



Trading a través del indicador RSI con la aplicación de Algoritmos Genéticos para la implementación en el sector empresarial de las inversiones

Trading Through the RSI Indicator Applying Genetic Algorithms for Implementation in the Business Investment Sector

Alberto Antonio Agudelo Aguirre 

Universidad Nacional de Colombia, Manizales, Colombia.

Ricardo Alfredo Rojas Medina 

Universidad Nacional de Colombia, Manizales, Colombia.

Néstor Darío Duque Méndez 

Universidad Nacional de Colombia, Manizales, Colombia.

Resumen

Objetivo: Este artículo propone para la literatura sobre inversión de activos de renta variable una metodología aplicada a través de Algoritmos Genéticos (AG) y su implementación en el sector empresarial de inversión.

Método: El estudio se desarrolló mediante simulación de las estrategias de inversión B&H, AT y AG sobre el índice accionario. El proceso de maximización del rendimiento de inversión para los activos financieros se realizó mediante Algoritmos Genéticos, los cuales se basaron en ecuaciones definidas en la tipificación cromosómica con operaciones inmersas en los genes. Se inició con una población aleatoria de individuos con cromosomas representando una solución para lograr el mayor rendimiento posible. **Resultados:** La aplicación de algoritmos con el RSI generó rendimientos superiores al 9 y 16% respecto a B&H y el análisis técnico, lo que quiere decir, mayor riesgo de inversión para B&H con volatilidad 17,6% pero comparable a las exhibidas por algoritmos genéticos y análisis técnico. **Conclusiones:** Mejor relación rendimiento-riesgo y eficiencia en los parámetros fundamentales de la Teoría de Portafolio es posible a través de estrategias de inversión basadas en algoritmos genéticos incluyendo el oscilador RSI. Este estudio sugiere que un mejoramiento del rendimiento de inversión puede ser anticipado mediante los parámetros stop loss y take profit y un rango de movimiento del precio del activo previo la toma de posición.

Palabras clave: Estrategias de inversión; Mercados de acciones; Trading automático; Trading cuantitativo.

Clasificación JEL: C63, C67, G11, G17, F17, E44.

Abstract

Objective: This article proposes a methodology for the literature on equity asset investment applied through Genetic Algorithms and their implementation in the business investment sector. **Method:** The study was carried out through a simulation of B&H, AT, and AG investment strategies on the equity index. The investment return maximization process for financial assets was developed by means of genetic algorithms, which were based on equations defined in chromosome classification with gene-immersive operations. It began with a random population of individuals with chromosomes representing a solution to achieve the greatest return possible.

Results: The application of algorithms with the RSI generated returns that were 9% and 16% higher than with B&H and technical analysis means a greater investment risk for B&H with a volatility of 17.6%, but comparable to those shown by genetic algorithms and technical analysis. **Conclusions:** An improved risk-return ratio and efficiency in the key parameters of the Portfolio Theory is possible through investment strategies based on genetic algorithms including the RSI oscillator. This study suggests that an improvement of the return on investment may be expected through the stop loss and take profit parameters and a range of motion of the asset price prior to taking position.

Keywords: Investment strategies; Stock markets; Automatic trading, Quantitative trading.

JEL Classification: C63, C67, G11, G17, F17, E44.

Autor de Correspondencia

aagudelo@unal.edu.co

Recibido: 23-03-2022
Aceptado: 24-06-2022
Publicado: 31-07-2022



Copyright © 2022
Desarrollo Gerencial

Como citar este artículo (Apa):

Agudelo Aguirre, A.A., Rojas Medina, R. A., & Duque Méndez, N.D. (2022). Trading a través del indicador RSI con la aplicación de algoritmos genéticos para la implementación en el sector empresarial de las inversiones. *Desarrollo Gerencial*, 14(2), 1-24. <https://doi.org/10.17081/dege.14.2.5755>

Introducción

La maximización del rendimiento en el mercado de valores ha sido de gran interés universal para sus participantes desde sus inicios. En las últimas décadas el enfoque para alcanzar mayores rendimientos se ha dirigido hacia la implementación de estrategias y herramientas de predicción del comportamiento del precio del activo financiero. Dentro de la complejidad intrínseca de los mercados financieros, es de gran interés la anticipación de los movimientos (tendencias) y con base a ello tomar decisiones y acciones en concordancia. Sin embargo, con volúmenes de información financiera cada vez mayores y más complejos el análisis financiero por parte del sector de inversión resulta intrincado y expuesto a alta incertidumbre operativa. Esto hace que nuevas herramientas computacionales sean de gran utilidad para aliviar la complejidad y eliminar la incertidumbre en el operar del sector empresarial de las inversiones.

La predicción a futuro (mediano o largo plazo) del valor de activos puede realizarse a través de análisis fundamental en el que se combinan factores de influencia económicos, del sector industrial específico al activo, y de la compañía en particular. Este análisis busca encontrar el valor justo del activo (precio potencial en el mercado del activo) o valor intrínseco que puede entonces ser comparado con el precio actual del activo. Esta comparación resulta útil para determinar si el activo está sobre o subvalorado como premisa resultante de aplicar análisis fundamental (Suresh, 2013). Si se establece que el precio actual del activo eventualmente se aproximaría a su valor justo, es entonces cuando el valor justo se torna referente en el proceso de decisión para la compra o no del activo (Suresh, 2013). Es decir, el inversionista optaría por comprar el activo cuando el precio en el mercado de este se situase por debajo de su valor intrínseco.

Con los precios de activos en constante fluctuación como resultado de la compra y venta continua de estos en el mercado, el análisis de los movimientos del precio de activos también puede llevarse a cabo encontrando la dirección de estos a futuro con base en sus precios en el pasado. Esta estrategia de análisis es denominado análisis técnico, cuya fundamentación se centra en la relación entre el desempeño histórico de un activo o mercado y su desempeño futuro. El objetivo inicial de un analista técnico es descifrar el cambio en la dirección de una tendencia en el precio de un activo y es la base en la identificación de patrones que puedan sugerir futuras actividades en el precio del activo. La tendencia o la dirección del movimiento en el precio es examinada con el análisis de información concerniente al volumen y precio histórico del activo en periodos determinados (diario, semanal, mensual).

Una gran variedad de herramientas llamadas indicadores técnicos son usados en la arena financiera de los mercados para el análisis tendencias y maximización de rentabilidad de inversiones en activos a través del análisis técnico. Indicadores de tipo oscilador (con movimientos a través de un punto de referencia) como el MACD (*Moving Average Convergence Divergence*) y el RSI (*Relative Strength Index*) que miden el

momentum del mercado son de especial interés por su uso común por parte de los inversionistas (Agudelo et al., 2020; Mohd-Nor y Wickremasinghe, 2014). Los indicadores técnicos tienen la habilidad de medir los cambios en un mercado específico, analizando información más allá de volumen y precio de los activos. El lector es referido a Swain (2012) e Isidore y Christie (2018) en los que se hace una revisión completa de los componentes prácticos y conceptuales más relevantes en el uso de indicadores técnicos en el mercado de valores.

El desarrollo tecnológico en recursos computacionales ha fomentado el desarrollo acelerado de nuevos métodos automáticos de *trading*, conocido comúnmente como *trading algorítmico* (Radeerom, 2014). Los Algoritmos Genéticos (AG), dentro de la rama de computación evolutiva, son la herramienta con más alta flexibilidad y capacidad de búsqueda de soluciones a problemas de tendencias y maximización de rentabilidad dentro del análisis técnico en mercados financieros (Radeerom, 2014). Además, su incorporación en reglas de *trading* ha mostrado ser eficiente en la captura de la dinámica de mercados como el de valores (Allen y Karjalainen, 1999; Fernández-Rodríguez et al., 2001; Radeerom, 2014). A continuación se documentan algunos de los estudios más relevantes en la incorporación de computación evolutiva aplicada dentro de estrategias de análisis técnico en diferentes mercados financieros.

Los Algoritmos Genéticos (AG) son un grupo de métodos computacionales de búsqueda que crean poblaciones de posibles soluciones entre cuyas características principales están las de evolucionar para optimizar una función objetivo. Esta técnica de optimización, desarrollada por Holland (1975), está basada en los principios biológicos de genética y selección natural. Los GA son frecuentemente empleados en la búsqueda de soluciones óptimas o soluciones bastante cercanas a la óptima en una fracción reducida de tiempo comparada con el tiempo que tardaría la ejecución de otro método alternativo rutinario. La población de posibles soluciones (también conocido como grupo de cromosomas) a un problema de optimización dado de una generación actual de soluciones es entonces sometida computacionalmente a procesos de recombinación y mutación comparables a los procesos de evolución natural en genética (Forrest, 1996).

Estos procesos son repetidos por varias generaciones de soluciones creadas. A cada una de las soluciones candidato se le es asignado un valor "*fitness*" con base en el valor de su función objetivo, y a las soluciones más "*fit*" o aptas se le dan mayores oportunidades de generar nuevas soluciones aún más aptas. El proceso de obtener soluciones cada vez más cercanas a las óptimas se basa en el proceso de evolución y supervivencia del más apto según la teoría Darwiniana (Forrest, 1993).

En tal sentido, los AG presentan grandes ventajas con respecto a métodos tradicionales de optimización, entre las más destacadas se encuentran la rapidez de ejecución, la habilidad de optimización para funciones tanto continuas, discretas y problemas con múltiples funciones objetivo, su poder de proveer con múltiples soluciones óptimas o bastante cercanas a las óptimas, y su habilidad para proveer siempre con una solución que mejora a través del tiempo.

Estos AG han encontrado una gran aplicación en diversos campos de las finanzas y el mundo empresarial y financiero de inversión. El uso de análisis técnico inmerso en AG ha sido un subcampo de las finanzas con gran potencial de desarrollo por sus beneficios en el procesamiento eficaz de grandes volúmenes de información histórica financiera con simples o múltiples funciones objetivo para su optimización, entre ellas el rendimiento.

La adopción de la sistematización de inversión en mercados financieros mediante AG y análisis técnico por parte de grupos empresariales de inversión resulta beneficiosa en múltiples aspectos, como la optimización del tiempo que el recurso humano tradicionalmente toma en su logística no automática de seguimiento de inversión. Esto a su vez, aumenta la certidumbre y facilita la toma de decisiones financieras al reducir sustancialmente la extensión en el análisis manual y al eliminar la subjetividad por parte del analista. Además, la implementación de sistemas automáticos de trading en el sector empresarial financiero es hasta la fecha primitivo en Latinoamérica y especialmente en el sector empresarial colombiano. Esto abre la oportunidad para que los potenciales beneficios económicos y logísticos locales sean explotados más acorde al mercado internacional actual.

Algunas aplicaciones exitosas en las que AG ha encontrado aplicabilidad en el análisis técnico han sido la generación de señales de compra/venta del NSE (*National Stock Exchange*) de India (Vora, 2011), mediante la identificación de patrones de *trading* en los movimientos del mercado con indicadores tales como Medias Móviles (*simple y exponencial*), MACD, bandas de *Bollinger* y RSI, entre otros. La negociación de divisas (USD/YEN y USD/EURO) ha sido también posible mediante indicadores técnico bajo AG con rendimientos superiores al 64% (Shangkun et al., 2012). El mercado de divisas también ha sido objeto de implementación exitosa y rentable con AG dentro de análisis técnico, en el mercado de *Forex* con pares de divisas EUR/USD con el indicador Índice de Fuerza Relativa (RSI) (Boboc y Dinică, 2013) y GBP/USD, EUR/GBP y EUR/USD (Evans et al., 2013; Papailias y Thomakos, 2015).

Con base en los antecedentes expuestos, este estudio propone una metodología de implementación de una estrategia técnica utilizando el oscilador RSI asistida por AG aplicada a una inversión en renta variable, tema que no ha sido explorado en la literatura y que podría servir para el avance de este como de otros tipos de inversión a futuro en la región. El presente estudio surge como alternativa para la introducción de sistemas automáticos de inversión (algoritmos genéticos dentro de análisis técnico) en el sector empresarial de las inversiones en Latinoamérica que brinde oportunidades de optimización de recursos en el proceso de toma de decisiones financieras. Además, su potencial implementación puede favorecer la asignación de recursos más eficientemente dentro del proceso global de inversiones, con los potenciales beneficios logísticos y económicos derivados.

El estudio busca responder las siguientes hipótesis propuestas:

- 1) ¿Es posible extraer señales (de compra y/o venta) a partir de datos históricos de activos de renta variable que puedan conducir a lograr un exceso de rentabilidad (comparada con una estrategia B&H)? Rendimientos superiores al encontrado por una metodología tradicional B&H son esperados mediante la optimización de parámetros técnicos inmersos en AG, esto sugeriría una superior captura de las fluctuaciones de precio del activo por parte de los indicadores operando a valores óptimos (o cercanos a óptimos).
- 2) ¿Es el análisis técnico tradicional suficiente para proporcionar parámetros óptimos que maximicen la rentabilidad y generen exceso en una inversión de renta variable? Se prevé que los resultados de rentabilidad de la estrategia B&H (tradicional) sean superados por la estrategia genética, pues los AG han demostrado su poder de refinamiento en la captura de señales (compra/venta) "productivas" de acuerdo con el comportamiento específico de cada mercado.

El objetivo propuesto fue encontrar los valores de los parámetros técnicos del indicador mediante AG que maximicen la rentabilidad y determinar si el proceso de maximización supera en utilidades a las encontradas para la estrategia siguiendo los métodos tradiciones de análisis técnico y B&H. Lo anterior aportaría a responder las hipótesis planteadas en este estudio.

Fundamentación teórica

El mercado de valores es considerado un elemento central de la economía de un país (Levine, 1997), contribuyendo a mejorar, entre otros aspectos, la liquidez de los diferentes instrumentos financieros que se negocian (Khan et al., 2016). Un mercado en el que ningún inversionista esté en la posición de alcanzar grandes e inusuales rentabilidades es comúnmente llamado *mercado eficiente*, premisa tradicional que es respaldada por la teoría de Eficiencia del Mercado (Fama, 1970). Sin embargo, en la práctica los mercados de valores en general son altamente aleatorios y no parecen exhibir esta propiedad, lo que ha abierto la oportunidad para que se estudien diferentes técnicas que los inversionistas puedan aplicar para alcanzar mayores rentabilidades a las que se esperaría dentro de la teoría tradicional (Khan et al., 2016).

Los índices bursátiles (NASDAQ, S&P 500, Dow Jones, etc.) son valores numéricos de referencia, que se calculan (generalmente la media aritmética) según los precios de cotización de mercado (en una bolsa de valores) de cada uno de los valores que componen ese índice en un momento determinado. Los índices bursátiles desempeñan papeles importantes en el ámbito financiero al proporcionar información de las tendencias en el mercado que representan estos valores. Los índices también permiten un seguimiento del comportamiento del valor de las acciones (activos) en un mercado y representan un referente de medición

de la asertividad de estrategias de inversión (Sevilla-Arias, 2012). El índice S&P 500 es uno de los más representativos índices de la economía de Estados Unidos, representando 10 sectores económicos, entre ellos sectores fundamentales de la economía como el de salud, tecnológico y financiero.

Por lo tanto, un análisis global del índice S&P 500 permitiría determinar que parte del mercado es en realidad más fuerte o mejor conectado, y facilitaría la visualización de tendencias a la baja o al alza que puedan conducir a crisis financieras o recesiones (Abrams et al., 2017). El índice S&P 500 (así como también el índice IBEX 35 de España) es construido mediante el método de capitalización ponderada, tomando como base la capitalización bursátil de cada uno de los valores que forman el índice. Este método de cálculo deriva en que índices como S&P 500 representen más fielmente la realidad de lo que se quiera determinar ya se elimina el gran peso que tienen las acciones con precios más elevados sobre el valor del índice.

La importancia de los índices del mercado accionario como S&P 500 alcanza a impactar mercados emergentes como el de Colombia, que forma parte del grupo CIVETS (Colombia, Indonesia, Vietnam, Egipto, Turquía y Sudáfrica) y el cual está conformado por economías que se encuentran en vías de desarrollo y con crecimiento acelerado. Estos países están inmersos en la economía en escala en la que pueden colocar sus acciones en mercado de capital y con una medición financiera en índices del mercado accionario. Análisis más detallados de la importancia e impactos del sistema financiero y los índices bursátiles en la economía colombiana están referenciados por Cortés-Villafradez y Hernández-Luna (2014); Figueroa-Pelayo y Gualdron-López (2014), y Restrepo-Gaviria (2015).

En general, existen dos alternativas de abordar la inversión de activos financieros, conocidas como análisis fundamental (comúnmente llamado *Buy & Hold o B&H*) y el análisis técnico (Moosa y Li, 2011; Petrusheva y Jordanoski, 2016; Isidore y Christie, 2018). El primero busca rentabilidad en inversiones con base en la tenencia de éstas a mediano y largo plazo mediante la estructuración de carteras plurales de inversión (varios activos) con diversos perfiles de riesgo. Alternativamente, el análisis fundamental busca rentabilidad mediante la inversión en índices del mercado accionario (Cohen y Cabiri, 2015). El lector es referido a Nti et al. (2020) para ampliar el conocimiento en el uso y aspectos característicos del análisis fundamental.

Por otro lado, el análisis técnico se apoya en los datos históricos del activo financiero con el objeto de extraer señales que puedan ser usadas por el analista como ayuda en el proceso de toma de decisión. La base del análisis técnico está centrada en la presunción de que el propio mercado es el generador de la mejor información de su evolución a futuro. A su vez, toda la información propia relevante respecto a sus beneficios y expectativas para una compañía específica está ya contenida en el precio del título de dicha compañía o activo (Murphy, 1998; Farias et al., 2017).

Con este criterio es entonces posible inferir la relevancia que presenta el análisis técnico para alcanzar, a través de este, mayor rentabilidad frente a una estrategia de inversión B&H tradicional. Lo anterior podría ser alcanzado debido al hecho de que la rentabilidad de inversión en un análisis técnico está sujeta a la frecuencia de negociación. Esto conlleva que a mediano y largo plazos las ganancias alcanzadas a través de B&H podrían ser eventualmente superadas por una serie de ganancias menores mediante un análisis técnico (Petrusheva y Jordanoski, 2016).

La aplicación del análisis técnico tradicional es ampliamente documentada dentro de sus dos ramas de estudio. Para ello, se emplea el análisis gráfico (comúnmente llamado "*chartismo*") o estudio de la evolución del mercado a partir de la representación de este. Otras herramientas son el análisis cuantitativo mediante el uso de matemáticas y estadística a través del uso de indicadores técnicos y osciladores (Rosillo et al., 2013) y el empleo de sistemas automáticos de trading. Este último, constituido por un conjunto de reglas (reglas de *trading*) que se emplean para la generación automática de señales ya sea de compra o venta (Radeerom, 2014; AFI, 2017).

Una de las mayores desventajas del análisis de *chartismo* es la alta posibilidad de discrepancia en el análisis entre analistas dependiendo de su experiencia individual y perspectivas del análisis (Cheng et al., 2010; Zapanis y Tsinaslanidis, 2012). Por su parte, el análisis mediante el uso de indicadores y osciladores incluye reglas definidas matemáticamente, denominadas comúnmente *trading rules*, lo que conlleva a criterios más específicos de análisis impidiendo cualquier sesgo de interpretación (Luukka et al., 2016).

En el presente estudio se examina el desempeño del oscilador Índice de Fuerza Relativa (*RSI por sus siglas en inglés para Relative Strength Index*) mediante transacciones ejecutadas con base en sus líneas de señales. El indicador RSI mide las magnitudes de las ganancias y pérdidas recientes y con base en ello determina si los activos están sobrevendidos o sobrecomprados (Wilder, 1978). En otras palabras, este indicador muestra la fuerza del precio mediante la comparación de los movimientos individuales al alza o a la baja de los sucesivos precios de cierre.

El cálculo del RSI se realiza a partir del parámetro RS obtenido de la relación del promedio (aritmético) de las variaciones positivas y negativas del precio registradas en un número (determinado) de periodos. Las señales que se generan (compra/venta) para las posiciones a tomar con el activo financiero en el mercado corresponden a los movimientos del oscilador RSI por encima y por debajo de los límites inferior y superior. Estos valores límite que conforman las reglas de trading corresponden respectivamente a 30 y 70 (Cohen y Cabiri, 2015; Chou y Lin, 2019).

Las reglas de *trading* son operadores que generan señales de entrada y señales de salida. Estas generalmente conforman un conjunto de condiciones (que deben cumplirse) para determinar el momento justo de compra o venta de un activo financiero (Taylor, 2014). Estas reglas se estructuran a partir de la definición de elementos específicos que permiten encontrar patrones de comportamiento dentro de un conjunto de datos, en muchos casos de difícil reconocimiento por el analista (Rodrigues Leles et al., 2017).

La utilización de varias reglas de *trading* de forma simultánea en una serie histórica de datos implica el análisis de gran volumen de éstos (tanto de precios de activos como de los indicadores asociados), lo que incrementa la dificultad y los requerimientos si solo se utilizan técnicas y herramientas tradicionales (Straßburg et al., 2012). Por último, al involucrar un sistema automático de *trading* se favorece el procesamiento de un volumen alto de datos en el análisis. Para ello, herramientas como los algoritmos computacionales y algoritmos genéticos, así como las redes neuronales entre otros, son recursos útiles que pueden ser implementados en el análisis técnico para acelerar el proceso de análisis dentro de un sistema automático (Rosillo et al., 2014).

Los Algoritmos Genéticos (AG), desarrollados por Holland (1982), son un tipo de secuencias computacionales que buscan encontrar soluciones a problemas que no pueden ser resueltos por métodos determinísticos o analíticos (Straßburg et al., 2012). Los AG son una combinación de búsqueda adaptativa y técnica de optimización, capaces de analizar funciones de pérdida o de ganancia, asociadas con parámetros predictivos y cuya principal habilidad es la adaptación a ambientes cambiantes (por ejemplo, el caso de nuevas tendencias en precios de activos) simulando el proceso de evolución natural (Cheng et al., 2010). La principal ventaja que presentan los AG es su habilidad de no requerir información adicional de continuidad y diferenciabilidad, entre otros, de la función objetivo (Wang et al., 2020).

Asimismo, los Algoritmos Genéticos típicamente consisten en cromosomas, los cuales representan las soluciones posibles del problema (de optimización), un arreglo de selección, un operador de cruce (*crossover*), así como también un operador de mutación y la función objetivo (Wang et al., 2020). Los cromosomas generalmente están representados por lazos en forma binaria compuestos por códigos de 0 y 1. Esta codificación binaria tiene como objetivo delinear el espacio continuo de búsqueda dentro de un espacio discreto conteniendo mallas a diferentes distancias entre sí. Las distancias entre mallas adyacentes dependen de la longitud del enlace binario que representa el respectivo cromosoma.

Por su parte, el operador de cruce tiene la propiedad de usar la información de cada individuo en la población actual para dirigir su búsqueda a regiones más potencial en el espacio de búsqueda (Wang et al., 2020). Los AG operan aplicando el concepto de supervivencia de la estrategia del individuo más apto sobre las estructuras de lazos a través de intercambio de información. Esta información es ordenada

aleatoriamente por el AG para formar en una forma consistente los optimizadores de la población global de individuos (Wang et al., 2020).

Los AG han mostrado tener alto potencial en la optimización de reglas de *trading*. Esto por consiguiente es promisorio en el desarrollo de estrategias de inversión de activos financieros en la búsqueda de superar rentabilidades obtenidas de manera corriente o tradicional (Shangkun et al., 2012). Una revisión comprehensiva del uso de AG en un amplio espectro de mercados financieros es dada por Drake y Marks (2002), García et al. (2013) y Henrique et al. (2019).

Método

Diseño

El estudio se desarrolló mediante simulación de las estrategias de inversión B&H, AT y AG sobre el índice accionario. El oscilador RSI fue empleado para el desarrollo de las estrategias AT y AG. En el caso de la estrategia AG, la combinación de las ecuaciones (7) descritas en la definición de los cromosomas (como se muestra en la Tabla 1), cada una de ellas operando la instrucción inmersa en cada uno de los genes fueron aplicadas en el procedimiento. La función objetivo para el desarrollo de la estrategia mediante AG fue definida en términos del mayor rendimiento posible. Una adquisición de 1.000 acciones iniciales fue asumida con reinversión (total incluidos los excedentes) de los recursos generados en cada una de las ejecuciones de venta. Los rendimientos alcanzados en cada una de las estrategias fueron calculados al momento de ejecutar la última venta, procediendo con la liquidación de la inversión.

Algoritmos Genéticos (AG)

El proceso de estructuración del algoritmo genético se inició a partir de una población aleatoria de individuos compuestos por cromosomas (combinaciones binarias compuestas por un número plural de genes), cada uno de los cuales representó una solución posible al problema planteado de lograr el mayor rendimiento posible. Posteriormente, se aplicó el operador de cruce sobre la población generada y el cruzamiento (de individuos) generaron nuevos individuos (representando nuevas posibles soluciones) a través de un proceso iterativo. Variaciones introducidas a los cromosomas de los individuos (mutaciones) fueron aplicadas a la población que dieron como resultados individuos con características mejoradas con respecto a sus antecesores. Un total de 10.000 iteraciones fue garantizado para obtener una población y realizar el proceso de selección de acuerdo con Burduk et al. (2019). Un número constante de individuos con características mejoradas fue mantenido durante el proceso iterativo mediante la eliminación de igual número de individuos con características deficientes, de acuerdo con Llorente-López (2012).

De acuerdo con lo anterior, una regla de *trading* aplicada para encontrar patrones se considera válida, si sus resultados son similares, tanto en el periodo de aprendizaje, como en el periodo de validación, lo que

daría como resultado la superación del análisis utilizando datos históricos y en consecuencia su disposición para ser aplicada con fines predictivos.

Oscilador RSI

El RSI fue calculado mediante la expresión (1) a partir del parámetro RS obtenido de la relación del promedio (aritmético) de las variaciones positivas y negativas del precio registradas en un número (determinado) de periodos. Los valores de RSI fueron obtenidos en el rango 0-100 y un gráfico de líneas fue trazado con estos. Los límites inferior y superior correspondientes a los valores de 30 y 70 fueron incorporados al gráfico (Cohen y Cabiri, 2015; Chou y Lin, 2019). Una aproximación en reversión a la tendencia para valores por encima de 30 y por debajo de 70 fue realizada de acuerdo con Tharavanij *et al.* (2015). Las reglas de trading consideradas a partir del criterio anterior para el oscilador RSI fueron: acción para la compra solo si $RSI < 30$ y acción para la venta solo si $RSI > 70$.

$$RSI = 100 - \frac{100}{1 + RS} \quad (1)$$

Cromosomas

Para el desarrollo de este estudio, cada cromosoma se constituyó de 22 *bits* agrupados en 6 genes, con el objeto de aportar una característica singular a cada individuo en la regla de *trading*. La Tabla 1 muestra las ecuaciones que definen las reglas de trading (2-8) y sus propiedades, así como la estructura cromosómica general resultante en el análisis.

Desarrollo del algoritmo genético

El proceso de maximización del rendimiento de inversión para los activos financieros de estudio se realizó mediante Algoritmos Genéticos de acuerdo con Chen *et al.* (2011) y Ding *et al.* (2020).

La secuencia del procedimiento fue la siguiente:

1. Una población de individuos con el número de *bits* representando cada parámetro definido en las reglas de *trading* fue generado aleatoriamente en la fase de entrenamiento, y a partir de esta población el rendimiento es calculado y ordenado de manera descendiente con base en el rendimiento de la inversión definido como función fitness.
2. Selección de una población constituida por el 10% de individuos con el mejor desempeño (rendimiento) es llevada a cabo con el objeto de conformar la próxima generación de individuos.
3. Cruce y mutación genética es llevada a cabo con el 90% de individuos restante de la fase inicial.

- El proceso de cruce se realizó entre cada individuo (k) y su individuo próximo (k+1) en dos puntos de corte. El primer punto correspondió a un número aleatorio entre 0 y 11 y el segundo a un número aleatorio entre 12 y 22. Estos puntos de corte representaron las correspondientes primera y segunda mitad de los individuos. La Figura 1 muestra esquemáticamente el proceso de cruce para el caso particular de cruzamiento en los puntos 5 y 16.

Figura 1. *Esquema de cruzamiento genético (ejemplo de cruce en puntos 5 y 16)*

Individuos (K y K+1) antes de cruzamiento																				
K	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
K+1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Individuos (K y K+1) después de cruzamiento																				
K	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0
K+1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1

Fuente: elaboración propia.

- Mutación de cada individuo fue llevada a cabo justo después de haber realizado el cruce de la población total. En el caso particular que un individuo K sobrepasase la probabilidad de mutación, uno de los bits del individuo seleccionado al azar fue cambiado su valor de 0 a 1, o en caso contrario de 1 a 0.
- El rendimiento de la nueva población generada es calculado y ordenado en forma descendente. En este ordenamiento los individuos seleccionados en el 10% de la generación anterior fueron también incluidos.
- Un proceso iterativo desde el paso 2 fue ejecutado hasta alcanzar 1000 generaciones, número de generaciones definido en este estudio. Este proceso permitió la selección del mejor individuo en términos de maximización del rendimiento.

Reglas de trading aplicados al indicador RSI tradicional

Las reglas de trading que se emplearon en el desarrollo de las estrategias de inversión con RSI tradicional están especificadas en la Tabla 2, de acuerdo con Murphy (1998) y Murphy (2016).

Tabla 1. Definición y propiedades de genes aplicadas a MACD y la estructura cromosómica general

Características genéticas, función genética específica, cálculo de cada gen y su rango de operación					
Gen	Bits	Función	Expresión de cálculo	Rango ¹	Ec.
A	5	Determinar el número de periodos considerados en RSI	Gen A = Número de periodos – 1	1 – 32	(2)
B	5	Determinar nivel de activación de límites inferior y superior de RSI	Nivel activacion = $\text{int}((5 + \text{Gen B}) * 1.25)$ activacion venta = 100 – Nivel de activacion activacion compra = Nivel de activacion – 0	6 – 45 55 – 94	(3) (4)
C	4	Establecer un límite de precio superior al de venta al que se está dispuesto a vender	Gen C = Take _{profit}	0 – 15 ²	(5)
D	2	Determinar el máximo nivel de pérdida a asumir por el inversionista ante eventual caída del precio, después de recepción de la señal de venta	Gen D = Stop _{Loss}	0 – 3 ²	(6)
E	4	Permitir la caída de precio hasta el nivel definido en el gen E aplicado a señales de compra después de recibida una señal	Gen E = Take _{profit}	0 – 15 ²	(7)
F	2	Determinar el nivel de subida de precio máximo dispuesto a asumir después de recibida la señal de compra.	Gen F = Stop _{Loss}	1 – 3	(8)
Estructura cromosómica general:					
<p>El diagrama muestra una fila de bits: 1 1 1 1 1 0 0 0 0 0 1 1 1 1 0 0 1 1 1 1 0 0. Encima de los bits se agrupan los genes: Gen A (bits 1-5), Gen B (bits 6-10), Gen C (bits 11-15), Gen D (bits 16-17), Gen E (bits 18-21) y Gen F (bits 22-23).</p>					

Nota: ¹rango del resultado. ²expresado en %. Fuente: Elaboración propia.

Tabla 2. Reglas de trading aplicados al oscilador RSI tradicional

Parámetros del RSI y sus valores habituales	
Parámetros	Valor tradicional
Número de datos de confirmación	14
Nivel de activación inferior	30
Nivel de activación superior	70

Fuente: Elaboración propia.

Cálculo del rendimiento

El cálculo del rendimiento total durante el plazo de la inversión se realizó empleando las siguientes expresiones presenta a continuación:

$$\text{Rendimiento Total} = \frac{\text{Valor final} - \text{Valor inicial}}{\text{Valor inicial}} \times 100 \quad (9)$$

La tasa efectiva anual es calculada con la expresión 10 correspondiente a un periodo de tiempo específico, así:

$$\text{Interés efectivo anual} = i_e = (1 + i_p)^{365/n} \quad (10)$$

Donde:

i_p = Tasa de interés periódica

n = Periodo de tiempo en días

$$\text{Rendimiento Total} = \frac{3.284.761 - 2.581.880}{2.581.880} \times 100$$

Participantes

Este estudio se realizó con datos históricos del precio de cierre del índice accionario S&P500, representado como activo financiero. La frecuencia de medición fue diaria para el periodo 17 de febrero de 2015–5 de agosto de 2019. La totalidad de los datos de precio fueron divididos en dos subgrupos para desarrollar las etapas de entrenamiento (65% de los datos) y validación (35% restante).

Instrumentos

Los datos de estudio fueron extraídos de la plataforma *Refinitiv®*.

Resultados

Los valores de los parámetros requeridos inicialmente para definir el indicador RSI de acuerdo con las reglas específicas de trading de este estudio fueron obtenidos del individuo con mayor ajuste (Tabla 3) con base en los parámetros que conformaron el cromosoma.

Tabla 3. Reglas de trading definidas en los valores de los parámetros hallados

Valores aplicados a los parámetros de las reglas de trading		
Regla	Parámetro	Valor
1	Número periodos de conformación RSI	16
2	Nivel de activación inferior	35
3	Nivel de activación superior	65
4	Take profit venta (%)	4
5	Stop loss venta (%)	3
6	Take profit compra (%)	4
7	Stop loss compra (%)	3

Fuente: Elaboración propia.

A partir de la aplicación de los parámetros de construcción de RSI se generaron 4 transacciones (2 de compra y 2 de venta) con los detalles de transacción dados en Tabla 4. Una adquisición inicial de 1000 acciones con precio de mercado equivalente al valor especificado al recibir la primera señal de compra del oscilador fue asumida para el desarrollo de este estudio. Esta cantidad fue sostenida hasta la siguiente señal de venta y posteriormente ajustada cada vez que se realizó una nueva compra (la totalidad del dinero disponible de la venta inmediatamente anterior se asumió ser invertida (de nuevo) en el activo al precio del mercado al momento de tomar la decisión de compra. Las transacciones permitieron alcanzar la última venta con un capital acumulado de USD 3.284.761 (valor de inversión inicial USD 2.581.880).

Tabla 4. *Detalles de las transacciones (compra - venta) del activo*


Información de las transacciones del activo				
Transacción	Tipo	Fecha	Precio unitario (USD)	Valor total (USD)
1	compra	2018-04-02	2.581,88	2.581.880
	venta	2018-05-25	2.846,07	2.846.070
2	compra	2018-06-28	2.716,31	2.843.977
	venta	2018-09-20	2.930,75	3.068.495
3	compra	2018-10-10	2.785,68	3.067.034
	venta	2019-02-04	2.724,87	3.000.082
4	compra	2019-05-13	2.811,87	2.997.453
	venta	2019-07-29	3.081,39	3.284.761

Nota: Precio unitario indica el precio de negociación del activo al momento de concretarse la transacción después de recibida la señal de compra o de venta. El valor de la transacción corresponde al precio del activo en el mercado por el número de unidades a adquirir o a vender en cada una de las fechas correspondientes. Fuente: Elaboración propia.

El rendimiento total correspondió a 27,22% en un rango de 483 días (obtenido empleando la expresión (9), equivalente a una tasa efectiva anual de 19,96% (aplicando la expresión (10)).

El comportamiento del valor acumulado de la inversión durante el periodo de análisis para las metodologías RSI con aplicación de AG, el análisis técnico tradicional del RSI (AT) y la estrategia B&H fue graficado como se muestra en la Figura 2.

Figura 2. Valor acumulado de inversión de las estrategias de análisis técnico - B&H – AG



Fuente: Elaboración propia.

El seguimiento a la inversión fue realizado simultáneamente para las tres estrategias durante el mismo periodo de tiempo, con el propósito de visualizar no solo el resultado final, sino también el comportamiento a lo largo del periodo. Los resultados de la aplicación de las tres estrategias de inversión en términos del valor acumulado mostraron cierto grado de uniformidad durante periodos específicos dentro del tiempo total de estudio (02-04-2018 y 05-08-2019). Las estrategias mostraron concurrir uniformemente durante los 50 días iniciales desde realizada la compra inicial de 1.000 acciones (Figura 2). A partir de este periodo y durante cerca de 30 días (06-2018) las estrategias con fundamentos técnicos (AT y AG) mostraron un comportamiento “estable” comparable entre sí (indicando un valor de inversión constante) mientras la estrategia B&H superó el valor acumulado en cerca del 2% a mediados del mismo periodo (Figura 2).

Si bien las metodologías de inversión B&H y AG indicaron señales en tendencias comparables hasta un poco posterior al 17-09-2018 (\cong 90 días), estas señales lograron superar la metodología técnica tradicional entre el 20-08-2018 y alrededor de 01-10-2018 (\cong 50 días) y lograron superar transitoriamente en cerca de USD 0.1 millones de la inversión mediante AT (alrededor de 01-10-2018).

Los resultados también mostraron una correspondencia en el comportamiento del rendimiento de la inversión entre las metodologías en el periodo 15-10-2018 y 07-01-2019 (Figura 2), siendo numéricamente

más ajustada entre los esquemas B&H y AT que fueron superados por la metodología de AG. A partir de esta posición en el tiempo, el rendimiento de inversión en el periodo de análisis comprendido entre el 07-01-2019 y el momento de cierre presentó cierta divergencia entre las metodologías, siendo B&H y AG aquellas con mayores resultados en el valor de inversión, aunque en términos generales la tendencia en el valor de inversión fue congruente entre estrategias. Imprevistamente, los resultados al momento de cierre (señal de cierre) mostraron superioridad para la metodología de AG en cerca de 8,1% y 16,2% comparados a los valores respectivos registrados mediante las metodologías B&H y AT.

Los parámetros adicionales importantes de medida para el estudio de inversión como el riesgo y Sharpe ratio (Sharpe, 1964) fueron también cuantificados junto con el rendimiento anualizado para las metodologías del estudio (Tabla 5).

Tabla 5. *Rendimiento, riesgo y Sharpe ratio de las estrategias de inversión*

Comparativo entre resultados de las estrategias estudiadas			
Estrategia	AT tradicional	B&H	AG
Rendimiento anual (%)	2,99	10,18	19,96
Riesgo anual (%)	14,88	17,57	15,44
Ratio Sharpe	0,0946	0,4894	1,1901

Nota: AT: análisis técnico. B&H: buy & hold. AG: algoritmos genéticos. Fuente: Elaboración propia.

El rendimiento (anual) por estrategia fue obtenido y comparado entre metodologías de inversión. La metodología AG mostró un rendimiento superior en un factor cercano al 2 y 6,7 frente a las estrategias B&H y AT, respectivamente. Por su parte, los resultados para la metodología B&H mostraron un rendimiento muy cercano al promedio obtenido por tres estrategias de inversión. En términos de riesgo de inversión (anual), los resultados también mostraron diferencias, aunque las desigualdades numéricas entre sí fueron menores con respecto al rendimiento. La estrategia con mayor riesgo correspondió al B&H, seguidas de AG y AT tradicional cuyos riesgos anuales no superaron una diferencia mayor al 1% entre sí.

El riesgo de la inversión, calculado por medio de la desviación estándar de los rendimientos, ubica la estrategia B&H como aquella más riesgosa con una volatilidad cerca de 17,6%, pero relativamente cerca de las volatilidades exhibidas por las estrategias, AG y AT, de 15,4% y 14,9%, respectivamente. Los resultados obtenidos en términos de rendimiento y riesgo no proporcionan una relación de causalidad entre cada uno de ellos, en el sentido que no se puede extraer de los resultados una relación directa que permita determinar que el mayor rendimiento generado por la inversión corresponde a la prima por el mayor riesgo asumido. Este aspecto por lo tanto sugiere que un examen del Sharpe ratio como indicador que mide la eficiencia entre estas dos variables es de gran utilidad. El Shape ratio, como medida de análisis del rendimiento de inversión que consideró el riesgo que involucra dicha inversión, mostró diferencias considerables entre los tipos de metodologías aplicadas. La metodología basada en algoritmos genéticos

mostró mayor eficiencia en términos de rentabilidad considerando el riesgo añadido (frente a la inversión libre de riesgo), con una Sharpe ratio en un factor de 12 superior al obtenido mediante la estrategia AT y superior en un factor de 2 con respecto a B&H (Tabla 5).

Discusiones

El desarrollo del estudio aplicando AG a la estrategia de inversión de análisis técnico bajo el indicador RSI mostró consistencia entre los resultados obtenidos en la etapa de entrenamiento y la etapa de validación, lo que se ve reflejado en que el mejor individuo seleccionado por el algoritmo en el periodo de entrenamiento generó un rendimiento superior en la etapa de validación con respecto a las estrategias AT y B&H. Esta consistencia en los resultados fue dada aun con las condiciones de mercado disímiles experimentadas durante las etapas de entrenamiento y validación. Durante la etapa de entrenamiento se presentó un crecimiento sostenido del precio del activo.

Durante la etapa de validación se presentó un periodo de crecimiento de la cotización del índice, y a su vez una caída fuerte en el precio (superior al 20%) en un periodo corto del tiempo, constituyéndose en un comportamiento atípico del índice. Al final del periodo analizado, la estrategia AG logró registrar un rendimiento cerca al 20% efectivo anual, casi el doble del rendimiento registrado mediante B&H (10,18%) y superando por un alto margen a la estrategia AT (2,99%). Este aspecto muestra que la potencial implementación de AG inmerso en análisis técnico de inversiones de renta variable presenta ventajas que aún no han sido aprovechadas en el sector empresarial de inversión.

Estos resultados contrastan con los obtenidos por [Shangkun et al. \(2012\)](#), así como los resultados obtenidos por [Boboc y Dinică \(2013\)](#) que mostraron divergencia de rendimientos entre los periodos de entrenamiento y validación y solo favorabilidad en la etapa de entrenamiento del algoritmo. [Shangkun et al. \(2012\)](#) atribuyeron sus resultados negativos a la alta discrepancia entre los movimientos de precio durante los periodos de validación y de entrenamiento, mientras que los casos positivos fueron sustentados en el hecho de que el precio del activo fue sostenido por ciertos lapsos de tiempo siguiendo una dinámica comparable durante ambos periodos.

Por su parte, en el estudio de [Boboc y Dinică \(2013\)](#) se concluyó que aquellos individuos con desempeño superior en la etapa de entrenamiento no lograron resultados similares de desempeño en la etapa de validación, a pesar de haberse llevado a cabo varios procesos de validación que fueron ejecutados para superar estos resultados adversos. De acuerdo con estos autores, la eficiencia del mercado en una forma débil ([Fama, 1970](#)) contribuyó a la observada incapacidad de la metodología empleada en la anticipación del comportamiento del precio del activo financiero en el mercado analizado. Sin embargo, en nuestro estudio se evidencia características de adaptación del algoritmo genético a las curso y evolución del precio

en el mercado y por ende proporciona robustez al análisis técnico, permitiendo que las tendencias de este sean mejor descritas en su trayectoria histórica y más dinámica en su curso con las reacciones del mercado.

Aunque el propósito de la inversión en renta variable a través del índice S&P 500 desarrollado en este estudio ha sido la obtención de los más altos rendimientos posibles, no se puede desconocer que la inversión en activos financieros se fundamenta en gran medida en la relación existente entre el rendimiento esperado y el riesgo que se asume con la inversión (Markowitz, 1952), razón por la cual toma importancia el resultado logrado en términos de rendimiento respecto al riesgo asumido, el cual se expresa a través del *Sharpe ratio*.

Así, como resultado del estudio este *Sharpe ratio* ha mostrado una diferencia favorable utilizando la estrategia de inversión bajo AG, respecto a la prima por el riesgo que se lograría con las estrategias AT y B&H (Tabla 3). La diferencia de valor del Sharpe ratio se debe a que el análisis técnico, bien sea bajo enfoque tradicional o por medio de algoritmos genéticos, presenta varios periodos en que se elimina la volatilidad del precio, porque durante los rangos de tiempo posteriores a una venta y mientras se recibe la siguiente señal para concretar una compra, se tiene la disponibilidad del dinero en efectivo. Por esto, el valor acumulado de la inversión durante estos periodos de tiempo se aísla de la variabilidad de la cotización del activo financiero en el mercado. Mientras que la inversión bajo la estrategia B&H, por la tenencia permanente del activo durante el rango total de tiempo analizado asume todas las variaciones del precio, haciéndola más volátil y en consecuencia más riesgosa y menos eficiente.

Estos resultados son consistentes con el estudio de Gold (2015), quien logró un riesgo notablemente más bajo y en consecuencia un Sharpe ratio más alto aplicando AG a través de análisis técnico con RSI, respecto a las demás estrategias utilizadas en el mercado. Así mismo, el estudio de Metghalchi et al. (2015) logró un mayor *Sharpe ratio* mediante diferentes indicadores de análisis técnico respecto a la estrategia B&H, a pesar de la alta volatilidad de los activos financieros considerados en el estudio.

La diferencia en los valores de los parámetros que conforman el oscilador RSI generados por el Algoritmo Genético (Reglas 1-3. Tabla 3), muy posiblemente contribuyeron a resultados superiores mediante esta estrategia. Esto, debido a que las señales generadas de compra y de venta se localizaron en puntos más favorables al propósito del analista desde la perspectiva del rendimiento de la inversión. A su vez, estos valores contrastan con los parámetros que indica el oscilador aplicado en su forma general y bajo métodos tradicionales (Tabla 1).

Según los valores de los parámetros de las dos estrategias comparadas en la Tabla 5, la estrategia bajo AG es más sensible a producir señales de compra y venta debido a que considera un rango de movimiento del oscilador más estrecho ($65-35 = 30$ puntos), respecto al enfoque tradicional ($70-30 = 40$ puntos).

La variación de los parámetros del indicador que produce un rango de movimiento diferente a la estrategia AT y un mayor número de datos para su construcción son determinantes para lograr un resultado superior. Esto, debido a que el indicador se adapta mejor a los datos históricos y en consecuencia presenta mejores atributos predictivos, lo que permite superar las estrategias de inversión convencionales de B&H y AT en un 9,78% y 16,97%, respectivamente. Esta última cifra fue cercana a la obtenida por Papailias y Thomakos (2015) y es consistente con la estrategia de modificación de los parámetros de los indicadores técnicos utilizados. Este hecho permitió alcanzar rendimientos superiores a 18% respecto al enfoque AT bajo parámetros estándar en los índices S&P 500 y DJIA.

Los resultados de este estudio también son consistentes con los resultados de Wang et al. (2016) mostrando rendimientos superiores a la estrategia AT bajo parámetros estáticos mediante el uso de AG con reglas de trading dinámicas (con mejor adaptación a las condiciones de volatilidad del activo).

Conclusiones

El uso de Algoritmos Genéticos permite obtener reglas de *trading* diferentes y con resultados notoriamente superiores desde el punto de vista de rendimiento financiero, respecto a las reglas utilizadas bajo la estrategia AT, debido a que los AG se ajustan más a las condiciones particulares del activo analizado y al propósito de rendimiento del analista, mientras que el método AT presenta parámetros estandarizados para la construcción del oscilador, independientemente del tipo de activo financiero analizado. Este aspecto asiste en responder la hipótesis de estudio ¿Es el análisis técnico tradicional suficiente para proporcionar parámetros óptimos que maximicen la rentabilidad y generen exceso en una inversión de renta variable?

El análisis técnico en sus forma simple (no automatizado mediante AG) es insuficiente *per se* para generar exceso en la rentabilidad (comparado con su contraparte automatizada). Esto es principalmente atribuible a los valores inadecuados de los parámetros del indicador técnico en uso. Por lo tanto, los resultados de rentabilidad de la estrategia AG demostraron su poder de refinamiento en la captura de señales (compra/venta) "lucrativas" como consecuencia de optimización paramétrica.

Por su parte, los resultados observados de la inversión mediante B&H fueron en general igualmente contrastantes con respecto al rendimiento de la estrategia AG. Debido a que en ciertos periodos puntuales B&H fue superior en rendimiento a AG, sugiere que otros factores de adaptación de los AG en estas fases tempranas del análisis pueden intervenir en el resultado esperado.

Con base a lo anterior, la hipótesis del estudio ¿Es posible extraer señales (de compra y/o venta) a partir de datos históricos de activos de renta variable que puedan conducir a lograr un exceso de rentabilidad (comparada con una estrategia B&H)? es avalada cuando se comparan ambas estrategias (B&H y AG) en

el mismo periodo total de estudio. Esto sugiere entonces que, la optimización de parámetros técnicos inmersos en AG es clave para la superioridad de la inversión bajo AG.

La aplicación de Algoritmos Genéticos a la estrategia de inversión con el oscilador RSI permite una mejor relación rendimiento-riesgo que deriva en una mayor eficiencia en los principales parámetros de la Teoría de Portafolio de Markowitz. Si bien, la incorporación de algoritmos genéticos con el indicador RSI es favorable, las circunstancias del mercado o el sistema económico juegan un papel igualmente determinante para la obtención de rendimientos superiores mediante cualquier estrategia y deben ser también considerados para una estrategia basada en AG.

El empleo de parámetros como *stop loss* y *take profit* muestran un favorecimiento del rendimiento de inversión a través de la facilitación de un rango de movimiento del precio del activo previo la toma de posición (compra o venta). La aplicación anticipada de dichos parámetros por medio de la utilización de órdenes de mercado y el sistema de alarmas del que disponen las plataformas electrónicas de transacción de activos financieros en el mercado de valores resulta práctico y representa beneficios para las estrategias con el indicador RSI.

Financiamiento

Este artículo es producto derivado de la investigación en finanzas cuantitativas, la cual fue financiada por la facultad de administración de la Universidad Nacional de Colombia.

Agradecimientos

Los autores de este artículo expresan su agradecimiento a la facultad de administración de la Universidad Nacional de Colombia por el soporte financiero que hizo posible la realización de esta investigación.

Referencias

- Abrams, J. R., Celaya-Alcalá, J., Ryan Gonda, D. B., & Chen, Z. (2017). Analysis of equity markets: a graph theory approach. https://evoq-eval.siam.org/Portals/0/Publications/SIURO/Volume%2010/Analysis_Equity_Markets_A_Graph_Theory_Approach.pdf?ver=2018-02-28-145946-083
- AFI Escuela de Finanzas España. (2017). *AFI guías. Análisis técnico-17*. <https://docero.es/doc/508v50>
- Agudelo Aguirre, A. A., Rojas Medina, R. A., & Duque Méndez, N. D. (2020). Machine learning applied in the stock market through the Moving Average Convergence Divergence (MACD) indicator. *Investment Management and Financial Innovations*, 17(4), 44-60. [https://doi.org/10.21511/imfi.17\(4\).2020.05](https://doi.org/10.21511/imfi.17(4).2020.05)

- Allen, F., Karjalainen, R. (1999). Using genetic algorithms to find technical trading rules. *Journal of Financial Economic*, 51(2), 245-271. [https://doi.org/10.1016/S0304-405X\(98\)00052-X](https://doi.org/10.1016/S0304-405X(98)00052-X)
- Boboc, I-A., & Dinică, M-C. (2013). An algorithm for testing the efficient market hypothesis. *PLoS ONE*, 8(10), e78177. <https://doi.org/10.1371/journal.pone.0078177>
- Burduk, A., Musiał, K., Kochańska, J., & Łapczyńska, D. (2019). Tabu search and genetic algorithm for production process scheduling problem. *Scientific Journal of Logistics*, 15(2), 181-189. <https://doi.org/10.17270/J.LOG.2019.315>
- Chen, Y., Mabu, S., & Hirasawa, K. (2011). Genetic relation algorithm with guided mutation for the large-scale portfolio optimization. *Expert System with Applications*, 38 (4), 3353-3363. <https://doi.org/10.1016/j.eswa.2010.08.120>
- Cheng, C-H., Chen, T-L., & Wei, L-Y. (2010). A Hybrid model based on rough sets theory and genetic algorithms for stock price forecasting. *Information Science*, 180(9), 1610-1629. <https://doi.org/10.1016/j.ins.2010.01.014>
- Chou, C.-C., & Lin, K.-S. (2019). A fuzzy neural network combined with technical indicators and its application to Baltic dry index forecasting. *Journal of Marine Engineering & Technology*, 18 (2), 82-91. <https://doi.org/10.1080/20464177.2018.1495886>
- Cohen, G., & Cabiri, E. (2015). ¿Can technical oscillators outperform the buy and hold strategy? *Applied Economics*, 47(30), 3189-3197. <https://doi.org/10.1080/00036846.2015.1013609>
- Cortés-Villafradez, R. A., y Hernández-Luna, Y. (2014). Impacto del desarrollo del sistema financiero en el crecimiento económico en países emergentes durante el periodo 2001-2011. *Equidad y Desarrollo* 1(22), 99-120. <https://doi.org/10.19052/ed.3252>
- Ding, S., Cui, T., Xiong, X., & Bai, R. (2020). Forecasting stock market return with nonlinearity: a genetic programming approach. *J Ambient Intell Human Comput*, 11, 4927–4939. <https://doi.org/10.1007/s12652-020-01762-0>
- Drake, A.E., & Marks, R.E. (2002). Genetic algorithms in economics and finance: forecasting stock market prices and foreign exchange—a review. En, Chen SH. (eds). *Genetic algorithms and genetic programming in computational finance* (pp. 29-54). https://doi.org/10.1007/978-1-4615-0835-9_2
- Evans, C., Pappas, K., & Xhafa, F. (2013). Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation. *Mathematical and Computer Modelling*, 58 (5-6), 1249-1266. <https://doi.org/10.1016/j.mcm.2013.02.002>
- Fama, E. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- Farias-Nazário, R. T., Lima e Silva, J., Sobreiro, V. A., & Kimura, H. (2017). A literature review of technical analysis on stock markets. *The Quarterly Review of Economics and Finance*, 66, 115-126. <https://doi.org/10.1016/j.qref.2017.01.014>

- Fernández-Rodríguez, F., González-Martel, C., Sosvilla-Rivero, S. (2001). Optimization of technical rules by genetic algorithms: evidence from the Madrid stock market. *[Documento de trabajo]*. FEDEA. www.ftp://ftp.fedea.es/pub/Papers/2001/dt2001-14.pdf
- Figueroa-Pelayo, A. P., y Gualdron-López, A. E. (2014). Importancia de los índices bursátiles en el mercado de Colombia. *Innovando en la U*, 5(6), 123-131. <https://revistas.unilibre.edu.co/index.php/innovando/article/view/3880>
- Forrest, S. (1993). Genetic algorithms: Principles of adaptation applied to computation. *Science* 261 (August 13), 872- 878. <https://doi.org/10.1126/science.8346439>
- Forrest, S. (1996). Genetic Algorithms. *ACM Computing Surveys*, 28(1), 77-80. <https://dl.acm.org/doi/10.1145/234313.234350>
- García, M. C., Jalal, A. M., Garzón, L. A., & López, J. M. (2013). Methods for predicting stock indexes. *Ecos de Economía*, 17(37), 51-82. <https://doi.org/10.17230/ecos.2013.37.3>
- Gold, S. (2015). The Viability of six popular technical analysis trading rules in determining effective buy and sell signals: MACD, AROON, RSI, SO, OBV, and ADL. *Journal of Applied Financial Research*, 2, 8-29.
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2019). Literature review: machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124, 226-251. <https://doi.org/10.1016/j.eswa.2019.01.012>
- Holland, J. H. (1975). *Adaptation in natural and artificial systems*. University of Michigan Press.
- Holland, J. H. (1982). *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. MIT Press.
- Isidore, R., Christie, P. (2018). Fundamental analysis versus technical analysis-A comparative review. *Int J Recent Sci Res*, 9(1), 23009-23013. <http://dx.doi.org/10.24327/ijrsr.2018.0901.1380>
- Khan, M. A., Aman, Q., & Khan, N. (2016) Technical analysis: concept or reality?. *Pakistan Business Review*: 732-751.
- Levine, R. (1997). Financial development and economic growth: views and agenda. *Journal of Economic Literature*, 35(2), 688-726. <https://www.jstor.org/stable/2729790>
- Llorente-López, M. A. (2012). *Programación Genética en Mercados Financieros - Construcción automática de reglas de inversión utilizando programación genética* [Proyecto final, Universitat Politècnica de Catalunya, UPC]. Repositorio digital. <https://upcommons.upc.edu/bitstream/handle/2099.1/14104/77634.pdf?sequence=1&isAllowed=y>
- Luukka, P., Pätäri, E., John, E., & Garanina, T. (2016). Performance of moving average trading rules in a volatile stock market: The Russian evidence. *Emerging Markets Finance & Trade*, 52(10), 2434-2450. <https://doi.org/10.1080/1540496X.2015.1087785>

- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 1952, 77-91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- Metghalchi, M., Chen, C., & Hayes, L. (2015). History of share prices and market efficiency of the Madrid general stock index. *International Review of Financial Analysis*, 40, 178-184. <https://doi.org/10.1016/j.irfa.2015.05.016>
- Mohd-Nor, S., & Wickremasinghe, G. (2014). The profitability of MACD and RSI trading rules in the Australian stock market. *Investment Management and Financial Innovations*, 11(4), 194-199. https://www.businessperspectives.org/images/pdf/applications/publishing/templates/article/assets/6228/imfi_en_2014_04cont_Nor.pdf
- Moosa, I., & Li, L. (2011). Technical and fundamental trading in the Chinese stock market: Evidence based on time-series and panel data. *Emerging Markets Finance and Trade*, 47 (Supplement 1), 23-31. <https://doi.org/10.2753/REE1540-496X4701S103>
- Murphy, J. (1998). *Technical analysis of the financial markets: a comprehensive guide to trading methods and applications*. Pearson Professional Education.
- Murphy, J. (2016). *Análisis Técnico de los Mercados Financieros*. Editorial Paidós.
- Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, (53), 3007–3057. <https://doi.org/10.1007/s10462-019-09754-z>
- Papailias, F., & Thomakos, D. D. (2015). An improved moving average technical trading rule. *Physica A: Statistical Mechanics and its Applications*, 428, 458-469. <https://doi.org/10.1016/j.physa.2015.01.088>
- Petrusheva, N., & Jordanoski, I. (2016). Comparative analysis between fundamental and technical analysis of stocks. *Journal of Process Management - New Technologies, International*, 4(2), 26-31. <https://scindeks-clanci.ceon.rs/data/pdf/2334-735x/2016/2334-735x1602026p.pdf>
- Radeerom, M. (2014). Automatic trading system based on genetic algorithm and technical analysis for stock index. *International Journal of Information Processing and Management (IJIPM)*, 5(4), 124-132.
- Restrepo-Gaviria, A. M. (2015). *El sistema financiero y su importancia en el crecimiento económicos*. [Tesis de pregrado, Universidad Pontificia Bolivariana]. Repositorio Institucional UPB. <http://hdl.handle.net/20.500.11912/2239>
- Rodrigues-Leles, M. C., Amaral-Mozelli, L., & Nogueira-Guimarães, H. (2017). A new trend-following indicator: Using SSA to design trading rules. *Fluctuation and Noise Letters*, 16(2), 1-16. <https://doi.org/10.1142/S021947751750016X>
- Rosillo, R., de la Fuente, D., & Burgos, J. A. L. (2013). Technical analysis and the Spanish stock exchange: testing the RSI, MACD, momentum and stochastic rules using Spanish market companies. *Applied Economics*, 45(12), 1541-1550. <https://doi.org/10.1080/00036846.2011.631894>

- Rosillo, R., Giner, J., & de la Fuente, D. (2014). Stock market simulation using support vector machines. *Journal of Forecasting*, 33 (6), 488-500. <https://doi.org/10.1002/for.2302>
- Sevilla-Arias, A. (2012). *Índice bursátil*. <https://bit.ly/3u5KvZi>
- Shangkun, D., Yizhou, S., & Akito, S. (2012). Robustness test of genetic algorithm on generating rules for currency trading, *Procedia Computer Science*, 13, 86-98. <https://doi.org/10.1016/j.procs.2012.09.117>
- Sharpe, W. F. (1964). Capital asset prices: a theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19(3), 425-442. <https://doi.org/10.1111/j.1540-6261.1964.tb02865.x>
- Straßburg, J., González-Martel, C., & Alexandrov, V. (2012). Parallel genetic algorithms for stock market trading rules. *Procedia Computer Science*, 9, 1306-1313. <https://doi.org/10.1016/j.procs.2012.04.143>
- Suresh, A. S. (2013) A study of fundamental and technical analysis. *International Journal of Marketing, Financial Services & Management Research*. 2(5), 44-59.
- Swain, K.R. (2012). Book Review: Technical Analysis Ideal for Beginners. *Asia-Pacific Journal of Management Research and Innovation*, 8(4), 537-538. <https://doi.org/10.1177%2F2319510X13482021>
- Taylor, N. (2014). The rise and fall of technical trading rule success. *Journal of Banking & Finance*, 40, 286-302. <https://doi.org/10.1016/j.jbankfin.2013.12.004>
- Tharavanij, P., Siraprapasiri, V., & Rajchamaha, K. (2015). Performance of technical trading rules. *SpringerPlus*, 4(1). 1-40. <https://doi.org/10.1186/s40064-015-1334-7>
- Vora, M. N. (2011). Genetic algorithm for trading signal generation. Solution to trader's dilemma: Is it right time to trade?. *International Conference on Business and Economics Research*, 1, 316-320. <http://ipedr.com/vol1/68-G00012.pdf>
- Wang, C.-F., Liu, K., Shen, P.-P. (2020) A novel genetic algorithm for global optimization. *Acta Mathematicae Applicatae Sinica, English Series*, 36(2), 482-491. <https://doi.org/10.1007/s10255-020-0930-7>
- Wang, L., An, H., Liu, X. & Huang, X. (2016). Selecting dynamic moving average trading rules in the crude oil futures market using a genetic approach. *Applied Energy*, 162, 1608-1618. <https://doi.org/10.1016/j.apenergy.2015.08.132>
- Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research.
- Zapranis, A., & Tsinaslanidis, P. E. (2012). A novel, rule-based technical pattern identification mechanism: Identifying and evaluating saucers and resistant levels in the US stock market. *Expert System with Applications*, 39(7), 6301-6308. <https://doi.org/10.1016/j.eswa.2011.11.079>