov, V., Lakhno, V., & Kolmakova, V. (2021). The Features of Building a Portfolio of Trading Strategies Using the SAS OPTMODEL Procedure. *Computation*, 9(7), 77. <https://doi.org/10.3390/computation9070077>

Théate, T., & Ernst, D. (2021). An application of deep reinforcement learning to algorithmic trading. *Expert Systems with Applications*, 173, 114632. <https://doi.org/10.1016/j.eswa.2021.114632>

Tigani, S., Chaibi, H., & Saadane, R. (2019). Gaussian Mixture and Kernel Density-Based Hybrid Model for Volatility Behavior Extraction From Public Financial Data. *Data*, 4(1), 19. <https://doi.org/10.3390/data4010019>

Useche Arévalo, A. J. (2014). Exceso de confianza y optimismo en las decisiones de presupuesto de capital: las finanzas corporativas desde un enfoque centrado en el comportamiento. *Revista Universidad y Empresa*, 16(26), 95-116.

Vezeris, D., Kyrgos, T., Karkanis, I., & Bizergianidou, V. (2020). Automated trading systems' evaluation using d-Backtest PS method and WM ranking in financial markets. *Investment Management & Financial Innovations*, 17(2), 198. [http://dx.doi.org/10.21511/imfi.17\(2\).2020.16](http://dx.doi.org/10.21511/imfi.17(2).2020.16)

Vicari, M., & Gaspari, M. (2021). Analysis of news sentiments using natural language processing and deep learning. *Ai & Society*, 36(3), 931-937. <https://link.springer.com/article/10.1007/s00146-020-01111-x>

Quintana Peña, A. (2006). Metodología de investigación científica cualitativa. En Quintana Peña, A. y Montgomery, W. (Eds.), *Psicología tópicos de actualidad* (pp. 65-73). <http://biblioteca.udgvirtual.udg.mx/jspui/bitstream/123456789/2724/1/Metodolog%c3%ada%20de%20investigaci%c3%b3n%20cient%c3%adfica%20cualitativa.pdf>

Yang, S. Y., Qiao, Q., Beling, P. A., Scherer, W. T., & Kirilenko, A. A. (2015). Gaussian process-based algorithmic trading strategy identification. *Quantitative Finance*, 15(10), 1683-1703. <https://doi.org/10.1080/14697688.2015.1011684>

Zhang, X.-D. (2020). *A Matrix Approach to Artificial Intelligence*, Springer. <https://doi.org/10.1007/978-981-15-2770-8>

Zhao, Z., & Palomar, D. P. (2018). Mean-reverting portfolio with budget constraint. *IEEE Transactions on Signal Processing*, 66(9), 2342-2357. <https://doi.org/10.1109/TSP.2018.2799193>

VIII. Anexos

Anexo 1

	Título	Autores	Pregunta
1	Automated trading systems evaluation using d-Backtest PS method and WM ranking in financial markets.	Vezeris, D., Kyrgos, T., Karkanis, I., & Bizergianidou, V.	1, 3 y 4
2	A wavelet method for panel models with jump discontinuities in the parameters.	Bada, O., Kneip, A., Liebl, D., Mensinger, T., Gualtieri, J., & Sickles, R. C.	1
3	Algorithmic trading for online portfolio selection under limited market liquidity.	Ha, Y., & Zhang, H.	1
4	An application of deep reinforcement learning to algorithmic trading.	Théate, T., & Ernst, D.	1 y 4
5	An oTree-based flexible architecture for financial market experiments.	Aldrich, E. M., Demirci, H. A., & Vargas, K. L.	1 y 4
6	Analysis of news sentiments using natural language processing and deep learning.	Vicari, M., & Gaspari, M.	1 y 4
7	Deep neural network and time series approach for finance systems: predicting the movement of the Indian stock market.	Srivastava, P. R., Zhang, Z. J., & Eachempati, P.	1
8	Deep robust reinforcement learning for practical algorithmic trading.	Li, Y., Zheng, W., & Zheng, Z.	4
9	Designing strategies for autonomous stock trading agents using a random forest approach.	Aloud, M.	1 y 4
10	Efficient stock-market prediction using ensemble support vector machine.	Nti, I. K., Adekoya, A. F., & Weyori, B. A.	4
11	Ensembling and dynamic asset selection for risk-controlled statistical arbitrage.	Carta, S. M., Consoli, S., Podda, A. S., Recupero, D. R., & Stanciu, M. M.	1, 3 y 4
12	Evolving trading strategies using directional changes.	Kampouridis, M., & Otero, F. E.	1, 2 y 4
13	Forecasting financial markets using high-frequency trading data: examination with strongly typed genetic programming.	Manahov, V., & Zhang, H.	1 y 4
14	Forecasting price movements in betting exchanges using cartesian genetic programming and ANN.	Dzalbs, I., & Kalganova, T.	1 y 4
15	Gaussian mixture and kernel density-based hybrid model for volatility behavior extraction from public financial data.	Tigani, S., Chaibi, H., & Saadane, R.	1
16	Gaussian process-based algorithmic trading strategy identification.	Yang, S. Y., Qiao, Q., Beling, P. A., Scherer, W. T., & Kirilenko, A. A.	1 y 4
17	Generating a multi-timeframe trading strategy based on three exponential moving averages and a stochastic oscillator.	Nickolaevich, L. I., Igovna, G. I., & Grigorievich, R. D.	1, 2 y 4

18	High frequency trading strategies, market fragility and price spikes: an agent based model perspective.	McGroarty, F., Booth, A., Gerding, E., & Chinthalapati, V. L.	1 y 4
19	Innovations in financial IS and technology ecosystems: High-frequency trading in the equity market.	Kauffman, R. J., Liu, J., & Ma, D.	1
20	Intelligent algorithmic trading strategy using reinforcement learning and directional change.	Aloud, M. E., & Alkhamees, N.	1 y 4
21	Intelligent dynamic backlash agent: a trading strategy based on the directional change framework.	Bakhach, A., Chinthalapati, V. L. R., Tsang, E. P., & El Sayed, A. R.	1 y 4
22	Investigating algorithmic stock market trading using ensemble machine learning methods.	Saifan, R., Sharif, K., Abu-Ghazaleh, M., & Abdel-Majeed, M.	1 y 2
23	Mean-reverting portfolio with budget constraint.	Zhao, Z., & Palomar, D. P.	1 y 3
24	Practical algorithmic trading using state representation learning and imitative reinforcement learning.	Park, D. Y., & Lee, K. H.	1
25	Receding horizon optimization of large trade orders.	Alfonso, G., Carnerero, A. D., Ramirez, D. R., & Alamo, T.	1 y 4
26	Robust technical trading strategies using GP for algorithmic portfolio selection.	Berutich, J. M., López, F., Luna, F., & Quintana, D.	1 y 4
27	The features of building a portfolio of trading strategies using the SAS optmodel procedure.	Terentiev, O., Prosiankina-Zharova, T., Savastyanov, V., Lakhno, V., & Kolmakova, V.	1, 3 y 4
28	TSFDC: A trading strategy based on forecasting directional change.	Bakhach, A. M., Tsang, E. P., & Raju Chinthalapati, V. L.	1 y 4
29	Two robust long short-term memory frameworks for trading stocks.	Fister, D., Perc, M., & Jagrič, T.	1 y 4