



**UNIVERSIDAD NACIONAL AUTÓNOMA DE
MÉXICO**

PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
MAESTRÍA EN SISTEMAS - OPTIMACIÓN FINANCIERA

*ALGORITMO GENÉTICO APLICADO EN ESTRATEGIAS DE
TRADING BASADAS EN INDICADORES TÉCNICOS PARA
LA GESTIÓN DEL RIESGO DE UN PORTAFOLIO*

TESIS

QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN INGENIERÍA

PRESENTA:

ROBERTO CERVERA AGUILAR Y RUIZ DE CHÁVEZ

TUTOR:

DR. WULFRANO GÓMEZ GALLARDO . F. I.

CIUDAD DE MÉXICO, AGOSTO 2022



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



Índice de figuras

1.1	Frontera Eficiente y elección del portafolio (Fuente: Pennacchi, 2008)	4
1.2	Representación estadística del VaR y CVaR (Fuente: Elaboración propia).	8
1.3	Diagrama de flujo de un algoritmo genético (Fuente: Elaboración propia).	12
2.1	Aplicación Estrategia Medias Móviles para Apple (Fuente: Elaboración propia).	17
2.2	Aplicación MACD (Fuente: Elaboración propia).	19
2.3	MACD como variable predictora (Fuente: Elaboración propia).	19
2.4	Aplicación RSI (Fuente: Elaboración propia)	21
3.1	Comportamiento Mercado Mexicano (IPC) de 2020-01-02 a 2021-03-31 (Fuente: Elaboración Propia).	23
3.2	Comportamiento de los Activos que conforman el portafolio de 2020-01-02 a 2021-03-31 (Fuente: Elaboración Propia).	25
3.3	Correlación de los activos seleccionados (Fuente: Elaboración Propia).	26
3.4	Riesgo vs Rendimiento (Fuente: Elaboración Propia).	27
3.5	Esquema "Rolling Window" utilizado en la calibración de los modelos (Fuente: Elaboración Propia).	28
3.6	Pesos Dinámicos del portafolio según el trimestre (Fuente: Elaboración Propia).	29
3.7	Comportamiento Volatilidad para cada periodo de rebalanceo (Fuente: Elaboración Propia).	29
3.8	Resumen Rendimiento de los portafolios rebalanceados (Fuente: Elaboración Propia).	31
4.1	Aplicación Algoritmo Genética para medias móviles - CEMEX (Fuente: Elaboración Propia)	36
4.2	Aplicación Algoritmo Genética para MACD - CEMEX (Fuente: Elaboración Propia)	37
4.3	Aplicación Algoritmo Genética para RSI - CEMEX (Fuente: Elaboración Propia)	38
4.4	Aplicación Estrategia Genética para CEMEX (Fuente: Elaboración Propia)	39
4.5	Aplicación Algoritmo Genético para Apple (Arriba) y Alsea (Abajo) (Fuente: Elaboración Propia)	40



ÍNDICE DE FIGURAS

4.6	Aplicación Algoritmo Genético para Bimbo (Arriba) y Grupo Carso (Abajo) (Fuente: Elaboración Propia)	41
4.7	Aplicación Algoritmo Genético para Gentera (Arriba) y Walmart (Abajo) (Fuente: Elaboración Propia)	42
4.8	Operaciones de la estrategia genética para PayPal (Fuente: Elaboración Propia)	44
4.9	Operaciones de la estrategia genética para Volaris (Fuente: Elaboración Propia)	45
4.10	Operaciones de la estrategia genética para Walmart (Fuente: Elaboración Propia)	46
4.11	Rendimiento Acumulado de Volaris con la estrategia genética (Fuente: Elaboración Propia)	47
4.12	Comparación estrategia genética vs Buy & Hold para cada activo (Fuente: Elaboración Propia)	50
4.13	Comparación portafolios (Fuente: Elaboración Propia)	51
4.14	Comportamiento del rendimiento acumulado y de la volatilidad de los portafolios (Fuente: Elaboración Propia)	52
4.15	Operaciones de la estrategia genética para Apple	62
4.16	Operaciones de la estrategia genética para Alsea	62
4.17	Operaciones de la estrategia genética para Bimbo	63
4.18	Operaciones de la estrategia genética para Cemex	63
4.19	Operaciones de la estrategia genética para Grupo Carso	64
4.20	Operaciones de la estrategia genética para Gentera	64
4.21	Operaciones de la estrategia genética para GM	65
4.22	Operaciones de la estrategia genética para MGM	65
4.23	Rendimiento Acumulado de Apple con la estrategia genética	66
4.24	Rendimiento Acumulado de Alsea con la estrategia genética	66
4.25	Rendimiento Acumulado de Bimbo con la estrategia genética	67
4.26	Rendimiento Acumulado de Cemex con la estrategia genética	67
4.27	Rendimiento Acumulado de Grupo Carso con la estrategia genética	68
4.28	Rendimiento Acumulado de Gentera con la estrategia genética	68
4.29	Rendimiento Acumulado de GM con la estrategia genética	69
4.30	Rendimiento Acumulado de MGM con la estrategia genética	69
4.31	Rendimiento Acumulado de PayPal con la estrategia genética	70
4.32	Rendimiento Acumulado de Walmart con la estrategia genética	70



Índice de cuadros

3.1	Lista de Activos que conforman el Portafolio	24
3.2	Resumen Rendimientos Logarítmicos de los Activos de 2019 a 2020	27
3.3	Resumen rendimiento para cada activo durante el periodo de inversión (2020-01-01 a 2021-04-01)	30
3.4	Comportamiento Trimestral del Portafolio con respecto al Riesgo	32
3.5	Métricas Resumen del Portofolio (2020-01-01 a 2021-04-01)	32
3.6	Métricas Resumen del Mercado-IPC (2020-01-01 a 2021-04-01)	33
4.1	Estrategia genética vs B&H para cada activo	48
4.2	Métricas del desempeño de la estrategia genética para cada activo durante el periodo de ejercicio (2020-01-01 a 2021-04-01)	49
4.3	Métricas Resumen del Portofolio con la estrategia genética	50
4.4	Comparación portafolios del rendimiento por periodo	53



Índice

1	Introducción	vii
	Marco Contextual	x
	Problemática	x
	Justificación	xi
	Hipótesis	xii
	Pregunta de investigación	xii
	Preguntas Específicas	xii
	Objetivo	xii
	Objetivos Específicos	xii
I	Marco Teórico	1
1		2
1.1	Modelo de Markowitz	2
1.2	Complejidad en los proceso de pronóstico	5
1.3	Indicadores Técnicos	6
1.4	Métodos de Cuantificación del Riesgo	7
1.4.1	Valor en Riesgo (VaR)	7
1.4.2	Críticas al VaR	9
1.4.3	Valor en Riesgo Condicional (CVaR)	9
1.5	Algoritmos de Aprendizaje Automático	10
1.6	Algoritmo Génético	11



II	Aplicación Indicadores Técnicos	14
2		15
2.1	Indicadores de Tendencia	15
2.1.1	Medias Móviles	15
2.2	Indicadores de Momento (Momentum-Osciladores)	18
2.2.1	Media Móvil de Convergencia/Divergencia	18
2.2.2	Índice de fuerza relativa	20
III	Descripción y Optimización del Portafolio Rebalanceado	22
3		23
3.1	Descripción del mercado	23
3.2	Activos Financieros	24
3.3	Estrategia del Portafolio Rebalanceado	26
3.3.1	Análisis Exploratorio de los Activos	26
3.3.2	Construcción del Portafolio	28
3.3.3	Desempeño y Evaluación del Portafolio	30
IV	Aplicación del Modelo y Evaluación de la Estrategia	34
4		35
4.1	Algoritmo Genético	35
4.1.1	Comportamiento de los Activos	39
4.2	Aplicación de la Estrategia	43
4.2.1	Desempeño Individual (por activo)	44
4.2.2	Comportamiento del Riesgo	49
4.3	Desempeño del Portafolio (conjunto)	50
V	Conclusiones	54
	Futuras Investigaciones	55



ÍNDICE



VI	Referencias	57
VII	Anexos	61



Introducción

Actualmente, el éxito de muchos inversores en el mercado de capitales radica en el resultado de la correcta elección y planificación de una estrategia de *trading*. El objetivo de dichas estrategias es maximizar el rendimiento y realizar una correcta gestión del riesgo. Existen dos enfoques principales para analizar el comportamiento de un activo y determinar si es conveniente optar por una posición larga o una posición corta, dichos enfoques son: el análisis técnico y el análisis fundamental (Iskrich & Grigoriev, 2017).

En el análisis fundamental, los indicadores de mayor importancia son la política de dividendos, valor empresarial, utilidad neta y las ventas brutas. El análisis técnico se basa en analizar el comportamiento del precio del activo y el cálculo de indicadores adicionales que, al seguir ciertos patrones, ayudan a identificar la dirección de la tendencia actual y su posible comportamiento futuro.

El análisis técnico emplea las herramientas de geometría y reconocimiento de patrones, su objetivo principal no es identificar regularidades en la serie temporal de precios, sino observar patrones para tomar decisiones de compra/venta de activos financieros. Implícito en este objetivo está el reconocimiento de que algunos movimientos de precios son significativos: contribuyen a la formación de un patrón y otros son simplemente fluctuaciones aleatorias que deben ignorarse (ruido).

La estrategia del inversor (*trader*) se basa en la formalización de reglas para tomar una posición (comprar, vender o mantener) y mediante estas reglas se logra una gestión óptima del portafolio en términos de rendimiento y riesgo. Muy a menudo estas reglas se basan en métodos de análisis técnico. De acuerdo con los postulados del análisis técnico, los indicadores técnicos permiten pronosticar la tendencia y su dirección con un cierto grado de seguridad. Por lo tanto, la combinación de indicadores y sus respectivos valores pueden ser de gran utilidad como base para el diseño de una estrategia de inversión (*trading*) (John, 1999; R. Morta, 2015; S. Yodphet & Leelathakul, 2016).

Es importante destacar que uno de los mayores abismos entre las finanzas académicas y la práctica de la industria, es la separación que existe entre los analistas técnicos y las críticas por parte de la academia. El análisis técnico es catalogado en muchos artículos como el “*Voodoo*” de las finanzas (Lo, Mamaysky, & Wang, 2000)

A lo largo del tiempo, se ha generado una gran cantidad de literatura sobre la efectividad de varias reglas técnicas de *trading*, la mayoría de esta literatura ha encontrado que tales reglas no son rentables. Por ejemplo, Alexander (1961) prueba un número de reglas de filtrado que aconsejan al inversionista que compre si el precio sube en un porcentaje fijo (por ejemplo 5%) y vender si el precio baja en el mismo porcentaje.



Aunque tales reglas parecen producir rendimientos por encima de la estrategia de comprar y mantener (*Buy and Hold*) para los Índices bursátiles *Dow Jones y Standard & Poors*, Alexander (1964) concluye que ajustadas por los costos de transacción, las reglas del filtro no son rentables. Estas conclusiones están respaldadas por los resultados de Eugene F. Fama & Blume (1966), quienes no encontraron evidencia de reglas de filtro rentables para los 30 activos del *Dow Jones*. A su vez, Eugene F. Fama (1965) concluye la existencia de independencia en el cambio de los precios y que estos siguen una caminata aleatoria, por lo que no se puede vencer al mercado a largo plazo y que la mejor estrategia posible es el *Buy and Hold* (B&H).

Varios estudios académicos sugieren que el análisis técnico puede ser un medio eficaz para extraer información útil de los precios del mercado. Por ejemplo, al rechazar la hipótesis de caminata aleatoria para los índices bursátiles semanales de EE.UU. Lo & MacKinlay (1999) demostraron que los precios pasados pueden utilizarse para pronosticar los rendimientos futuros con un cierto grado de seguridad, un hecho que todos los analistas técnicos toman por subvención. Estudios de Brown & Jennings (1989), Treynor & Ferguson (1985), Jegadeesh & Titman (1993) y, sobre todo Pruitt & White (1988) (por mencionar algunos) también han proporcionado apoyo y sustento para el análisis técnico.

A pesar de las duras críticas hacia el análisis técnico, existe vasta evidencia sobre la eficacia del análisis técnico para la gestión del riesgo, en donde se proporcionan estrategias para minimizar la pérdida. Bohnenblust & Slovic (1998) utilizaron el análisis técnico como una herramienta complementaria y de apoyo para el análisis del riesgo y poder realizar decisiones óptimas de inversión.

Varios autores han propuesto diversas aproximaciones en donde se utiliza el análisis técnico en conjunto con otras técnicas de modelación de series de tiempo, con el objetivo de maximizar el rendimiento y/o minimizar el riesgo (Q. Lin, 2018). Fang & Xu (2003) diseñaron una estrategia de *trading* basada en un modelo “Garch” en conjunción con indicadores técnicos. Y demostraron que se tiene un mejor rendimiento que si se hubieran utilizado las 2 técnicas de forma individual, y a su vez se tuvo una volatilidad más estable y controlada.

Otro ejemplo del uso combinado del análisis técnico con otras herramientas de modelación más novedosas fue demostrado por Li & Bastos (2020), ellos combinaron el análisis técnico y redes neuronales (aprendizaje profundo) para determinar estrategias de *trading* para la óptima gestión del riesgo, y la maximización del rendimiento.

Gracias a los ejemplos anteriormente mencionados se puede concluir que utilizar el análisis técnico aunado a otras herramientas es bastante fructífero. El incluir el análisis técnico como una herramienta complementaria mejora el desempeño de la estrategia en términos de la varianza (riesgo) y el rendimiento (Bohnenblust & Slovic, 1998).

Usualmente las estrategias de *trading* están enfocadas en maximizar el rendimiento y dejan de lado la gestión del riesgo. Aunque el uso clásico de los indicadores técnicos también busca maximizar el rendimiento, también de forma indirecta se logra reducir el riesgo al minimizar las pérdidas.

Dorffleitner & Klein (2003) proponen 3 estrategias basadas en indicadores técnicos exclusivamente para la gestión del riesgo, con lo cual lograron reducir el riesgo con respecto a la estrategia de Buy & Hold al utilizar las estrategias anteriormente mencionadas.

En este trabajo se propuso una estrategia de *trading* utilizando el análisis técnico en conjunto con un algoritmo genético, de tal manera que la estrategia funcione como una herramienta para la gestión del riesgo y no tanto para la maximización del rendimiento.



Allen & Karjalainen (1999) utilizaron el algoritmo genético para generar las reglas de compra y venta óptimos sobre el S&P500, de la cual se concluyó que no era significativamente mejor que “B&H” después de considerar los costos de transacción. Debido a lo anterior, en este documento se pretende dar un enfoque diferente con estos algoritmos, en lugar de generar las reglas a partir del algoritmo. Éstas se determinaron “a priori” y se utilizó el algoritmo solo para optimizar los parámetros de los indicadores técnicos que constituyen la estrategia de *trading* y que generan las reglas de compra/venta . Por ejemplo, en el caso de una estrategia basada en medias móviles, los parámetros a optimizar son el número de periodos de cada media móvil y mediante el uso de estas medias móviles “optimizadas” se generan las señales de compra y venta.

Dicho enfoque fue probado por Gómez Vilchis, Hernández Álvarez, & Román de la Sancha (2021), en donde utilizaron el algoritmo genético para obtener las combinaciones óptimas de medias móviles para generar las señales de compra y venta. Demostrando que su uso permite minimizar las pérdidas en el periodo de crisis del 2008 y tener ligeramente mayores rendimientos en periodos subsecuentes, aunque esta estrategia solo fue aplicado en activos individuales y no en un portafolio.

En el presente trabajo se pretende corroborar si el hecho de utilizar una estrategia de *trading* basada conjuntamente en indicadores técnicos y en un algoritmo genético puede desempeñarse como una herramienta para la gestión del riesgo de un portafolio y no solo para activos de forma individual. Aplicar la estrategia de *trading* de forma eficiente a cada activo también debería tener un desempeño positivo en un portafolio que esté conformado por dichos activos. El realizar las compras y ventas mediante esta estrategia para cada activo debería propiciar una gestión inteligente y eficaz del riesgo del portafolio.

Aunque existen diversos modelos y herramientas dirigidos a la gestión del riesgo de un portafolio, se seleccionó el Modelo de Markowitz con rebalanceo, ya que este es uno de los más comunes y prácticos y de los más utilizados en la industria. Se generó un portafolio mediante el modelo de Markowitz, en el cual se realizó un rebalanceo trimestral con el objetivo de mantener la volatilidad constante a lo largo del periodo de inversión.

El portafolio rebalanceado gestionó el riesgo de forma trimestral bajo el enfoque de optimización de Markowitz, mientras que el portafolio que utilizó la estrategia genética lo hizo mediante los indicadores técnicos. Se comparó ambos portafolios para determinar cuál es mejor principalmente en términos del riesgo. Para considerar viable la estrategia propuesta en este trabajo el portafolio basado en el algoritmo genético tiene que ser mejor que el portafolio rebalanceado basado en Markowitz.

En resumen, la estrategia que se utilizó en este trabajo consiste en la aplicación conjunta de 3 indicadores técnicos: *RSI*, *MACD* y tres Medias Móviles, para generar señales de compra y venta. Se hizo uso de las reglas de compra y ventas características de cada indicador técnico y a partir de estas reglas se obtuvieron los parámetros óptimos de cada indicador que maximizaron el rendimiento en un periodo específico de 12 meses, dicha optimización fue realizada mediante el algoritmo genético cada 3 meses (misma frecuencia que el rebalanceo de Markowitz). Posteriormente, se combinaron las señales generadas para cada indicador técnico optimizado y, con estas señales se definió una estrategia de *trading* general. Dicha estrategia se aplicó a un portafolio con activos del mercado de capitales y se comparó con el portafolio de Markowitz rebalanceado de forma trimestral. La función del algoritmo genético es obtener los parámetros óptimos de los indicadores técnicos, de tal forma que se generen señales (compra y venta) que maximizan las utilidades en un periodo determinado, por lo que se tendrían indicadores técnicos optimizados para cada activo.

Con el fin de verificar la gestión del riesgo de ambos portafolio se optó por un periodo de crisis. Para



dicho escenario se seleccionó el periodo que transcurrió de enero de 2020 a agosto del mismo año, que fue donde se suscitó el fenómeno de la pandemia por COVID-19.

Lo anterior es muy relevante, ya que en periodos de alta volatilidad generalmente las estrategias y modelos matemáticos tienden a reducir su eficacia y a comportarse de forma inesperada, motivo por el cual el periodo del COVID se considera como una situación ideal para probar la eficacia de la estrategia genética en un escenario extremista de alta volatilidad, de incertidumbre y poco común.

Marco Contextual

Son plétóricas las fuentes de información financiera en el mundo que pueden convertirse en áreas de investigación valiosas. Una de estas áreas es la correcta gestión del riesgo de un portafolio. La capacidad de poder administrar el riesgo con modelos más precisos se ha vuelto cada vez más importante, especialmente en la creación de varias reglas para ayudar a tomar mejores decisiones de inversión en diferentes mercados de valores (Alkhatib, Najadat, Hmeidi, & Shatnawi, 2013).

La previsión del mercado de valores es una tarea desafiante, ya que se caracteriza por no ser estacionaria y con un alto grado de incertidumbre (Abu-Mostafa & Atiya, 1996). Por lo tanto, existe en la actualidad una necesidad de establecer modelos que permitan analizar los patrones del comportamiento de los activos para generar reglas de compra y venta que logren reducir el riesgo.

Aunado a lo anterior y debido a la existencia de datos de alta frecuencia (información en tiempo real, cuyo comportamiento no puede ser tipificado de la misma manera de aquella información de baja frecuencia, por ejemplo información por segundo vs diaria), ha ido incrementando la necesidad de implementar algoritmos de *trading* con un enfoque en la minimización de pérdidas.

En el mercado existen muchas estrategias que involucran algoritmos que se encargan de realizar estas acciones de forma eficiente e inmediata con base a un modelo. La gran mayoría de éstos están utilizando herramientas de inteligencia artificial y aprendizaje automático. Por lo que en el mercado está presente una creciente oportunidad para el uso de dichas herramientas, que día con día son implementadas en más estrategias de *trading*, esto aunado a los avances tecnológicos y apertura que han tenido los mercados.

Problemática

En las actividades diarias de negociación de acciones, los precios de las acciones tienden a fluctuar demasiado debido a las crecientes tecnologías y a la gran difusión de la información. Por lo que el mercado se ha vuelto realmente complejo y volátil, en donde correcciones de mayor magnitud suceden con mayor frecuencia que antes, con lo cual la estimación del riesgo de un activo y su correcta administración se ha vuelto una tarea extremadamente compleja y desafiante, en la que la mayoría de las personas que pretenden entrar al mercado terminan perdiendo una parte de su inversión (Richards, Rutterford, Kodwani, & Fenton-O'Creevy, 2017).

Los inversionistas (*traders*) realizan análisis y métodos de pronóstico de las cotizaciones de los activos con el objetivo de apoyarse para la toma de decisiones de cuándo comprar o vender sus acciones, con el objetivo de maximizar sus rendimientos y/o minimizar pérdidas. Para tener rendimientos y gestionar el



riesgo, los inversionistas hacen uso de una estrategia, la cual puede incluir la aplicación de diversas reglas de compra/venta a partir del análisis de los indicadores técnicos y/o la utilización de varios modelos matemáticos.

Aunque existen diversos modelos propuestos, aún no existe uno que sea infalible y la mayoría de éstos suelen no funcionar en todos los activos y/o en todo momento (periodos de alta volatilidad). Por otra parte, el aprendizaje automático (*machine learning*) ha estado creciendo exponencialmente, mostrando muy buenos resultados en la aplicación de tareas complejas. Existe un mundo de posibilidades para complementar las herramientas de aprendizaje automático con una estrategia de *trading* existente, con el objetivo de mejorar la gestión del riesgo de un activo durante distintos periodos de inversión.

Justificación

Los pronósticos del mercado de valores tienen un papel altamente relevante, ya que pueden tener un impacto significativo en la economía global (Bosworth, Hymans, & Modigliani, 1975). Debido a su importancia funcional, el análisis de la volatilidad del mercado de valores se ha convertido en un tema de investigación importante en varias áreas, incluidas las finanzas, la estadística y las matemáticas (Cavalcante, Brasileiro, Souza, Nobrega, & Oliveira, 2016). Sin duda, es muy difícil comprender el comportamiento del mercado de valores, ya que la volatilidad es demasiado grande para ser capturada en un modelo (Atsalakis & Valavanis, 2009), esto debido a las colas pesadas y a que la varianza no está definida, por lo que no se tiene estacionariedad en covarianza (Eugene F. Fama, 1965).

Se ha observado que es cada vez más compleja una correcta administración del riesgo donde se subestime o se sobrestime. Ya que una incorrecta gestión del riesgo puede tener consecuencias altamente nocivas en la economía global como se ha observado en las distintas crisis, sobre todo en la *Subprime* del 2008.

A pesar de estas dificultades, ha existido un deseo constante de desarrollar modelos fiables para comprender el mercado de valores (Tay & Cao, 2001). En las últimas décadas se han realizado varios enfoques para pronosticar los mercados de valores utilizando estadística y algoritmos de automatización. La mayoría de los primeros estudios tienden a emplear métodos estadísticos, pero estos enfoques tienen limitaciones cuando se aplican a los erráticos datos de las series financieras, debido a muchos supuestos estadísticos, como: la linealidad, estacionariedad, ergodicidad, simetría y normalidad (H. Kim & Shin, 2007).

En consecuencia, varias técnicas de algoritmos evolutivos y aprendizaje automático, incluida la red neuronal artificial (*ANN*, *Artificial Neuronal Networks*, por sus siglas en inglés) y la máquina de vectores de soporte (*SVM*, *Support Vector Machines*, por sus siglas en inglés), pueden reflejar la no linealidad y las características complejas de las series de tiempo financieras, las cuales han comenzado a aplicarse al mercado de valores con una correcta administración del riesgo. Estos enfoques han proporcionado habilidades destacadas para anticipar entornos caóticos de los mercados de valores al capturar su naturaleza no lineal y no estructurada (X. Lin, Yang, & Song (2009) y Adebisi, Adewumi, & Ayo (2014)). Por la gran cantidad de información que se puede obtener de los activos, así como el gran número de indicadores técnicos que se pueden contrastar, es posible diseñar una estrategia de negociación (*trading*) utilizando dichas técnicas. El principal reto en una estrategia de *trading* basada en indicadores técnicos es la selección de éstos y el determinar el valor óptimo de los parámetros de dichos indicadores, ya que los parámetros utilizados en un indicador no tendrán la misma eficacia en todos los activos.



Debido a la problemática de los parámetros de los indicadores técnicos, se han propuesto valores para algunos indicadores, mediante los cuales, se tiene un desempeño presumiblemente óptimo para la mayoría de los activos. Mientras que para otros indicadores, es responsabilidad del inversionista el seleccionar los parámetros óptimos para su estrategia con base a su conocimiento y experiencia.

En consecuencia, se optó por utilizar un algoritmo genético para maximizar las utilidades de la estrategia de *trading* a partir de la optimización del conjunto de parámetros que comprenden los indicadores técnicos utilizados.

Hipótesis

Utilizando un algoritmo genético que optimice los parámetros de los indicadores técnicos se puede construir una estrategia de *trading* a partir de dichos indicadores optimizados, que al ser aplicada de forma individual a cada activo de un portafolio logre gestionar de forma automática el riesgo de todo el portafolio, así como la minimización de las posibles pérdidas que puede sufrir el portafolio a lo largo del periodo de inversión.

Pregunta de investigación

¿Es posible con la aplicación de un algoritmo genético tener una estrategia de *trading* más robusta que reduzca el riesgo, minimice las pérdidas y/o mejore los rendimientos de diversos activos de forma individual y en forma conjunta (portafolio) con respecto a la estrategia de *Buy and Hold*?

Preguntas Específicas

¿Qué tan útil puede ser la estrategia aplicándola de forma conjunta a un portafolio y no solo a un activo, se logra maximizar el rendimiento y/o minimizar el riesgo?

¿Bajo qué escenarios/activos estos modelos se comportan mejor que *Buy and Hold* y, para cuáles no son recomendables?

¿Se puede aplicar un algoritmo genético como herramienta para minimizar el riesgo de inversión en una estrategia de *trading* durante una etapa de crisis como el COVID 19?

Objetivo

Aplicar a un portafolio una estrategia de *trading* basada en indicadores técnicos, utilizando un algoritmo genético como herramienta para determinar los parámetros óptimos de cada indicador que logren maximizar los rendimientos.

Objetivos Específicos

- Determinar para qué tipo de comportamiento es óptimo la aplicación de dicho modelo y, de forma complementaria en cuáles no es recomendable.



-
- Analizar la eficiencia de dicha estrategia en la etapa COVID (2020-01-01 a 2020-06-01)
 - Analizar la eficacia del modelo para un portafolio de activos.

Todo lo anteriormente mencionado otorga argumentación sobre la factibilidad de utilizar un algoritmo genético en conjunción con los indicadores técnicos. Se ha demostrado que el uso de análisis técnico es muy útil y funcional en la generación de estrategias que maximizan el rendimiento y/o reduzcan el riesgo, con lo cual, el diseño de una estrategia basada en indicadores técnicos es una excelente aproximación para proponer un modelo de gestión del riesgo de un activo y/o portafolio, sin mencionar que mediante la inclusión de herramienta de aprendizaje automático se puede potenciar la eficacia de dicha estrategia.

En el siguiente capítulo se ahondará con más detalle en todo lo comentado hasta este punto, con la finalidad de tener una mejor comprensión de los temas y presentar las bases para desarrollar el modelo aquí propuesto.



I

Marco Teórico



Capítulo 1

El modelo de Markowitz es el modelo por antonomasia para la construcción de un portafolio óptimo, aunque actualmente existen técnicas más innovadoras, algunas de las cuales utilizan aprendizaje automático, se considera el modelo de Markowitz como el modelo de referencia.

Otro apartado a tener en cuenta al momento de invertir en mercado de valores, es la estrategia con la cual se va a operar. Dicha estrategia puede estar basada en indicadores técnicos (análisis técnico), y/o utilizar un algoritmo de aprendizaje automático. Esto debido a que el análisis y pronóstico de los precios es una tarea compleja.

A continuación se realizará una breve descripción del modelo de Markowitz, así como las técnicas que se utilizarán para definir la estrategia de *trading*.

1.1 Modelo de Markowitz

Markowitz (1952) reconoció que ante la asignación de la riqueza entre varios activos de riesgo, el inversor debe enfocarse en el rendimiento esperado y el riesgo procedente de las combinaciones de los rendimientos del portafolio. La varianza total del portafolio depende de la varianza de los rendimientos de los activos individuales que conforman el portafolio y de sus covarianzas.

Un inversionista racional escogerá un portafolio que eficientemente otorgue mayor rendimiento y menor riesgo. No todos los portafolios que un inversionista puede crear cumplen con esta característica de eficiencia en este sentido (Pennacchi, 2008). Los rendimientos esperados y las covarianzas de los rendimientos de los activos individuales, Markowitz resolvió dicho problema de eficiencia, desarrollando el portafolio eficiente. Es decir, para un cierto nivel de riesgo se obtiene el portafolio que tiene el mayor rendimiento (frontera eficiente) conformados por los activos en cuestión.

Por lo tanto, el modelo de Markowitz consiste en encontrar el portafolio de inversión óptimo para cada inversor en términos de rentabilidad y riesgo, por lo que se basa en la optimización de los dos primeros momentos: media y varianza. Los supuestos del modelo son:

- La rentabilidad del portafolio viene dada por su esperanza matemática o media.
- El riesgo del portafolio se mide a través de la volatilidad (según la varianza o desviación típica).
- La varianza del portafolio depende de la varianza de los rendimientos que lo conforman, pero la varianza del portafolio también dependen de las covarianzas de los activos.



1.1. MODELO DE MARKOWITZ

- El inversor siempre prefiere el portafolio con mayor rentabilidad y menor riesgo, es decir, buscará para un riesgo determinado aquel que maximice sus ganancias (función de utilidad del inversor).

Sea $\bar{\mathbf{R}} = (\bar{R}_1, \bar{R}_1, \dots, \bar{R}_n)$ un vector ($n \times 1$) de los rendimientos esperados de los activos y V la matriz ($n \times n$) de covarianzas de los activos (de rango completo), la matriz de covarianza es simétrica y definida positiva. Sea $w = (w_1, w_2, \dots, w_n)$ un vector ($n \times 1$) de pesos (proporciones del portafolio) para cada activo, el rendimiento esperado queda definido como: $\bar{R}_p = w' \bar{\mathbf{R}}$, si se considera la tasa libre de riesgo:

$$E(R_p) = \bar{R}_p = R_f + w'(\bar{\mathbf{R}} - eR_f) \quad (1.1)$$

donde e es un vector de $n \times 1$ de unos y con varianza: $\sigma_p^2 = w' V w$. Entonces el problema de optimización queda de la siguiente manera:

$$Max \rightarrow E(R_p) = \sum_{i=1}^n w_i E(R_i) \quad (1.2)$$

Sujeto a las restricciones:

$$V(R_p) = \sum_{i=1}^n \sum_{j=1}^n w_i w_j Cov(R_{ij}) \quad (1.3)$$

$$\sum_{i=1}^n w_i = 1 \quad o \quad e w' = 1 \quad (1.4)$$

$$w_i \geq 0 \quad \forall i \in \{1, 2, \dots, n\} \quad (1.5)$$

Lo anterior representa la restricción paramétrica, presupuestaria y de no negatividad, respectivamente.

La frontera eficiente dada por la línea \bar{R}_p puede ser replicada por un portafolio que conste solamente de un activo sin riesgo y un portafolio en la frontera del activo de riesgo, dicho portafolio está determinado por una línea tangente a esta frontera (Figura 1.1 - Panel A), cuyo intercepto es R_f (activo libre de riesgo). ω^A denota el portafolio de activos de riesgo determinado por la línea tangente, donde \bar{R}_A y σ_A son el rendimiento esperado y la volatilidad (desviación estándar del rendimiento) en la línea tangente respectivamente.

Se asume que todos los inversionistas escogerán mantener activos de riesgo en las mismas proporciones relativas al portafolio tangente ω^A . Los inversionistas sólo van a diferir en la cantidad de riqueza que alojarán en el portafolio con activos de riesgo con respecto al activo libre de riesgo.

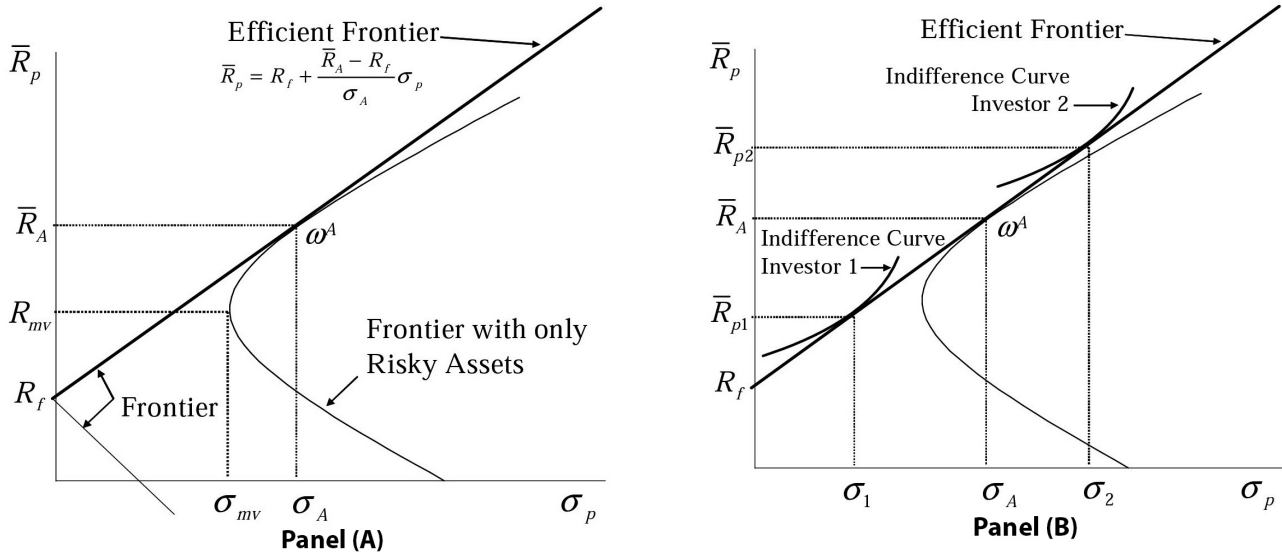


Figura 1.1: Frontera Eficiente y elección del portafolio (Fuente: Pennacchi, 2008)

La proporción de la riqueza total de un inversionista mantenida en el portafolio tangente $e'w^*$, se incrementa conforme se vaya moviendo a la derecha (Figura 1.1 - Panel B). En el punto $(\sigma_p, \bar{R}_p) = (0, R_f)$, $e'w^*$ toda la riqueza está invertida en la tasa libre de riesgo R_f . Entre los puntos $(0, R_f)$ y (σ_A, \bar{R}_A) sería el caso si el *inversionista 1* tuviera una curva de indiferencia tangente a la frontera eficiente en el punto (σ_1, \bar{R}_{p1}) , entonces $0 < e'w^* < 1$ y las proporciones positivas de la riqueza son invertidas en la tasa libre de riesgo y en el portafolio tangente. En el punto, $e'w^*$ la riqueza es invertida en su totalidad en el portafolio.

Finalmente, a la derecha del punto anterior, que sería el caso en donde la curva de indiferencia del *inversionista 2* fuera tangente a la frontera eficiente en el punto (σ_2, \bar{R}_{p2}) , entonces $e'w > 1$. Esto implica una proporción negativa en la riqueza en la tasa libre de riesgo, la interpretación es que el *inversionista 2* pide prestada a la tasa libre de riesgo, para que de esta forma se invierta más del 100% de la riqueza en el portafolio tangente.

Una práctica común en el mundo del *trading* es el rebalanceo del portafolio cada cierto periodo, por lo que se puede aplicar el modelo de Markowitz cada cierto periodo para rebalancear el portafolio de forma óptima y de esta manera mantener el nivel de riesgo del portafolio constante a lo largo del tiempo.

Se podría considerar que la primera etapa para invertir en el mercado de valores consiste en la selección y construcción de un portafolio, para el cual se tiene que determinar la distribución óptima del capital a invertir a través de los activos que lo conforman, esta problemática es resuelta por el modelo de Markowitz. La segunda etapa está relacionada con las transacciones realizadas en el periodo de inversión con el objetivo de mantener la rentabilidad del portafolio y reducir su riesgo, para esto se hacen uso de herramientas y modelos cuantitativos.

Antes de poder hablar de dichas herramientas, es necesario enunciar las dificultades que existen en torno al análisis y pronóstico de los precios de los activos financieros, y porque esta tarea es considerada compleja.



1.2 Complejidad en los proceso de pronóstico

El interés de las recientes investigaciones de esta área se han concentrado en temas relacionados con las predicciones de los movimientos de los precios de las acciones, los cuales han generado investigaciones demasiado desafiantes y exigentes. Investigadores, comunidades empresariales y usuarios interesados, que asumen que la ocurrencia futura depende de datos presentes y pasados, están interesados en identificar la predicción de movimientos del precio de las acciones en los mercados de valores (Shamsuddin & Kim, 2003). Sin embargo, los datos financieros se consideran datos complejos para pronosticar.

Los precios de los activos están determinados por las preferencias de riesgo de los inversores y por las distribuciones de los pagos futuros de los activos. Los economistas se refieren a estas dos bases de los precios como los “gustos” de los inversores y las “tecnologías” de la economía para generar la rentabilidad de los activos (Pennacchi, 2008).

A diferencia de un bien o servicio, un activo no proporciona un beneficio de consumo para un individuo. Más bien, un activo es un vehículo para ahorrar. Es un componente de la riqueza financiera de un inversor, que representa un derecho sobre un futuro consumo o poder adquisitivo. La principal distinción entre activos es la diferencia en sus beneficios futuros. Con excepción de los activos que pagan un rendimiento sin riesgo, los pagos de los activos son aleatorios (Pennacchi, 2008).

Una posible medida del atractivo de un activo es el valor promedio o esperado de su rendimiento. Suponga que un activo ofrece un único rendimiento aleatorio en una determinada fecha futura, y este pago tiene una distribución discreta con n resultados posibles (x_1, x_2, \dots, x_n) y sus correspondientes probabilidades (p_1, p_2, \dots, p_n) , donde $\sum_{i=1}^n p_i = 1$ y $p_i \geq 0$. Entonces el pago esperado es $\bar{x} = E[X] = \sum_{i=1}^n p_i x_i$. Por lo que el rendimiento esperado de un activo se puede considerar como una variable aleatoria, por lo que se han creado diversos modelos de predicción basados en procesos estocásticos. Lo anterior dificulta en gran medida la predicción del precio de un activo, ya que los patrones que sigue el comportamiento de sus precios son “aleatorios” (Pennacchi, 2008).

El pronóstico de los precios del mercado se considera problemático y, como se explica en las hipótesis de mercado eficiente (*Efficient Market Hypothesis* - “EMH” por sus siglas en inglés), que fue propuesto por Eugene F. Fama (1991), se considera que la EMH cierra la brecha entre la información financiera y el mercado financiero. También afirma que las fluctuaciones en los precios son solo el resultado de información y, que toda la información disponible se refleja en los precios del mercado. La EMH establece que los activos se encuentran en todo momento en equilibrio y son difíciles de especular para los inversionistas.

La predicción del mercado de valores se ha estudiado durante décadas, la hipótesis del mercado eficiente (EMH) afirma que los cambios de precio en el mercado de capitales pueden ocurrir de forma independiente. Además, varios estudios empíricos han demostrado que las predicciones del mercado de valores son posibles hasta cierto punto (J. H. Kim, Shamsuddin, & Lim, 2011; Kumar & Murugan, 2013; Tay & Cao, 2001). La EMH se puede dividir en tres tipos según el nivel de reflejo de la información del mercado, las cuales son: débil, semi-fuerte y fuerte (Armano, Marchesi, & Murru, 2005). Entre los tres tipos de EMH que existen, este estudio asume una EMH débil, que solo se refiere a los datos anteriores de negociación del mercado.

Además de comprar y vender acciones en los mercados de valores, cada acción no solo se caracteriza por su precio, sino también por otras variables como el precio de cierre que representa la variable más importante para predecir el precio del día siguiente para una acción específica. Existe también una relación y un



1.3. INDICADORES TÉCNICOS

comportamiento específico entre todas las variables que afectan las fluctuaciones de precio a lo largo del tiempo. Diferentes factores económicos, como: la estabilidad política y otras circunstancias imprevisibles, son variables que se han considerado para las predicciones del precio de las acciones (Ou & Wang, 2009).

De ahí deriva el hecho de que pueden existir variables subyacentes y/o complementarias al precio que ayuden a pronosticar el precio futuro, y por ende la formulación de un modelo predictivo más robusto y certero, como podrían ser los indicadores técnicos. Los estudios pasados generalmente empleaban técnicas estadísticas y de aprendizaje automático para pronosticar los valores financieros futuros. Las técnicas tradicionales de predicción del mercado de valores,- basadas en métodos estadísticos-, se generan mediante un proceso lineal (Hsieh, Hsiao, & Yeh, 2011).

El análisis estadístico basado en datos histórico, como: el modelo de promedio móvil integrado autorregresivo (ARIMA), el modelo de heterocedasticidad condicional autorregresiva (ARCH) y, el modelo de heterocedasticidad condicional autorregresiva generalizada (GARCH); se han utilizado ampliamente para hacer predicciones sobre el mercado (Engle, 1982; Franses & Van Dijk, 1996; Karolyi, 1995; Rao, 1972). Sin embargo, los sistemas de predicción basados en métodos estadísticos no funcionan bien y tienen sus propias limitaciones al requerir más datos históricos para cumplir con los supuestos estadísticos, como los postulados de normalidad (Wei & Cheng, 2012), por mencionar alguno.

Dado que los mercados de valores se consideran sistemas dinámicos no lineales y no paramétricos (Abu-Mostafa & Atiya, 1996), los métodos más flexibles que pueden aprender la dimensionalidad compleja, son esenciales para mejorar el rendimiento de la predicción. Las técnicas de aprendizaje automático tienen grandes ventajas en ese sentido, porque pueden extraer relaciones no lineales entre datos sin conocimiento previo de los datos de entrada (Atsalakis & Valavanis, 2009).

Estas técnicas se han adoptado ampliamente con relativo éxito en la realización de pronósticos del mercado de valores (E. Chong, Han, & Park, 2017). Entre las redes neuronales artificiales y las máquinas de vectores de soporte son las técnicas más populares para pronosticar series de tiempo financieras, ya que pueden asimilar el comportamiento ruidoso de los datos sin imponer restricciones estadísticas (Tay & Cao, 2001).

Los resultados empíricos muestran que las técnicas de aprendizaje automático producen un rendimiento excepcional en comparación con los modelos estadísticos (Adebiyi et al., 2014; De Faria, Albuquerque, Gonzalez, Cavalcante, & Albuquerque, 2009), ya que tienen una mejor capacidad para aprender las relaciones ocultas entre los factores del mercado y capturar los patrones complejos en los datos (K. Kim & Han, 2000).

1.3 Indicadores Técnicos

En términos del *trading* financiero, los analistas de la industria (generalmente denominados “quants”) han desarrollado indicadores que se utilizan para identificar los momentos más adecuados para abrir y cerrar operaciones y, son posiblemente las herramientas más populares que se utilizan actualmente en el mercado.

Los indicadores técnicos se han utilizado como entradas a los modelos de aprendizaje de máquina para encontrar patrones no observables o relaciones entre ellos, con el fin de predecir precios futuros, tendencias o un porcentaje de confianza en estas predicciones. Con la posible excepción de los promedios a largo plazo, estos indicadores técnicos se construyen utilizando información de precios en períodos cortos del pasado, no más de 20-30 períodos comerciales para incorporar el comportamiento histórico en un solo valor.



El período de negociación seleccionado es parte de la estrategia de *trading* y puede variar en función de la frecuencia de muestreo, de un día a un minuto, o incluso ventanas de tiempo más pequeñas, como en el caso del *trading* de alta frecuencia (Gerlein, McGinnity, Belatreche, & Coleman, 2016).

Existen principalmente cuatro tipos de indicadores: Tendencia, Momento (osciladores), Volatilidad y, de Volumen

- **Tendencia:** Son usados para indicar la dirección del mercado, esto es, la dirección de la tendencia.
- **Momento:** Indican qué tan fuerte es la tendencia (fuerza y/o velocidad de un movimiento) y son muy útiles para identificar una posible reversión en la tendencia (cambio de dirección). La mayoría de los indicadores de momento son osciladores que muestran zonas de “sobrecompra” o “sobreventa”.
- **Volatilidad:** Indican cuánto está cambiando/oscilando el precio en un periodo determinado, es decir, representan la volatilidad presente en el mercado. La baja volatilidad representa pequeños movimientos de precios, la alta volatilidad grandes movimientos de precios. Cuanto mayor sea la volatilidad, más rápido cambiará el precio, y es importante destacar que no dice nada sobre la dirección del mercado, solo sobre el rango de precios. La alta volatilidad también sugiere que existen ineficiencias de precios en el mercado.
- **Volumen:** Indican como el volumen está cambiando a través del tiempo, nos dice cuántas unidades están siendo compradas/vendidas. Por lo general, son muy útiles para confirmar cambios de tendencia o las señales generadas por una ruptura (“breakout”) en el mercado. Esto es útil porque cuando cambia el precio, el volumen da una indicación de qué tan fuerte es el movimiento. Es más probable que se mantengan los movimientos alcistas en volúmenes altos que en los de volumen bajo.

Es importante recalcar que ningún indicador es perfecto y todos pueden arrojar falsas alarmas, por lo que la verdadera utilidad de estos, estriba en la interpretación que se realice con base a las pautas recomendadas.

Para tener una estrategia óptima es necesario utilizar varios indicadores para complementar el análisis y, de esta manera robustecer la decisión, minimizar las falsas alarmas y, limitaciones que tiene cada indicador.

Debido a lo anterior, se utilizaron varios indicadores de diferentes categorías. En el siguiente capítulo se presentan los indicadores técnicos seleccionados y la aplicación de estos para el modelo y la estrategia.

1.4 Métodos de Cuantificación del Riesgo

El aumento de las actividades comerciales y las grandes carteras mantenidas por los participantes en los mercados financieros han hecho que la medición del riesgo de mercado sea una de las principales preocupaciones para los reguladores y los administradores de riesgos. Coordinado por el Comité de Supervisión Bancaria de Basilea, los bancos están obligados a mantener una cierta cantidad de capital frente a movimientos adversos del mercado.

1.4.1 Valor en Riesgo (VaR)

La metodología de valor en riesgo (VaR) promovida y difundida por JP Morgan en 1994, se considera como un nivel de referencia (Benchmark) y un estándar de los mercados financieros (De Lara Haro, 2005), lo que permite comparar la exposición de riesgos de mercado entre diversas instituciones.



El VaR es una medida estadística de riesgo de mercado que estima la “pérdida máxima” que podría registrar un portafolio en un intervalo de tiempo y con cierto nivel de probabilidad o confianza.

Es importante destacar que la definición de valor en riesgo es válida únicamente en condiciones normales de mercado, ya que en momentos de crisis y turbulencia la pérdida esperada se define por pruebas de estrés o valores extremos.

En una empresa o institución financiera, los miembros del consejo de administración son quienes deben definir 2 aspectos fundamentales para el cálculo del VaR: el nivel de confianza y el horizonte de tiempo con el que se va a calcular. El Banco Internacional de Liquidaciones (BIS) recomienda definir 99% de nivel de confianza (cuantil 0.01 de la distribución de rendimientos), sin embargo, JP Morgan recomienda 95%.

Desde un punto de vista estadística, el VaR es el cuantil asociado a un percentil específico (comúnmente 0.05 o 0.01) de la función de densidad de los rendimientos de un activo (Figura 1.2). Por lo que la interpretación bajo este contexto es: el 5% (dependiendo el percentil que se elija el VaR) de los periodos durante el horizonte de inversión se tendrá un pérdida de al menos el VaR.




Figura 1.2: Representación estadística del VaR y CVaR (Fuente: Elaboración propia).

Como se observa, el VaR no otorga certidumbre con respecto a las pérdidas que se podría sufrir en una inversión, sino una expectativa de resultados basada en estadística (datos históricos de la serie de tiempo) y en algunos supuestos de los modelos o parámetros que se utilizan en el cálculo.

Para entender este concepto, a continuación se presenta un ejemplo: un inversionista tiene un portafolio de activos con un valor de 10 millones de pesos, cuyo VaR diario es de \$250,000 pesos al 95% de confianza, esto significa que la máxima pérdida esperada en un día será de \$250,000 pesos en 19 días de cada 20. En otras palabras, solo un día de 20 días de operación en condiciones normales, la pérdida que ocurrirá será de al menos \$250,000 pesos.

Existen principalmente dos metodologías para el cálculo del VaR: los métodos paramétricos y los no



paramétricos. EL primero tiene como característica el supuesto de que los rendimientos del activo en cuestión se distribuyen de acuerdo con una curva de densidad de probabilidad normal, por lo que la fórmula para calcularlo es la siguiente:

$$VaR = Z_{1-\alpha} \cdot S \cdot \sigma \cdot \sqrt{t} \quad (1.6)$$

Donde S : Monto total a invertir, σ : Desviación estándar de los rendimientos, t : Horizonte de tiempo para el VaR.

En el caso de tener un portafolio de activos, la formula anterior se generaliza de la siguiente forma:

$$VaR_p = Z_{1-\alpha} \cdot S \cdot \sigma_p \cdot \sqrt{t} \quad (1.7)$$

Donde σ_p es la varianza del portafolio de activos, su cálculo involucra la matriz de covarianzas de los activos que conforman el portafolio.

El método no paramétrico o de simulación histórica consiste en utilizar una serie histórica de precios de la posición de riesgo para construir una serie de tiempo de precios y/o rendimientos simulados o hipotéticos, con el supuesto de que se ha conservado el portafolio durante el periodo de tiempo de la serie histórica.

Para aplicar esta metodología se deben identificar primero los componentes de los activos de portafolio y reunir los datos de los precios considerando un periodo que oscile entre los 250 y 500 observaciones. A partir del histograma de los rendimientos se calcula el cuantil correspondiente de dicha distribución (percentil 0.05 si el nivel de confianza elegido es del 95%).

1.4.2 Críticas al VaR

El VaR ha suscitado muchas críticas como medida de riesgo. Suele ser criticado por no tener en consideración la magnitud de las pérdidas cuando se supera el VaR, como medida riesgo puede fallar en estimular la diversificación debido a su característica de no subaditividad (Rootzén, 1999) y que el VaR solo proporciona una estimación puntual de la distribución de pérdidas. La estimación del VaR no proporciona ninguna información sobre las pérdidas en la cola que exceden el VaR, es decir, información sobre los llamados "picos", los eventos de la empresa (baja probabilidad, alta pérdida) no se capturan con el modelo. Sin embargo, la historia reciente ha demostrado que tales eventos representan una amenaza fidedigna de la realidad (Danielsson, 2001).

1.4.3 Valor en Riesgo Condicional (CVaR)

El CVaR (*Conditional Value at Risk*) por sus siglas en inglés, también es conocido como *Expected Shortfall* (ES), es una medida de riesgo utilizado en la medición del riesgo financiero para evaluar el riesgo de mercado o el riesgo crediticio de una cartera o portafolio. En términos prácticos, es el valor esperado de las pérdidas que son mayores o iguales al VaR (Figura 1.2).

$$CVaR = E[x|x \leq VaR] \quad (1.8)$$



El CVaR cuantifica las pérdidas que exceden el VaR y actúa como una cota superior para el VaR. Por lo tanto, portafolios con un bajo CVaR también tienen bajo VaR.

El CVaR así definido es una representación convenientemente simple del riesgo, aplicable a distribuciones de pérdida no simétricas, que tiene en cuenta los riesgos más allá del VaR y es convexa. Además, es una medida coherente de riesgo, ya que satisface la invarianza traslacional, la homogeneidad positiva, la monotonicidad y, lo que se considera mucho más importante, satisface la subaditividad ([Franco Arbeláez, 2005](#))

1.5 Algoritmos de Aprendizaje Automático

Las predicciones financieras que incorporan enfoques de aprendizaje automático construyen los conjuntos de datos de entrenamiento, prueba y, fuera de muestra como una colección de casos que utilizan indicadores técnicos populares. Por lo tanto, normalmente se crea una instancia utilizando el valor del precio actual y los valores instantáneos de los indicadores mencionados, generando una imagen estática de la situación del mercado para el momento exacto en que se construye la instancia.

En este escenario, cada instancia, los precios y sus correspondientes indicadores técnicos, son utilizados como atributos. Se convierte en sí mismo en un ejemplo independiente del problema que evita la dependencia del tiempo en la serie, abordando el problema como una simple tarea de clasificación, en lugar de un análisis de las series, en el sentido estricto de la palabra.

La hipótesis en este caso, es que una vez que se entrena un modelo de aprendizaje automático, puede ser capaz de clasificar/pronosticar instancias individuales utilizando los indicadores técnicos como atributos. Debido al hecho de que esas instancias invisibles representan a su vez las circunstancias invariantes del mercado en determinados momentos y que el resultado de la tarea de clasificación/pronóstico se puede interpretar como un pronóstico de tendencia.

La principal implicación de esta hipótesis es que el pronóstico financiero puede beneficiarse del uso de técnicas de aprendizaje automático más simples en lugar de utilizar enfoques de análisis de series de tiempo complejas, simplificando el uso de recursos computacionales y, al mismo tiempo, evitando los problemas de indexación y ordenación en los conjuntos de datos ([Gerlein et al., 2016](#)).

En las predicciones de los precios de los activos, se utiliza un conjunto de datos técnicos puros, datos fundamentales y, datos derivados en la predicción de valores futuros de las acciones. Los datos técnicos puros se basan en datos de existencias anteriores, mientras que los datos fundamentales representan la actividad de las empresas y la situación del mercado.

Mediante la combinación de los enfoques de clasificación de minería de datos en la predicción de los precios de un activo, el modelo proporciona un valor futuro para cada entidad desconocida de los valores de las acciones de las empresas en función de los datos históricos. Este pronóstico utiliza varios métodos de enfoques de clasificación, como: redes neuronales, regresión, algoritmo genético, inducción del árbol de decisión y, k-vecinos más cercanos (KNN). El conjunto de datos se divide en dos grupos para realizar el aprendizaje: conjunto de datos de entrenamiento y conjunto de prueba ([Ian H. Witten & Hall, 2011](#)).



1.6 Algoritmo Génético

Los algoritmos genéticos pertenecen a una clase de algoritmos de aprendizaje automático que se han utilizado con éxito en varias áreas de investigación. Hay un interés creciente en su uso en economía financiera, pero hasta ahora ha habido poco análisis formal. A su vez, los algoritmos genéticos constituyen una clase de búsqueda, adaptación y optimización de técnicas basadas en los principios de la evolución natural.

Un algoritmo evolutivo mantiene una población de candidatos como solución y evalúa la calidad de cada solución candidata de acuerdo con un problema específico (Función fitness), que depende del entorno para la evolución. Los candidatos para la nueva solución se crean seleccionando relativamente n miembros de la población y recombinándolos a través de varios operadores. Por lo que los algoritmos evolutivos aplicados a distintos problemas difieren entre sí en la representación de las soluciones, el mecanismo de selección y los detalles de los operadores de recombinación.

En un algoritmo genético, los candidatos a ser la solución se representan como una cadena de caracteres (cromosomas) de un alfabeto dado (a menudo binario). En un problema particular, el mapeo entre estas estructuras genéticas, la solución original y el espacio debe ser desarrollado, y se debe definir una función de aptitud (fitness). La función de aptitud mide la calidad de la solución correspondiente a una estructura genética. En un problema de optimización, la función aptitud simplemente calcula el valor de la función objetivo.

El algoritmo genético comienza con una población de solución generada aleatoriamente (candidatos). La próxima generación se crea recombinando candidatos prometedores. La recombinación (crossover) involucra a dos padres elegidos al azar de la población, con las probabilidades de selección sesgadas a favor de aquellos con mejores aptitudes (selección), los padres se recombinan a través de un operador "crossover", que divide las dos estructuras genéticas (de los padres) en ubicaciones elegidas al azar, y las combina para formar a los hijos (nueva generación).

Posteriormente, se puede realizar una mutación, la cual consiste en alterar la estructura genética de algunos hijos de forma aleatoria. Este proceso se realiza varias veces hasta obtener un número determinado de individuos, los cuales se consideran como la nueva generación. Posteriormente se vuelve a evaluar la generación para obtener las aptitudes de cada individuo y determinar los candidatos prometedores para formar la nueva generación.

Este proceso se realiza varias veces hasta un número determinado de generaciones o hasta que se converga a la solución óptima. También se puede introducir el concepto de elitismo, el cual consiste en considerar a los mejores candidatos de la generación anterior para formar parte de la nueva generación. De esta manera se evita desechar soluciones prometedoras entre cada iteración.

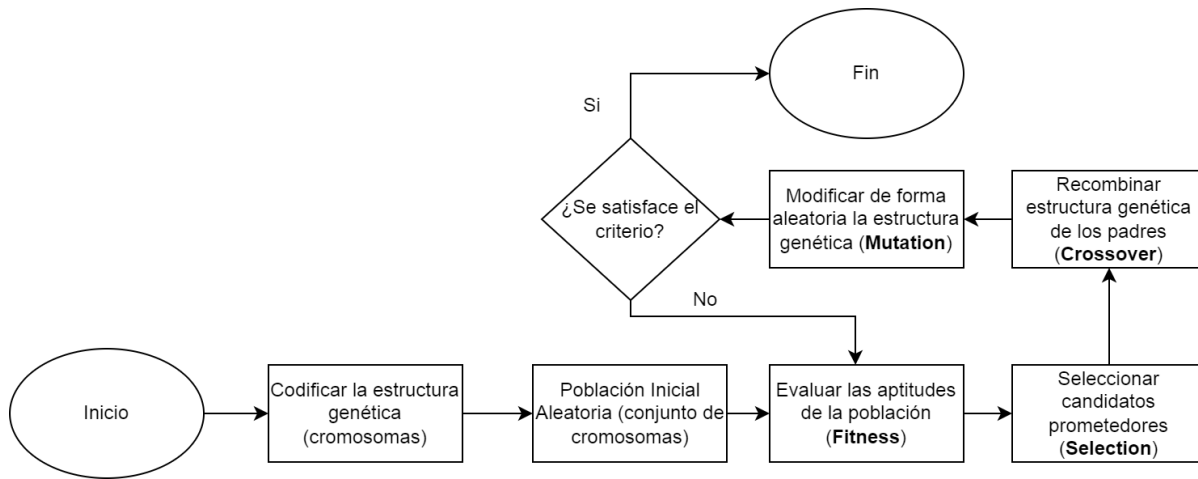


Figura 1.3: Diagrama de flujo de un algoritmo genético (Fuente: Elaboración propia).

La base teórica de los algoritmos genéticos se expone en mantener una población de posibles soluciones hace que el proceso de búsqueda sea paralelo, lo que permite una exploración eficiente del espacio de la solución (Holland, 1976). Además de este paralelismo explícito, los algoritmos genéticos son implícitamente paralelos en el sentido de que la evaluación de la idoneidad de una estructura genética específica proporciona información sobre la calidad de una gran cantidad de esquemas o bloques de construcción.

El llamado teorema del esquema muestra que un algoritmo genético asigna automáticamente un número exponencialmente creciente de ensayos con los mejores esquemas observados. Esto conduce a un intercambio favorable entre la explotación de direcciones prometedoras del espacio de búsqueda y exploración de regiones menos frecuentadas del espacio (Vose, 1991). Sin embargo, no existe un resultado general que garantice la convergencia de un algoritmo genético al óptimo global.

Los algoritmos evolutivos ofrecen una serie de ventajas sobre los más tradicionales métodos de optimización. Se pueden aplicar a problemas con un elemento no diferenciable o función objetivo discontinua, a la que métodos basados en gradientes como Gauss-Newton no sería aplicable. También son útiles cuando la función objetivo tiene varios óptimos locales. Debido a la naturaleza estocástica de los operadores de selección y recombinación, los algoritmos evolutivos son menos probables a converger a los máximos locales que los métodos de escalada o de tipo gradiente.

En informática, hay un gran conjunto de problemas, que representan un alto costo computacional (NP). Esto esencialmente significa que, incluso los sistemas informáticos más potentes, tardan mucho tiempo (incluso años) en resolver un problema muy complejo. Aquí es donde radica principalmente la ventaja de los algoritmos genéticos, ya que son una herramienta eficiente para proporcionar soluciones casi óptimas en un corto período de tiempo.

Existen diversas estrategias basadas en indicadores técnicos para gestionar las transacciones de los activos que conforman un portafolio, todos estos indicadores dependen de parámetros, por lo que el encontrar la combinación óptima de estos para obtener los mayores rendimientos no es una tarea sencilla.

El uso del algoritmo genético puede ser una solución para encontrar la combinación de parámetros que



1.6. ALGORITMO GÉNÉTICO



más se acerquen a maximizar el rendimiento, a su vez que otorga la posibilidad de analizar millones de combinaciones (tareas complejas) con un costo computacional relativamente bajo.

Por lo que antes de implementar dicha estrategia con el algoritmo genético es necesario tener conocimiento de algunos indicadores técnicos, para seleccionar aquellos que mejor se adapten al activo financiero en cuestión y al tipo de estrategia deseada por el inversionista.



II

Aplicación Indicadores Técnicos



Capítulo 2

En este capítulo se ahondará en los indicadores técnicos que se usarán en la estrategia de “trading”, como ya se mencionó estos son: medias móviles, MACD y RSI. Se eligió dichos indicadores ya que son de los más conocidos y muchas estrategias de “trading” suelen hacer uso de estos. A su vez, su cálculo y uso es realmente sencillo, por lo que son candidatos perfectos para adaptarlos con el algoritmo genético.

Cada uno de estos indicadores técnicos están compuestos de diversos parámetros, lo cuales, dependiendo de sus valores se puede llegar a distintas conclusiones en función de su uso. Por lo que la decisión de elegir la combinación correcta de parámetros no suele ser una tarea sencilla, los parámetros óptimos de un activo no serán necesariamente los óptimos para otro activo, ni permanecerán siendo los mismo para un mismo activo, debido al comportamiento altamente dinámico y volátil que presentan los activos financieros.

Es aquí donde entre el algoritmo genético, mediante dicho algoritmo se pretende encontrar la combinación óptima de parámetros que maximice el rendimiento en un cierto periodo (entrenamiento), para posteriormente hacer uso de dichos parámetros en el futuro.

2.1 Indicadores de Tendencia

Los indicadores de tendencia se utilizan para detectar las tendencias en los mercados financieros. Este grupo de indicadores es ineficiente para los períodos de equilibrio (Flat) del mercado. Los indicadores de tendencia indican a la dirección del movimiento del precio.

2.1.1 Medias Móviles

Tiene una expresión general:

$$MA_n = \frac{\sum_{i=1}^n w_i \cdot p_i}{\sum_{i=1}^n w_i} \quad (2.1)$$

En la forma más simple, una regla de cruce de medias móviles opera bajo el supuesto de que las señales de compra se generan cuando el precio actual del activo cruza su media móvil desde abajo, mientras que las señales de venta se generan cuando el precio del activo cruza su media móvil desde arriba (Brock, Lakonishok, & LeBaron, 1992). A continuación se muestra la formula para el cálculo de una media móvil simple:



2.1. INDICADORES DE TENDENCIA

$$SMA_k = \frac{p_{n-k+1} + p_{n-k+2} + \dots + p_n}{k} = \frac{1}{k} \sum_{i=n-k+1}^n p_i \quad (2.2)$$

El fundamento de esta interpretación es que surge una tendencia cuando el precio del activo penetra en la media móvil. Específicamente, surge una tendencia alcista (alcista) cuando el precio sube por encima de su media móvil, mientras que surge una tendencia a la baja (bajista) cuando el precio cae por debajo de su media móvil.

Existen numerosas variaciones de esta regla básica de cruce. Por ejemplo, señales de compra y venta pueden ser detectadas por el cruce de una media móvil de larga plazo por una de corta plazo, es decir, utilizando dos medias móviles (Fong & Yong, 2005).

A su vez se pueden proponer tres medias móviles para efectuar las señales de compra y venta: Una de largo plazo, otra de mediano plazo y por último una de corto plazo. Esta situación se puede generalizar hasta n medias móviles, donde las reglas de compra y venta se basan en el cruce de éstas.

Otra variación es imponer algún tipo de filtro para eliminar las señales falsas, es decir, señales que resultarían en pérdidas. Un filtro común es un filtro de banda de porcentaje fijo para comprar solo cuando la señal de compra excede la media móvil en un porcentaje fijo, digamos 1%, y vender solo cuando la señal de venta caiga por debajo de la media móvil en el mismo porcentaje (Brock et al., 1992).

La capacidad de una media móvil para revelar una tendencia de los precios depende de la longitud de la “ventana”, es decir, el número de periodos que se utiliza para calcular la media móvil. Cuanto más largo sea el período de ventana, más suavizada será la tendencia resultante de los precios del activo.

Sin embargo, una media móvil larga no responde tan rápidamente a nuevos cambios de tendencia como una media móvil corta. La elección de la ventana/periodo de la media móvil suele ser arbitrario y este es el parámetro que determina la eficacia de la estrategia de *trading* (Fong & Yong, 2005). Por lo que el número de periodos de cada media móvil es diferente para cada activo y horizonte temporal (ventana).



2.1. INDICADORES DE TENDENCIA




Figura 2.1: Aplicación Estrategia Medias Móviles para Apple (Fuente: Elaboración propia).

En el caso de tres medias móviles, se requieren de tres cruces, en los cuales para una señal de compra se requiere que al momento de un cruce el orden de las medias móviles sea el siguiente: la de corto plazo por arriba de la de mediano plazo y la de mediano plazo por arriba de la de largo plazo (Figura 2.1 - Línea verde). Para la señal de venta (Figura 2.1 - Línea roja) se necesita que la media móvil de largo plazo esté por arriba de la de mediano plazo y la de mediano plazo por arriba de la de corto plazo.

Cabe aclarar, que en la estrategia de medias móviles se pueden utilizar distintos tipos de medias móviles y/o una combinación de estas, como por ejemplo, media móvil exponencial (EMA), media móvil ponderada (WMA), etc.

$$WMA_k = \frac{k \cdot p_n + (k-1)p_{n-1} + \dots + 2p_{n-k+2} + p_{n-k+1}}{k + (k-1) + \dots + 2 + 1} \quad (2.3)$$

$$EMA_k = \frac{p_n + (1-\alpha)p_{n-1} + (1-\alpha)^2 p_{n-2} + \dots + (1-\alpha)^k p_{n-k+1}}{1 + (1-\alpha) + (1-\alpha)^2 + \dots + (1-\alpha)^k} \quad (2.4)$$

La diferencia entre estas radica en el peso que se le asigna a cada observación/precio histórico, por lo que la media móvil exponencial tiende a dar mayor importancia a los precios recientes, mientras que la simple otorga el mismo peso a cada observación. Debido a lo anterior, se puede utilizar la combinación de estas para proponer medias móviles de corto, mediano y largo plazo.



2.2 Indicadores de Momento (Momentum-Osciladores)

Mientras que los indicadores de tendencia nos sirven para conocer la dirección de la tendencia de un activo, existen otros indicadores que reflejan el impulso del precio del activo, es decir, miden la velocidad de los cambios (momentum) en los precios del activo. Usualmente se utilizan para detectar posibles puntos de giro de la tendencia.

2.2.1 Media Móvil de Convergencia/Divergencia

También llamada MACD, por sus siglas en inglés, consta de una línea rápida, una línea lenta, conocida como señal, y un histograma. La línea MACD representa un promedio móvil, el cual se obtiene de la diferencia de un promedio móvil de corto y otra de mediana/largo plazo, comúnmente de doce y veintiséis periodos respectivamente (Thorp, 2000).

$$MACD = EMA_K - EMA_M; \quad K < M \quad y \quad Señal = EMA_R \quad (2.5)$$

Mientras que la línea señal corresponde a una media móvil de corto plazo, generalmente de nueve periodos. El histograma sirve para visualizar la diferencia e interacción de las dos líneas anteriormente mencionadas (Figura 2.2).

$$Histograma = MACD - Señal \quad (2.6)$$

El MACD es un excelente indicador para confirmar tendencias, su uso consiste en computar la diferencia entre las dos líneas, cuando esta diferencia se hace pequeña se dice que está convergiendo, en caso contrario divergiendo. Cuando una nueva tendencia se empieza a formar, sucede la convergencia hasta el punto en que se suscita un cruce entre las dos líneas, que representa el cambio de tendencia (Thorp, 2000), para posteriormente volver a diverger. Cuando el cambio de tendencia sucede, el histograma desaparece. Mientras que conforme empieza a converger, el histograma empieza a disminuir, en caso de divergencia sucede lo contrario.

Por ende, se utilizó la diferencia entre las dos líneas (MACD - Señal): $X_i = MACD_i - Señal_i$ (Figura 2.3), cuando dicha diferencia sea negativa, se habla de una tendencia bajista (señal de venta), cuando es positiva, de una tendencia alcista (señal de compra), y cuando cruce por el cero, se tiene un cambio de tendencia (Thorp, 2000). De esta forma el comportamiento de esta nueva variable X captura de forma eficiente el principal uso de este indicador, así como su aplicación. Los parámetros óptimos a definir son tres: los periodos de la línea señal y la línea MACD (conformado por dos medias móviles: corta/lenta y larga/rápida).



2.2. INDICADORES DE MOMENTO (MOMENTUM-OSCILADORES)



Figura 2.2: Aplicación MACD (Fuente: Elaboración propia).




Figura 2.3: MACD como variable predictora (Fuente: Elaboración propia).



2.2.2 Índice de fuerza relativa

También llamado RSI por sus siglas en inglés, se utiliza para Identifica las condiciones de “sobrecompra” y “sobreventa” en el mercado, la interpretación y, el uso tradicional del RSI, en donde los valores de 70 o más indican que el activo está “sobrecomprado” (señal de venta) o sobrevalorado y puede estarse orquestando un cambio de tendencia o un retroceso correctivo en el precio (T. T.-L. Chong, Ng, & Liew, 2014).

Se calcula para cada día la variación porcentual al alza U o a la baja D. En un día de subida, con el precio de cierre superior al de ayer:

$$U_t = cierre_{hoy} - cierre_{ayer} \quad y \quad D_t = 0 \quad (2.7)$$

O recíprocamente, en un día de bajada (nótese que D es un número positivo):

$$D_t = cierre_{ayer} - cierre_{hoy} \quad y \quad U_t = 0 \quad (2.8)$$

Se calcula una media móvil exponencial para los valores de U y D obtenidos a lo largo del n periodos, para obtener la siguiente métrica.

$$RS_n = \frac{EMA_{U,n}}{EMA_{D,n}} \quad y \quad RSI_n = 100 - \left(\frac{1}{1 + RS_n} \right) \cdot 100 \quad (2.9)$$

Una lectura de RSI de 30 o menos, indica una condición de “sobreventa” (señal de compra) o infravalorada, por lo que existe alta posibilidad que comience una tendencia alcista. Su valor está contenido dentro de un rango de 0 a 100. Usualmente las cotas anteriormente mencionadas dan buenos resultados, aunque pueden provocar señales falsas en otros activos, por lo que lo ideal es determinar las cotas óptimas para cada activo.

Lo recomendable es utilizar 14 periodos (Wilder, 1978), por lo que el verdadero reto está en **determinar el valor de las cotas de las áreas de “sobrecompra” y “sobreventa”**, ya que la eficiencia de este indicador tiende a variar según los valores que se determinen para cada activo.

Por ejemplo, en la figura 2.4 se observa que el RSI cruza por arriba de la línea roja (región de sobreventa) alrededor de mayo del 2020, por lo que es indicio de que la tendencia del activo puede cambiar, así que se tiene una posible señal de compra. Mientras que en septiembre el RSI cruza por debajo de la línea verde (región de sobrecompra), entonces se efectúa una señal de venta.



2.2. INDICADORES DE MOMENTO (MOMENTUM-OSCILADORES)



Figura 2.4: Aplicación RSI (Fuente: Elaboración propia)

Toda la idea detrás del RSI es elegir los máximos y mínimos para ingresar a un mercado a medida que la tendencia se invierte. El RSI también se puede utilizar para confirmar la formación de tendencias. Si el RSI está por encima del nivel $CotaInferior + \frac{RangoCotas}{2}$ (generalmente 50), es probable que el mercado esté en una tendencia alcista. Por el contrario, si la línea está por debajo de 50, es probable que el mercado se encuentre en una tendencia bajista (T. T.-L. Chong et al., 2014).

Si se tiene más aversión al riesgo, esperar la confirmación de la tendencia puede ser el camino a seguir. Es una compensación entre dos cosas; por un lado, puede obtener más ganancias al entrar en una tendencia tempranamente, pero también se equivocará más a menudo y posiblemente se perderá muchos “pips”/puntos en sus paradas.

Los tres indicadores anteriormente mencionados serán implementados en la estrategia de trading y optimizados por el algoritmo genético para la correcta gestión de un portafolio. Mediante la aplicación de estos y basado en las reglas de uso enunciadas en esta sección, se construyó una estrategia de trading para gestionar de forma individual cada uno de los activos que conforman un portafolio.



III

Descripción y Optimización del Portafolio Rebalanceado



Capítulo 3

Es necesario desarrollar un escenario de referencia para comparar la eficacia de la estrategia con el algoritmo genético, para esto se propuso elaborar un portafolio optimizado que maximice el rendimiento y minimice la varianza. Dicho portafolio se rebalanceó de forma trimestral y se evaluó el desempeño que tuvo la aplicación que tuvo de dicho portafolio, a continuación se muestran los resultados obtenidos.

3.1 Descripción del mercado

Como horizonte temporal para el análisis, se escogió el rango de fechas que parte desde el 2020-01-01 a 2021-04-01, lo cual comprende un un año y un trimestre de operación. Se seleccionó dicho horizonte ya que fue donde se suscitó la crisis sanitaria del COVID-19, la cual ocasionó una caída generalizada mundial en el mercado de capitales. Posteriormente se presentó una lenta recuperación y estabilidad en las cotizaciones en las distintas bolsas.



Figura 3.1: Comportamiento Mercado Mexicano (IPC) de 2020-01-02 a 2021-03-31 (Fuente: Elaboración Propia).



En la figura 3.1 se observa claramente que el mercado mexicano tuvo una gran corrección a principios de febrero hasta mediados de abril, para posteriormente presentar su recuperación, en donde se tiene un comportamiento lateral (o en rango) de mayo hasta noviembre. A partir de noviembre se presenta una vertiginosa recuperación, y en enero de 2021 el IPC logró alcanzar el valor máximo que se tuvo en 2020 antes de la caída.

El objetivo de este periodo es analizar la eficacia del algoritmo para adaptarse a distintos comportamientos y periodos de crisis, que sufrieron la mayoría de los activos que cotizaban en los mercados.

3.2 Activos Financieros

Es importante destacar que la recuperación y caída que tuvieron los activos no fue el mismo, algunos sectores como el tecnológico se vió altamente beneficiado por la situación de cuarentena a raíz de la pandemia, mientras que otros sectores tuvieron grandes pérdidas, y que todavía batallan en recuperar el valor que tenían a principios del 2020. A continuación se muestran los activos pertenecientes al mercado de capitales que se seleccionaron para construir el portafolio:

Cuadro 3.1: Lista de Activos que conforman el Portafolio

Emisora	Sector	Industria
APPLE	Tecnología	Electrónica de consumo
PAYPAL	Servicios Financieros	Servicios de Crédito
VOLARIS	Industriales	Aerolíneas
MGM	Consumidor Cíclico	Resorts y Casinos
ALSEA	Consumidor Cíclico	Restaurantes
WALMART	Defensivo del Consumidor	Tiendas de Descuento
BIMBO	Defensivo del Consumidor	Alimentos Envasados
GM	Consumidor Cíclico	Fabricantes de Automóviles
CEMEX	Materiales Básicos	Materiales de Construcción
GRUPO CARSO	Industriales	Conglomerados
GENTERA	Servicios Financieros	Servicios de Crédito

* Fuente: Elaboración Propia.

Se eligieron los activos retrospectivamente en función del comportamiento que tuvieron durante la crisis sanitaria del COVID 19. A su vez, se eligieron activos de distintos sectores e industrias, para tener en su mayoría dos activos por cada sector, pero especializados en diferentes industrias. De esta manera, se tiene un portafolio diversificado con respecto a las actividades económicas, y también se tiene una forma de analizar la interacción (rendimientos y volatilidad) que tuvieron con la crisis sanitaria.

En la figura 3.2 se puede apreciar el comportamiento que tuvieron a lo largo del horizonte de tiempo propuesto y el efecto que tuvo la pandemia sobre los distintos sectores. Se observa que los activos relacionados con el sector tecnológico tuvieron un excelente crecimiento durante la crisis, mientras que aquellas relacio-



3.2. ACTIVOS FINANCIEROS



nados con el turismo y servicios sufrieron un gran caída, hasta del 120% en el caso de MGM (principios de marzo).

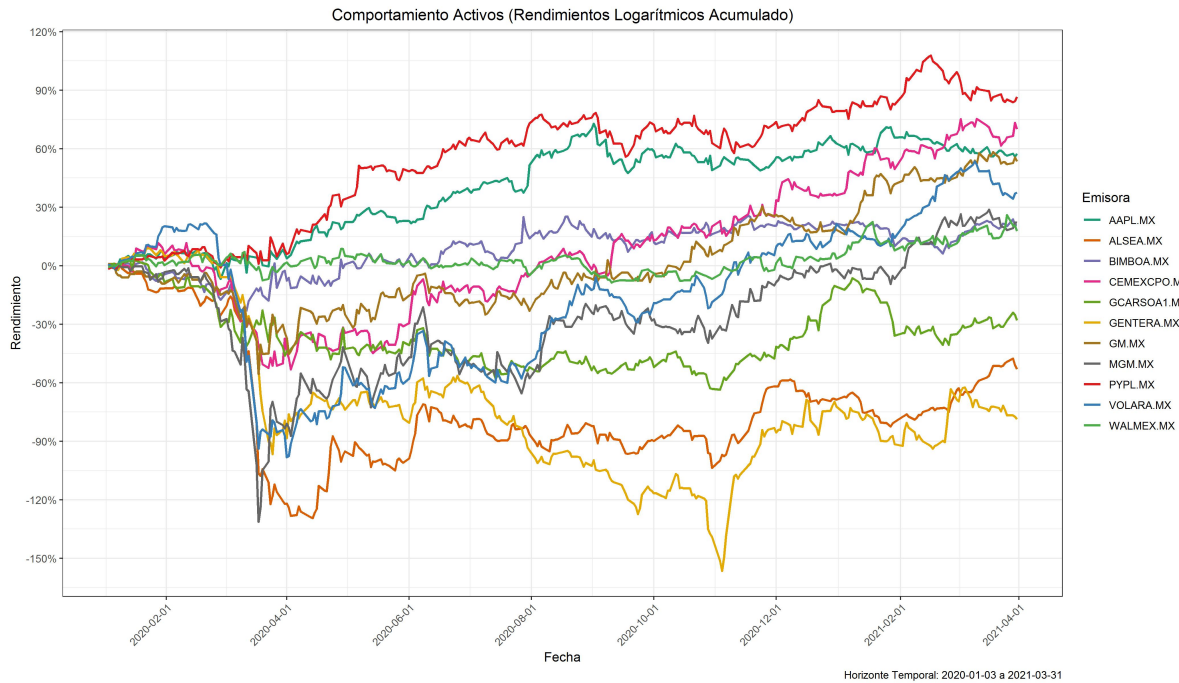


Figura 3.2: Comportamiento de los Activos que conforman el portafolio de 2020-01-02 a 2021-03-31 (Fuente: Elaboración Propia).

Los activos pertenecientes a productos de consumo como Walmart y Bimbo se mantuvieron casi constantes con ligeras oscilaciones. Con excepción de las tecnológicas, todas las empresas experimentaron un rebote y una recuperación a partir de abril. General Motors, Cemex, Volaris y MGM fueron las que tuvieron una mayor recuperación, mientras que Grupo Carso, Alsea y Gentera aún no han alcanzado sus valores antes de la crisis, aunque todas ellas presentan una tendencia alcista.

Por otra parte, las tecnológicas mermaron su crecimiento y su “momentum” a partir de agosto, disminuyendo mucho la tendencia que traían y prácticamente presentando una comportamiento en rango con una marcada corrección a partir de febrero. Todo lo contrario a lo que sucedió en los otros sectores.

Se aplicó una estrategia de análisis técnico optimizada por un algoritmo genético para cada activo y de forma conjunta (portafolio) (vease el siguiente capítulo). De esta forma, se logró estudiar para qué tipo de comportamiento es más/menos eficiente el modelo y si sería una herramienta útil para minimizar las pérdidas y/o maximizar rendimientos en periodos de crisis y de alta volatilidad. Para la tasa libre de riesgo se tomó el CETE a un año, considerando los impuestos se estableció a un rendimiento anual del 3%.



3.3 Estrategia del Portafolio Rebalanceado

Para poder analizar la eficacia del modelo (que utiliza el algoritmo genético) en forma conjunta se comparó (vease el siguiente capítulo) con una estrategia basada en optimización de portafolio del modelo de Markowitz, el cual se irá rebalanceando de forma trimestral para mantener la volatilidad del portafolio constante. En el capítulo 4 se realizó la comparación de este modelo basado en optimización de portafolio rebalanceado contra el modelo de análisis técnico con algoritmo genético.

3.3.1 Análisis Exploratorio de los Activos

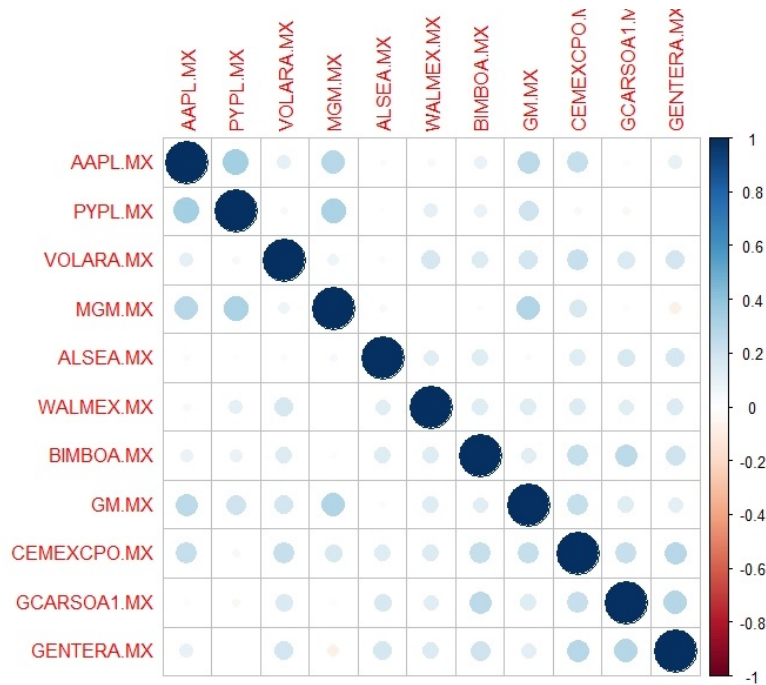


Figura 3.3: Correlación de los activos seleccionados (Fuente: Elaboración Propia).

En la Figura 3.3 se observa que no existen correlaciones significativas entre los activos, la mayoría son cercanas a cero. Al no existir correlación entre los activos y tener activos de diferentes sectores, se puede asumir que se tiene una correcta diversificación, ya que el incremento/decrementos de los precios de un activo no deberían de impactar de forma significativos en los demás activos del portafolio (siempre cuando no sea una situación sistemática).



3.3. ESTRATEGIA DEL PORTAFOLIO REBALANCEADO



Cuadro 3.2: Resumen Rendimientos Logarítmicos de los Activos de 2019 a 2020

Emisora	Rendimiento Anual %	Rendimiento Medio Anualizado %	Volatilidad Anualizada %	Sharpe Ratio Anualizado	Beta
AAPL.MX	58.65	59.12	25.78	2.18	0.42
PYPL.MX	20.14	20.3	26.45	0.65	0.33
VOLARA.MX	65.16	65.68	32.58	1.92	0.82
MGM.MX	25.2	25.4	28.12	0.80	0.29
ALSEA.MX	-2.63	-2.65	26.42	-0.21	0.57
WALMEX.MX	10.49	10.57	23.75	0.32	0.88
BIMBOA.MX	-10.93	-11.02	24.73	-0.57	0.75
GM.MX	4.71	4.75	24.35	0.07	0.45
CEMEXCPO.MX	-28.52	-28.75	32.55	-0.98	1.58
GCARSOA1.MX	-1.67	-1.68	31.44	0.15	1.05
GENTERA.MX	25.68	25.88	34.29	0.67	0.95

* Fuente: Elaboración Propia.




Figura 3.4: Riesgo vs Rendimiento (Fuente: Elaboración Propia).

Con respecto al cuadro 3.2 y a la Figura 3.4 los mejores activos del 2019 fueron Apple, Paypal, MGM y Volaris, al tener la mejor relación rendimiento/volatilidad. Como se aprecia en la Figura 3.4, los activos más volátiles no tendrían mucho sentido existiendo los anteriormente mencionados, mientras que Walmart



y General Motors son buenas elecciones para reducir la volatilidad de un posible portafolio. Así que el portafolio óptimo debe de destinar el mayor porcentaje del capital a dichos activos, sobre todo a Apple, Walmart y MGM, ya que prácticamente la mayoría tienen una volatilidad similar.

3.3.2 Construcción del Portafolio

Para el portafolio se definieron las siguientes restricciones: solo se consideran posiciones largas, se tiene que invertir todo el capital propuesto, todos los activos tienen que estar presentes en el portafolio, ningún activo puede tener más del 40% del capital a invertir, ni menos del 5%. Aunado a lo anterior, se consideró un costo de transacción del 0.25% y para la optimización del portafolio se estableció la maximización del rendimiento con una volatilidad objetivo no mayor al 2%.

Se implementó el modelo de forma trimestral mediante un rebalanceo, donde cada 3 meses con la información histórica de un año se volvió a optimizar los pesos del portafolio bajo el método de Markowitz (Figura 3.5), poniendo como objetivo una volatilidad del portafolio del 2%. Lo anterior se realizó con el objetivo de mantener la volatilidad constante durante cada periodo de rebalanceo, para que de esta forma se tenga en promedio una volatilidad del 2% a lo largo del periodo de inversión. En resumen, se utilizó la información histórica de un año para cada rebalanceo trimestral (ventana móvil, *rolling window* por sus siglas en inglés), es decir, cada trimestre que se avanzó se tomó la información de un año a partir de dicha fecha, y así sucesivamente hasta recorrer todo el periodo de inversión (2020-01-01 a 2021-04-01).

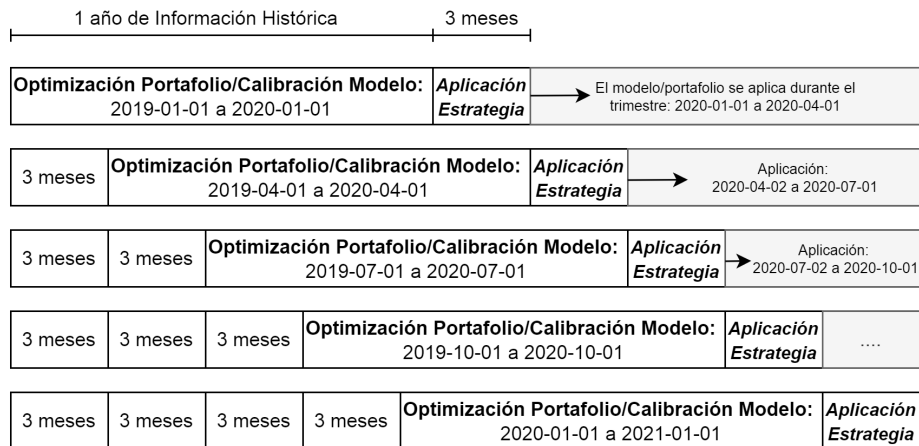


Figura 3.5: Esquema "Rolling Window" utilizado en la calibración de los modelos (Fuente: Elaboración Propia).



3.3. ESTRATEGIA DEL PORTAFOLIO REBALANCEADO

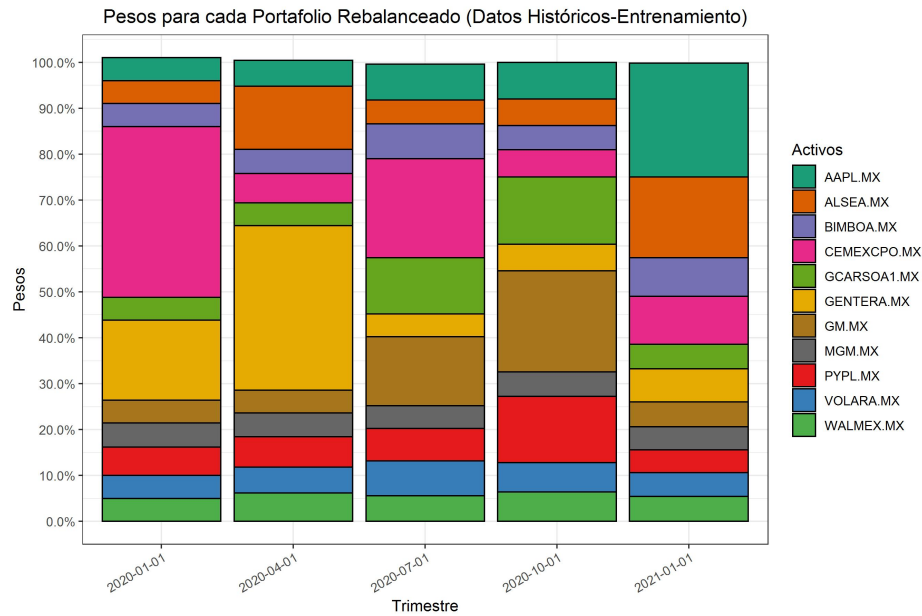


Figura 3.6: Pesos Dinámicos del portafolio según el trimestre (Fuente: Elaboración Propia).

En la Figura 3.6 se tienen los pesos (porcentaje) del capital a invertir para cada activo según el trimestre. Por ejemplo, el portafolio que comprende del trimestre uno del 2020 al trimestre dos del 2020 (2020-01-01 a 2020-04-01), se distribuyó el capital como lo muestra la primera barra de la figura 3.6. Mientras que para el último trimestre que comprendió del 2021-01-01 al 2021-04-01, se distribuyó el capital como lo muestra la última barra. Es decir, el trimestre de cada barra en la gráfica hace alusión al inicio del trimestre en el que se utilizó dicha distribución para el portafolio.

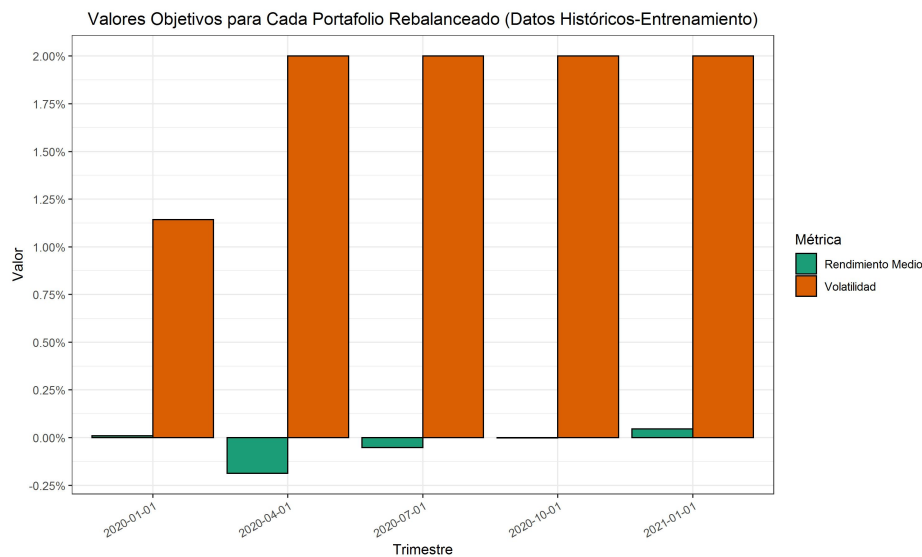


Figura 3.7: Comportamiento Volatilidad para cada periodo de rebalanceo (Fuente: Elaboración Propia).



En la Figura 3.7 se observa la volatilidad estimada del portafolio en cada trimestre para cada rebalanceo. Se espera que el comportamiento constante de la volatilidad (que se observa en la gráfica) permanezca muy similar al momento de operar con el portafolio propuesto para cada trimestre. Se observa que solo para el primer trimestre del 2020 la estimación no alcanzó el valor objetivo del 2%, aunque los demás trimestres si, por lo que se cumple el propósito de tener en promedio una volatilidad estimada del 2% a lo largo del periodo de inversión.

3.3.3 Desempeño y Evaluación del Portafolio

A continuación se describirá a fondo el desempeño que tuvo el portafolio contra el desempeño que tuvo el mercado, con el objetivo de determinar si se logró tener mejores métricas que el mercado en términos de utilidad y/o de riesgo.

Cuadro 3.3: Resumen rendimiento para cada activo durante el periodo de inversión (2020-01-01 a 2021-04-01)

Emisora	Rendimiento Medio	Volatilidad	Rendimiento/Riesgo	Rendimiento Total	VaR	CVaR
AAPL.MX	0.18%	2.38%	0.077	77.53%	-3.19%	-4.41%
PYPL.MX	0.28%	2.82%	0.098	137.67%	-3.77%	-5.00%
VOLARA.MX	0.12%	4.15%	0.029	45.50%	-7.21%	-9.33%
MGM.MX	0.07%	5.27%	0.013	24.72%	-7.06%	-7.56%
ALSEA.MX	-0.17%	3.76%	-0.045	-41.18%	-6.78%	-7.62%
WALMEX.MX	0.06%	1.91%	0.03	19.45%	-3.08%	-4.12%
BIMBOA.MX	0.07%	2.61%	0.026	23.09%	-3.56%	-4.59%
GM.MX	0.17%	3.47%	0.049	70.83%	-4.83%	-6.29%
CEMEXCPO.MX	0.22%	3.38%	0.066	101.40%	-4.82%	-6.08%
GCARSOA1.MX	-0.09%	3.10%	-0.029	-24.37%	-4.98%	-6.41%
GENTERA.MX	-0.25%	4.15%	-0.060	-54.44%	-5.41%	-8.40%

* Fuente: Elaboración Propia.

* VaR y CVaR a nivel de confianza del 95%

La tabla 3.3 muestra el comportamiento individual de los activos durante el periodo de inversión, se observa que el sector tecnológico tuvo el mayor rendimiento, siendo Paypal el mejor de toda la lista de activos, seguido por Cemex, aunque este último pertenece a otro sector. Los peores fueron Alsea y Gentera, siendo estos dos junto con Grupo Carso, los únicos activos que presentaron pérdidas.

Curiosamente el sector tecnológico no fue el que presentó mayor volatilidad, de hecho fue el segundo sector con menor volatilidad, siendo el mejor el de productos de consumo (Walmart y Bimbo), aunque estos últimos fueron los de menor ganancias, como era de esperarse.

En cuestión de riesgo (VaR y CVaR)¹ los más riesgosos fueron MGM, Volaris y Alsea, aunque los primeros dos tuvieron un buen rendimiento, sobre todo Volaris con 45.5%, siendo de los mejores rendimientos, pero no tan bueno si lo analizamos con respecto a la volatilidad que tuvo.

¹Para el cálculo de las medidas de riesgo se realizó una limpieza de los rendimientos (Boudt) y se utilizó el método modificado (Boudt, Peterson, & Croux, 2007). De esta manera se tienen estimaciones mas robustas del riesgo.



3.3. ESTRATEGIA DEL PORTAFOLIO REBALANCEADO



A continuación se presentan los resultados de aplicar el portafolio rebalanceado, y el comportamiento que tuvieron sus rendimientos durante cada trimestre que se rebalanceó.

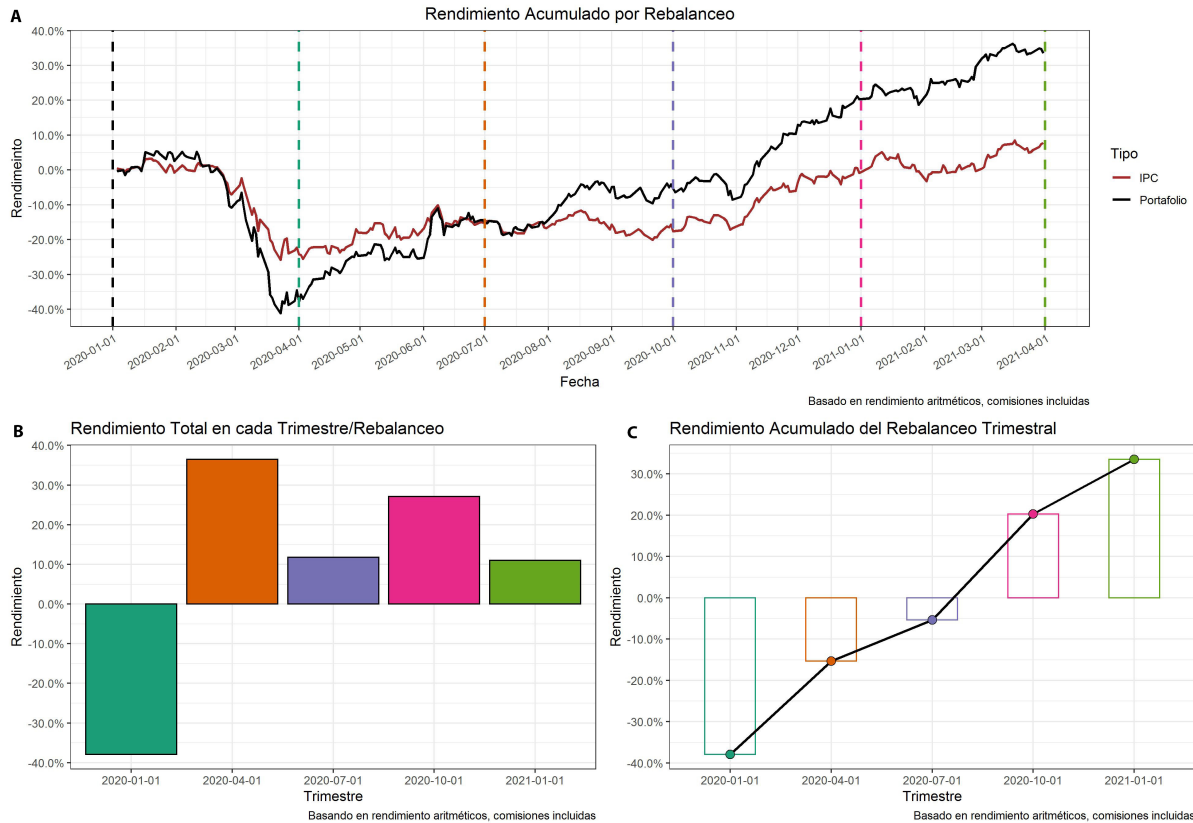


Figura 3.8: Resumen Rendimiento de los portafolios rebalanceados (Fuente: Elaboración Propia).

En la Figura 3.8 - Panel A se tiene un resumen de cómo se comportó el portafolio en la práctica. Se observa que para el primer trimestre del 2020 el portafolio sufrió pérdidas significativas y mayores que el IPC, esto ocasionado por la caída generalizada de los activos por el COVID 19. A partir de abril del 2020 el portafolio empezó a recuperarse, mientras que el IPC comenzó con un comportamiento en rango.

Para junio del 2020, el portafolio ya tenía los mismos rendimientos que el IPC, y en cuestión de dos meses empezó a tener mejores rendimientos que el IPC. A partir de septiembre del 2020 el portafolio tuvo un rendimiento muy superior al IPC durante todo el periodo de inversión, teniendo un excelente “rally” y una tendencia muy alcista. Al final del periodo de inversión (2021-04-01) esta estrategia logró en un año un rendimiento total (aritmético) del 34%, mientras que el IPC del 7% aproximadamente.

La figura 3.8 - Panel B y C muestra el rendimiento total que tuvo en cada trimestre y el comportamiento del rendimiento acumulado del portafolio para cada trimestre. El Panel A muestra el rendimiento que se tuvo en cada trimestre, mientras que el Panel B el rendimiento Acumulado que se tenía en cada corte trimestral.

Se observa en el Panel C que al finalizar el cuarto trimestre del 2020 (2020-10-01) el portafolio no solo recuperó todo lo que había perdido, sino que ya presentaba ganancias. El único trimestre de pérdidas que



3.3. ESTRATEGIA DEL PORTAFOLIO REBALANCEADO



presentó el portafolio fue el primero del 2020 (2020-01-01 a 2020-04-01) y en el que tuvo más ganancias fue el segundo del 2020 (2020-04-01 a 2020-07-01) con 36% de rendimiento aproximadamente.

Cuadro 3.4: Comportamiento Trimestral del Portafolio con respecto al Riesgo

Trimestre	Máxima Pérdida Diaria %	Máxima Ganancia Diaria %	Volatilidad %	VaR %	CVaR %
2020-01-01 a 2020-04-01	-9.28	5.83	3.12	-6.24	-8.29
2020-04-01 a 2020-07-01	-4.86	6.40	2.14	-2.8	-3.59
2020-07-01 a 2020-10-01	-3.31	3.04	1.33	-2.07	-2.79
2020-10-01 a 2021-01-01	-3.11	2.82	1.30	-1.79	-2.38
2021-01-01 a 2021-04-01	-2.06	2.96	1.00	-1.3	-1.60
Promedio	-4.53	4.21	1.78	-2.84	-3.73

* Fuente: Elaboración Propia.

* VaR y CVaR a nivel de confianza del 95%

En la práctica se tienen valores diferentes a las estimaciones, pero en promedio se tiene una volatilidad mejor a la establecida (volatilidad objetivo) (cuadro 3.4). Los dos primeros trimestres son los que presentan mayor volatilidad debido a las caídas generalizadas ocasionadas por el COVID 19, sobre todo en el primer trimestre. Con el VaR y el CVaR se tienen comportamientos similares a la volatilidad, conforme pasa el tiempo el riesgo y la volatilidad decrecen.

Cuadro 3.5: Métricas Resumen del Portofolio (2020-01-01 a 2021-04-01)

Métrica	Valor
Máxima Pérdida Diaria	-9.28 %
Rendimiento Medio Diario	0.09 %
Volatilidad Diaria	1.97 %
Rendimiento/Volatilidad	0.047
VaR	-2.99 %
CVaR	-4.59 %
Máxima Ganancia Diaria	6.40 %

* Fuente: Elaboración Propia.

* VaR y CVaR a nivel de confianza del 95%



3.3. ESTRATEGIA DEL PORTAFOLIO REBALANCEADO



Cuadro 3.6: Métricas Resumen del Mercado-IPC (2020-01-01 a 2021-04-01)

Métrica	Valor
Máxima Pérdida Diaria	-6.42 %
Rendimiento Medio Diario	0.02 %
Volatilidad Diaria	1.48 %
Rendimiento/Volatilidad	0.013
VaR	-2.37 %
CVaR	-3.28 %
Máxima Ganancia Diaria	4.27 %

* Fuente: Elaboración Propia.

* VaR y CVaR a nivel de confianza del 95%

Analizando los rendimientos durante todo el periodo de inversión (2020-01-01 a 2021-04-01) y no de forma trimestral, se tuvo prácticamente una volatilidad del 2%, como se estableció en los modelos (cuadro 3.5). El VaR y CVaR son mayores que los promediados de forma trimestral; se esperaba que fueran mayores al considerar los datos de todo el periodo de inversión.

En conclusión, se tuvo un rendimiento mucho mayor que el mercado (cuadro 3.6) y se logró obtener la volatilidad establecida en los modelos (cuadro 3.5). Las medidas de riesgo son mayores que las del mercado (cuadro 3.6 y 3.5), aunque las medidas de riesgo del portafolio son mejores que las de la mayoría de los activos que conforman el portafolio (cuadro 3.2), con lo cual la diversificación redujo el riesgo en gran medida (objetivo principal).

La relación del rendimiento por cada unidad de volatilidad es mejor que la mayoría de los activos, con excepción de Apple, Paypal, Cemex y General Motors; por lo que también se logró un resultado muy bueno en el portafolio con respecto al rendimiento, y sobre todo al mercado. Analizando en retrospectiva, la mejor inversión fue Paypal al otorgar el mayor rendimiento y con un riesgo aun menor al portafolio.

Se demostró que el portafolio optimizado por el modelo de Markowitz y rebalanceado trimestralmente fue significativamente mejor que el mercado mexicano. Aunque el portafolio optimizado presenta ligeramente mayor riesgo y volatilidad que el mercado, este tiene una mejor relación de rendimiento/volatilidad, por lo que otorga mayor rendimiento por unidad de volatilidad.

Con base a todo lo anterior, este método representa un excelente modelo de referencia para comparar la eficacia del portafolio optimizado por el algoritmo genético. En el siguiente capítulo se realizarán las respectivas comparaciones para determinar si en efecto el modelo propuesto en este trabajo realmente es funcional y vale la utilizarlo.



IV

Aplicación del Modelo y Evaluación de la Estrategia



Capítulo 4

El portafolio basado en el algoritmo genético hace uso de la aplicación de cada uno de los indicadores técnicos enunciados en el capítulo 2, donde cada uno de estos tiene reglas de compra y venta. El objetivo del algoritmo genético es utilizarlo para encontrar los parámetros óptimos de cada uno de estos indicadores, para posteriormente definir una estrategia general basada en los 3 indicadores, de tal forma que nos proporcione señales de compra y venta para realizar las transacciones de la manera más eficiente posible.

La estrategia que se definió es bastante simple, se consideró como señal general lo que la mayoría de los indicadores, por ejemplo si 2 de 3 indicadores presentan una señal de compra, se realizará una compra.

4.1 Algoritmo Genético

Para la construcción de la estrategia se utilizaron tres indicadores técnicos: tres Medias Móviles, RSI y MACD. Para cada uno de se obtuvo mediante un algoritmo genético los parámetros óptimos que maximizan el rendimiento en función de su aplicación.

Para determinar ciertas características extras de cada indicador, se realizaron distintas simulaciones sobre varios activos para obtener la configuración óptima que proporcione el mejor desempeño para cada indicador. En el caso de las medias móviles la característica fue el tipo de media móvil según los periodos, y para el MACD, el valor absoluto mínimo del histograma (diferencia entre el MACD y Señal).

Por ejemplo, para las medias móviles se obtuvieron los periodos de cada media móvil de tal forma que al cruce de estas se tuvieran señales de compra y venta que maximizaran el rendimiento y que fueron mejor que la estrategia de *Buy & Hold*.

Por medio de simulaciones se determinó que lo óptimo para una media móvil de 12 periodos o menos, es utilizar una media móvil ponderada. Si el número de periodos comprenden de 13 hasta 30, lo ideal es una media móvil simple, y para mayores a 30 periodos una media móvil ponderada. Lo anterior se definió con la finalidad de mejorar el desempeño de la estrategia. Otra restricción que se consideró, es que existan el menos cinco periodos de diferencia entre cada media móvil, y que el periodo mínimo de las medias móviles no puede ser menor a seis periodos. Esto se realizó con el objetivo de disminuir las falsas señales de compra y venta.

Para el RSI se tomó como parámetros el periodo de la media móvil y las regiones de compra y venta. En donde la señal de compra se efectúa cuando la media móvil cruce hacia arriba la región de sobrevendido y la señal de venta cuando la media móvil cruce hacia abajo la región de sobrecomprado.



4.1. ALGORITMO GENÉTICO



Mientras que para el MACD los parámetros son los periodos de la media móvil lenta y la rápida, así como el periodo de la media móvil señal. La señal de compra se efectúa cuando el MACD cruce por arriba de la media móvil señal y de forma contraria la venta se realizará cuando el MACD cruce por abajo. Aunado a lo anterior, para disminuir el número de falsas señales aparte del cruce se necesita que la diferencia absoluta entre ambas (MACD y Señal) sea mayor a 0.7 para hacer efectiva la operación. El valor anterior se determinó a partir de simulaciones, las cuales demostraron que el valor óptimo que otorgaba mayor desempeño era 0.7.

Bajo la suposición de que al utilizar las señales de compra y venta de cada indicador se puede mejorar el rendimiento individual, se combinaron dichas señales para tener una estrategia más robusta.

Una vez obtenido los parámetros óptimos de cada indicador se combinaron las señales de compra y venta, para establecer la estrategia general. La cual consiste en que la operación de compra y venta solo se efectuará si al menos dos de los tres indicadores están generando la misma señal, en caso contrario no se realizará ninguna operación, hasta que existan al menos dos indicadores arrojando la misma señal.

Para la calibración de los parámetros se utilizó seis meses como periodo de entrenamiento. A continuación y a manera de ejemplificar el método, se muestra la aplicación del algoritmo genético para la acción de CEMEX. Las flechas rojas hacen alusión a una señal de venta, mientras que las verdes a una señal de compra

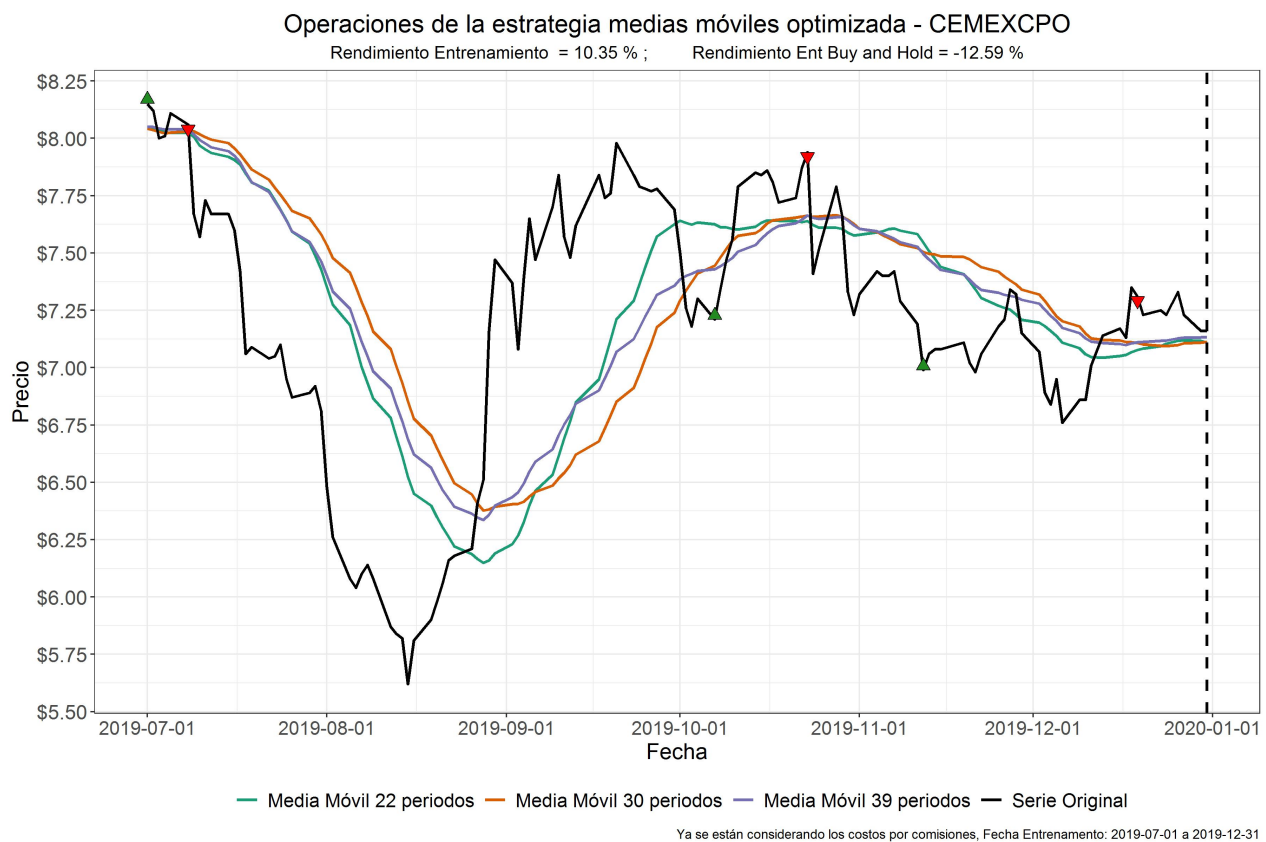


Figura 4.1: Aplicación Algoritmo Genética para medias móviles - CEMEX (Fuente: Elaboración Propia)



4.1. ALGORITMO GENÉTICO

Para la estrategia de medias móviles se tuvo seis operaciones, es decir, tres transacciones. A principios de junio, de forma momentánea la media de corto plazo (22 periodos) cruzó por debajo de la de media de mediano plazo (30 periodos) y a su vez la media de mediano plazo cruzó por debajo de la media de largo plazo (39 periodos). Por lo que se efectuó una operación de venta.

En octubre del 2019 se tuvo un último cruce donde la media larga se posicionó por debajo de la media de mediano plazo. Gracias a este último cruce se obtuvo el orden necesario para efectuar la operación de compra (media corto plazo > media de mediano plazo > media de largo plazo).




Figura 4.2: Aplicación Algoritmo Genética para MACD - CEMEX (Fuente: Elaboración Propia)

En el caso del MACD, cuando el cruce hacia arriba de la media móvil MACD sobre la media móvil señal es superior a 0.7 se efectúa la compra (línea punteada vertical verde), en caso contrario, se efectúa una venta (línea punteado vertical roja).

En términos más prácticos, cuando el histograma es superior a la línea punteada horizontal verde se efectúa la compra, mientras que cuando es menor a la línea punteada roja se efectúa la venta.



4.1. ALGORITMO GENÉTICO




Figura 4.3: Aplicación Algoritmo Genética para RSI - CEMEX (Fuente: Elaboración Propia)

Para el RSI la venta se realiza cuando la media móvil cruza hacia abajo la línea punteada horizontal roja, y la compra cuando cruza arriba de la línea punteada horizontal verde.



4.1. ALGORITMO GENÉTICO



Figura 4.4: Aplicación Estrategia Genética para CEMEX (Fuente: Elaboración Propia)

Se puede observar que en la aplicación de todos los indicadores se logra tener un rendimiento mucho mayor al *Buy & Hold*, de hecho proporciona un rendimiento negativo, del -12.59%. Con las medias móviles se tuvo un rendimiento del 10.35% (Figura 4.1), con el MACD el 12.48% (Figura 4.2) y 23.34% con el RSI (Figura 4.3).

Al utilizar la estrategia conjunta, combinando los tres indicadores (Figura 4.4) se tuvo un rendimiento del 26.8%, con la cual el rendimiento de la estrategia es mejor que los rendimientos individuales de cada indicador.

Entonces los parámetros óptimos para Cemex que se aplicarán el siguiente trimestre son: tres Medias móviles de 22, 30 y 39 periodos respectivamente, MACD de siete y 16 periodos para las medias móviles (rápida y lenta respectivamente), y 16 periodos para la señal, y por último, RSI de ocho periodos con valor de cinco para la región de sobrevendido y 67 para la de sobrecompra.

4.1.1 Comportamiento de los Activos

A continuación se muestran los resultados de aplicar el algoritmo a algunos de los activos que conforman el portafolio, se utilizó el mismo periodo de entrenamiento.



4.1. ALGORITMO GENÉTICO

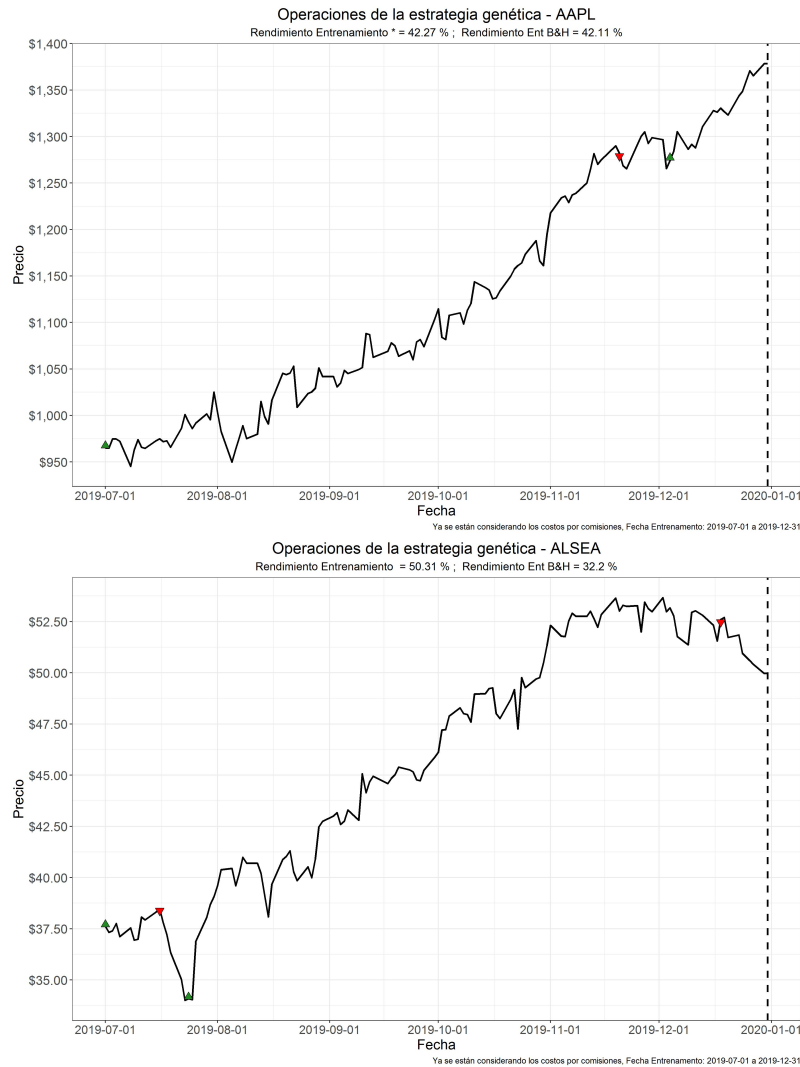


Figura 4.5: Aplicación Algoritmo Genético para Apple (Arriba) y Alsea (Abajo) (Fuente: Elaboración Propia)

En la Figura 4.5 se puede apreciar que la aplicación de la estrategia no tiene mucho sentido si el comportamiento del activo es muy alcista, como sucede con Apple. Aunque si el activo presenta gran volatilidad se tienen una mejora (aunque no muy significativa) con respecto al *Buy & Hold*, como sucede con Alsea.



4.1. ALGORITMO GENÉTICO

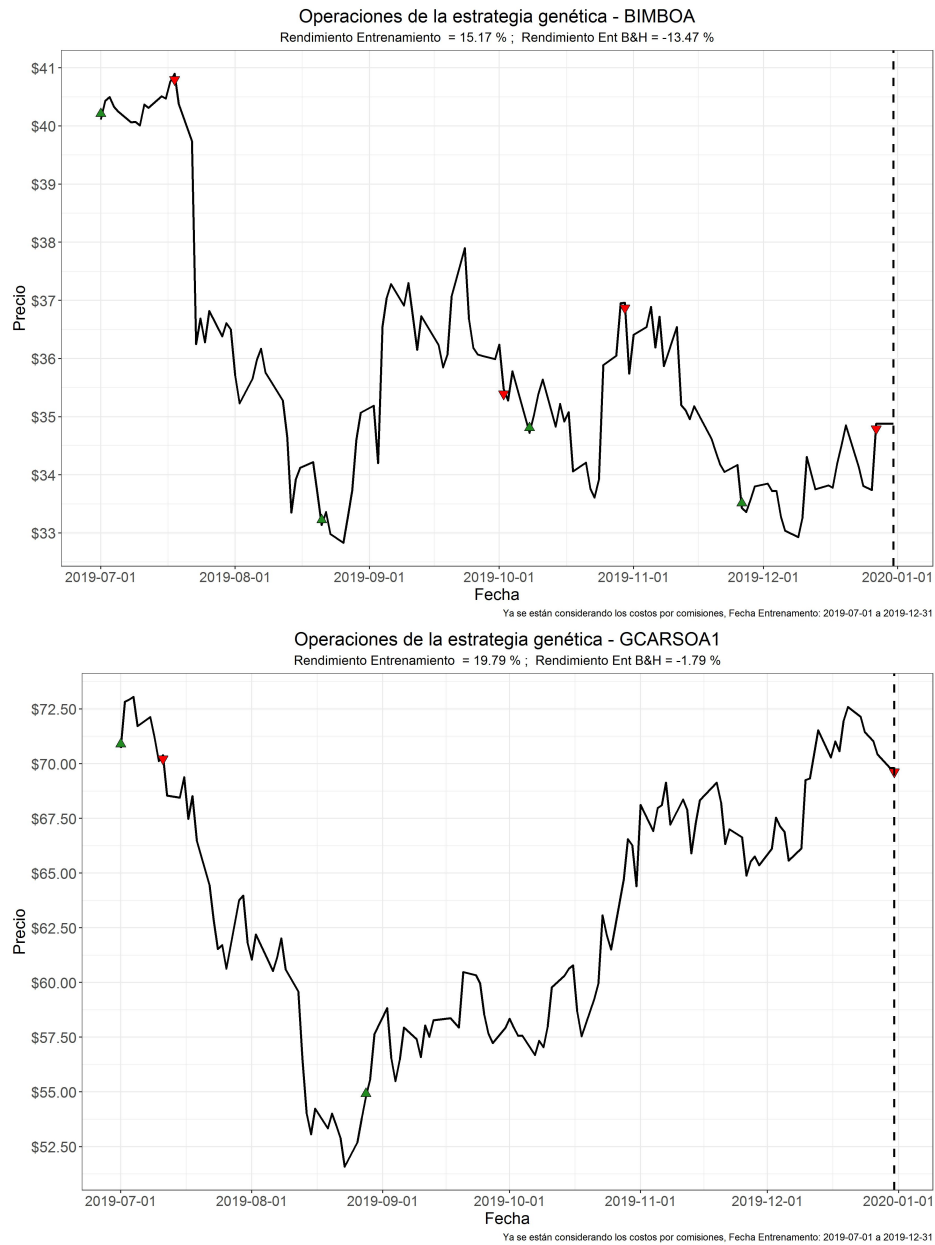


Figura 4.6: Aplicación Algoritmo Genético para Bimbo (Arriba) y Grupo Carso (Abajo) (Fuente: Elaboración Propia)

Para Cemex (figura 4.4) y Bimbo y Gentera (figura 4.6) se observa que la aplicación del algoritmo genético limitó las pérdidas de forma considerable, como se alcanza a apreciar en la gran corrección que se presentó a mediados de julio hasta finales de agosto.



4.1. ALGORITMO GENÉTICO

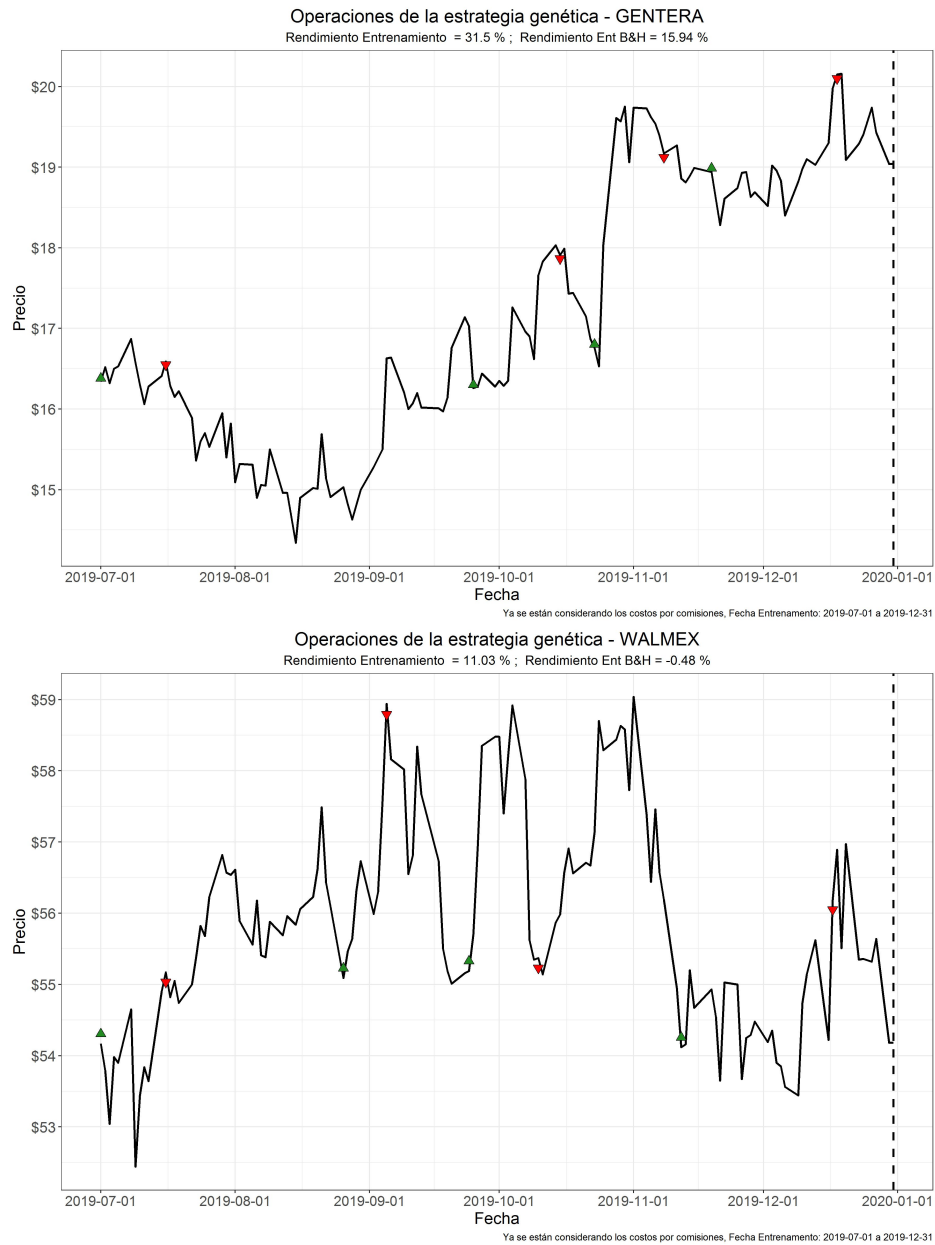


Figura 4.7: Aplicación Algoritmo Genético para Gentera (Arriba) y Walmart (Abajo) (Fuente: Elaboración Propia)

Gracias a la volatilidad que se presentó en dichos activo (Bimbo, Grupo Carso, Gentera y Walmart) efectuaron compras y ventas muy eficientes, principalmente en Walmart (figura 4.7), en donde se logró un rendimiento del 11% contra la pérdida del 0.48% del *Buy & Hold*.

Para los activos de: Bimbo, Grupo Caros, Gentera y Walmart, se tiene considerablemente un mejor desempeño al utilizar el algoritmo genético, ya que el *Buy & Hold* con excepción de Gentera tuvo pérdidas en todos los activos.



Para Gentera la mejora no fue tan significativa como los demás activos (Bimbo, Grupo Caros y Walmart), ya que presentó en los últimos meses un comportamiento alcista, no tan extremo como Apple y con mayor volatilidad que Alsea (Figura 4.5), por lo que su relación con respecto al *Buy & Hold* es mejor que Apple y Alsea, esta estrategia es recomendable para operar en periodos de alta volatilidad e incertidumbre, ya que puede aprovechar la venta en un punto alto para posteriormente recomprar más barato (“*buy the dip*”). También sería ideal para un periodo de crisis, ya que logra evitar y/o minimizar las pérdidas.

Evidentemente aún falta corroborar el desempeño (rendimiento y riesgo) en la aplicación de datos futuros, ya que es obvio que el desempeño del modelo sobre los datos con los que fue entrenado, iba a mostrar rendimientos muy superiores al *Buy and Hold*. Pero gracias a lo anterior tenemos nociones de las fortalezas y debilidades de la estrategia y para qué tipo de activos está justificado aplicar el modelo.

4.2 Aplicación de la Estrategia

Para calibrar los parámetros se optó por utilizar como periodo de entrenamiento un año de información histórica con una recalibración cada tres meses (Figura 3.5), similar a lo que se realizó para el portafolio rebalanceado del capítulo anterior. De esta forma, los parámetros estarán siempre actualizados conforme al dinamismo presente en el comportamiento del activo.

La estrategia con los valores óptimos se aplicó durante el siguiente trimestre¹ consecutivo al periodo de entrenamiento, para posteriormente volverse a calibrar y aplicar en el siguiente trimestre, y así sucesivamente hasta recorrer todo el periodo de inversión (2020-01-01 a 2021-04-01), por lo que se tiene un sistema tipo “rolling window” (Figura 3.5). Lo anterior se realizó para ser consistente con la metodología utilizada en el portafolio rebalanceado (capítulo anterior).

Dicha estrategia se aplicó durante un un año tres meses (cinco trimestres), en el periodo que comprende de 2020-01-01 hasta 2021-04-01. Para ser consistente con el portafolio rebalanceado y poder tener una comparación directa con este, se utilizaron los mismos pesos iniciales del portafolio rebalanceado (Figura 3.6 - Trimestre 2020-01-01) para el portafolio del algoritmo genético.

A partir de ese punto, la estrategia del algoritmo genético se encargó de gestionar el riesgo y el rendimiento mediante las señales de compra y venta obtenidas a partir de los indicadores técnicos, en comparación con el portafolio rebalanceado, el cual gestionó el riesgo a partir del rebalanceo trimestral de los pesos de cada activo en el portafolio.

Para el caso donde al efectuar una transacción (operación de compra y venta) se obtuvieron utilidades, se consideró que al volver a efectuar una operación de compra se invertirá el monto original más las utilidades generadas de la transacción anterior (reinvertir). Es decir, siempre se vuelve a invertir el monto restante después de efectuar una transacción. En caso de tener utilidades el monto será mayor, por el caso contrario, al tener pérdidas será menor. Por lo que se tendrá un rendimiento para cada transacción efectuada.

¹A partir de los parámetros obtenidos al entrenar el modelo con los datos históricos del último año



4.2.1 Desempeño Individual (por activo)

Se muestran las operaciones efectuadas por el algoritmo genético para algunos de los activos².




Figura 4.8: Operaciones de la estrategia genética para PayPal (Fuente: Elaboración Propia)

Para activos excesivamente alcista como PayPal se corrobora lo mencionado en la sección anterior. Para activos con una tendencia muy alcista, no es recomendable la estrategia genética (Figura 4.8). Con Apple se tiene un comportamiento ligeramente menos alcista que PayPal (véase el apéndice) y de todas formas el algoritmo genético no superó al *Buy & Hold* (Cuadro 4.2)

²En la sección de anexos se adjuntan las operaciones para los demás activos del portafolio.



4.2. APLICACIÓN DE LA ESTRATEGIA




Figura 4.9: Operaciones de la estrategia genética para Volaris (Fuente: Elaboración Propia)

En Volaris, Alsea, Cemex, Gentera, GM y MGM, se logró reducir en gran medida la pérdida ocasionada por la caída de la bolsa a mediados de febrero del 2020, derivada de la pandemia por el COVID 19. Y en otros activos hasta se logró evitar las pérdidas, como en el caso de Volaris (Figura 4.9). A su vez, el algoritmo se desempeñó de forma óptima, aprovechando las oscilaciones de los activos para efectuar las operaciones de compra y venta, maximizando de esta forma el rendimiento.

Walmart presentó un comportamiento lateral o en rango³ durante el clímax de la pandemia (2020-02-01 a 2020-09-01), para posteriormente iniciar una tendencia alcista (Figura 4.10). Durante el periodo que estuvo en rango, la estrategia genética logró efectuar operaciones de compra y ventas satisfactorias, donde en casi todas las transacciones (con excepción de uno) se obtuvieron utilidades.

³Se refiere al comportamiento sin tendencia definida y oscilatorio, es decir, su comportamiento presenta subidas y bajadas pero sin mostrar una tendencia.



4.2. APLICACIÓN DE LA ESTRATEGIA




Figura 4.10: Operaciones de la estrategia genética para Walmart (Fuente: Elaboración Propia)

En el periodo alcista también la estrategia fue efectiva, aunque no tanto como el periodo en que se encontraba con un comportamiento en rango/lateral. Se puede observar que con el *Buy & Hold* en el periodo alcista, se hubieran tenido mejores rendimientos.

En Volaris se efectuó la primera venta en utilidades a mediados de febrero, por lo que en la gráfica del rendimiento acumulado se aprecia un incremento y posteriormente una línea horizontal (Figura 4.11), ya que en ese momento se vendió el activo y ya no era parte del portafolio. A principios de abril se volvió a comprar y luego se vendió con una ligera utilidad, aunque lo ideal era vender en el punto más alto (2020-05-01), donde se tenía el mayor rendimiento acumulado. A partir de la compra de agosto del 2020, el activo tuvo una tendencia alcista, con lo cual se incrementó significativamente el rendimiento acumulado.



4.2. APLICACIÓN DE LA ESTRATEGIA




Figura 4.11: Rendimiento Acumulado de Volaris con la estrategia genética (Fuente: Elaboración Propia)

En el caso de Volaris⁴ todas las operaciones fueron altamente efectivas, ya que prácticamente la mayoría del tiempo el rendimiento acumulado nunca descendió, y el rendimiento acumulado al momento de la venta fue mayor que el que se tenía en la compra anterior a esta.

⁴En la sección de anexos se adjuntan los rendimientos acumulados para los demás activos del portafolio.



4.2. APLICACIÓN DE LA ESTRATEGIA

Cuadro 4.1: Estrategia genética vs B&H para cada activo

	Rendimiento	Rendimiento.B.H	Mejor
AAPL	72.89 %	76.56 %	Buy & Hold
ALSEA	18.69 %	-39.71 %	Estrategia Gen
BIMBOA	0.73 %	22.38 %	Buy & Hold
CEMEXCPO	111.48 %	100.39 %	Estrategia Gen
GCARSOA1	-19.17 %	-20.34 %	Estrategia Gen
GENTERA	-1.55 %	-52.29 %	Estrategia Gen
GM	30.94 %	69.87 %	Buy & Hold
MGM	75.78 %	24.05 %	Estrategia Gen
PYPL	83.76 %	142.35 %	Buy & Hold
VOLARA	171.92 %	44.71 %	Estrategia Gen
WALMEX	36.59 %	18.4 %	Estrategia Gen

Note:

Fuente: Elaboración Propia

De los 11 activos, en siete la estrategia genética superó al *Buy & Hold* (Cuadro 4.1). Como ya se mencionó, la estrategia es recomendable para activos que no presenten una tendencia alcista, por esa razón Apple y PayPal no se vieron beneficiados por la estrategia genética.

En algunos activos la estrategia *Buy and Hold* tuvo pérdidas, mientras que al aplicar la estrategia genética, dichas pérdidas se redujeron y en algunos casos se logró tener utilidades.

En todos los casos la estrategia genética mitigó y hasta evito las pérdidas, por lo que el verdadero potencial de la estrategia genética es la de una herramienta para reducir el riesgo, más que una forma de maximizar el rendimiento. En el caso de activos con comportamiento en rango/lateral que presenten alta volatilidad, la estrategia genética se desempeña de forma satisfactoria, como fue en el caso de Walmart.



4.2.2 Comportamiento del Riesgo

Cuadro 4.2: Métricas del desempeño de la estrategia genética para cada activo durante el periodo de ejercicio (2020-01-01 a 2021-04-01)

	Rendimiento.Medio	Volatilidad	Rendimiento.Riesgo	VaR	CVaR
AAPL	0.18 %	2.36 %	0.074	-3.26 %	-4.31 %
ALSEA	0.05 %	1.84 %	0.030	-2.12 %	-2.12 %
BIMBOA	0 %	2.03 %	0.001	-2.47 %	-2.71 %
CEMEXCPO	0.24 %	2.21 %	0.108	-2.59 %	-2.94 %
GCARSOA1	-0.07 %	2.11 %	-0.032	-3.02 %	-5.05 %
GENTERA	0 %	2.28 %	-0.002	-2.94 %	-3.23 %
GM	0.09 %	1.69 %	0.051	-1.83 %	-1.83 %
MGM	0.18 %	3.01 %	0.060	-3.72 %	-3.89 %
PYPL	0.19 %	2.61 %	0.074	-3.67 %	-4.75 %
VOLARA	0.32 %	2.62 %	0.122	-3.16 %	-4.02 %
WALMEX	0.1 %	1.41 %	0.070	-2.1 %	-3.15 %

Note:

Fuente: Elaboración Propia

* VaR y CVaR a nivel de confianza del 95%

El cuadro 4.2 muestra el rendimiento, volatilidad y el riesgo asociado a cada activo al utilizar la estrategia genética. Comparando con las métricas de la estrategia de *Buy and Hold* (Cuadro 3.3).

En la mayoría de los casos el rendimiento fue mayor en la estrategia genética y la volatilidad menor, con respecto a la estrategia de *Buy and Hold*⁵ (Figura 4.12). La estrategia genética es considerablemente menos riesgosa que el “Buy and Hold”, al tener un menor CVaR en todos los activos.

⁵La relación no es confiable si el rendimiento medio fue negativo, ya que a menor volatilidad se incrementará la magnitud del rendimiento, por ende si se tiene el rendimiento negativo parecerá que tiene peor relación de rendimiento con respecto a la volatilidad. En este caso analizar de forma separada el rendimiento y la volatilidad.



4.3. DESEMPEÑO DEL PORTAFOLIO (CONJUNTO)

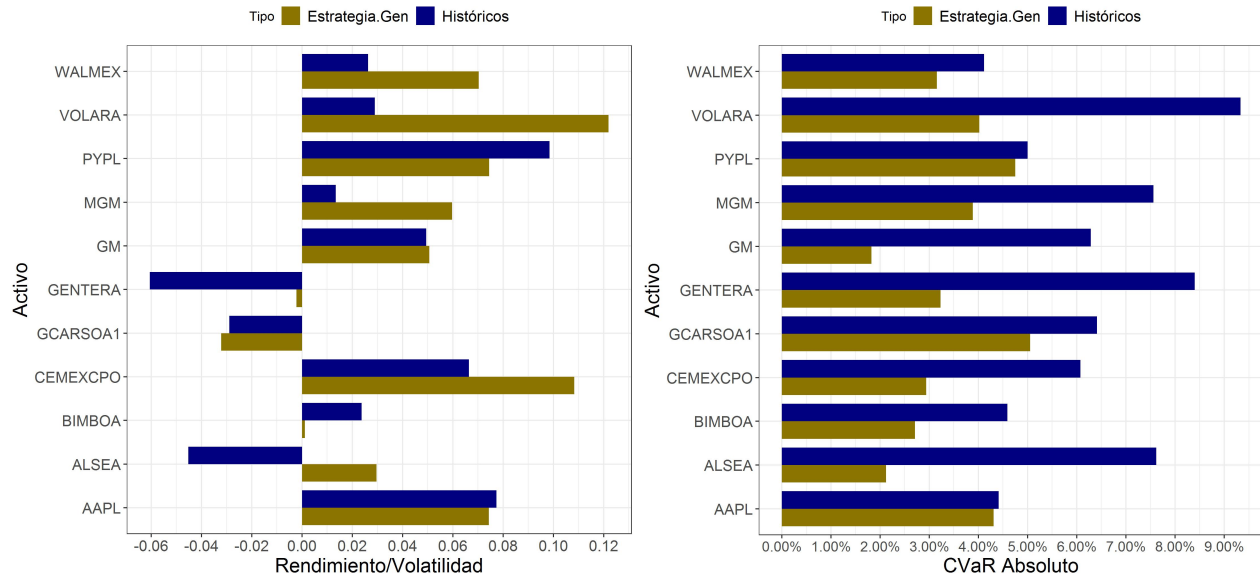


Figura 4.12: Comparación estrategia genética vs Buy & Hold para cada activo (Fuente: Elaboración Propia).

4.3 Desempeño del Portafolio (conjunto)

En la sección anterior se evaluó la eficacia de la estrategia genética para cada activo, es decir, de forma individual. En esta sección se analizó si al aplicar la estrategia genética de forma individual para los activos que conforman un portafolio (forma conjunta), se logra obtener una mejora sustancial con respecto al *Buy and Hold*.

Cuadro 4.3: Métricas Resumen del Portofolio con la estrategia genética

Máxima Pérdida Diaria	-3.051 %
Rendimiento Medio Diario	0.175 %
Volatilidad Diaria	1.135 %
Rendimiento/Volatilidad	0.1539
VaR	-1.446 %
CVaR	-1.784 %
Máxima Ganancia Diaria	5.113 %

Note:

Fuente: Elaboración Propia

* VaR y CVaR a nivel de confianza del 95%

Comparando los resultados del portafolio rebalanceado (Cuadro 3.5) vs el portafolio de la estrategia



4.3. DESEMPEÑO DEL PORTAFOLIO (CONJUNTO)



genética (Cuadro 4.3), se tiene que el portafolio con la estrategia genética fue muy superior, a su vez la estrategia genética es muy superior al mercado (Cuadro 3.6). La máxima pérdida, la volatilidad y el riesgo (VaR y CVaR) fue mucho menor en la estrategia genética, mientras que la máxima ganancia, el rendimiento medio y la relación de rendimiento-volatilidad fueron mayores en la estrategia genética.

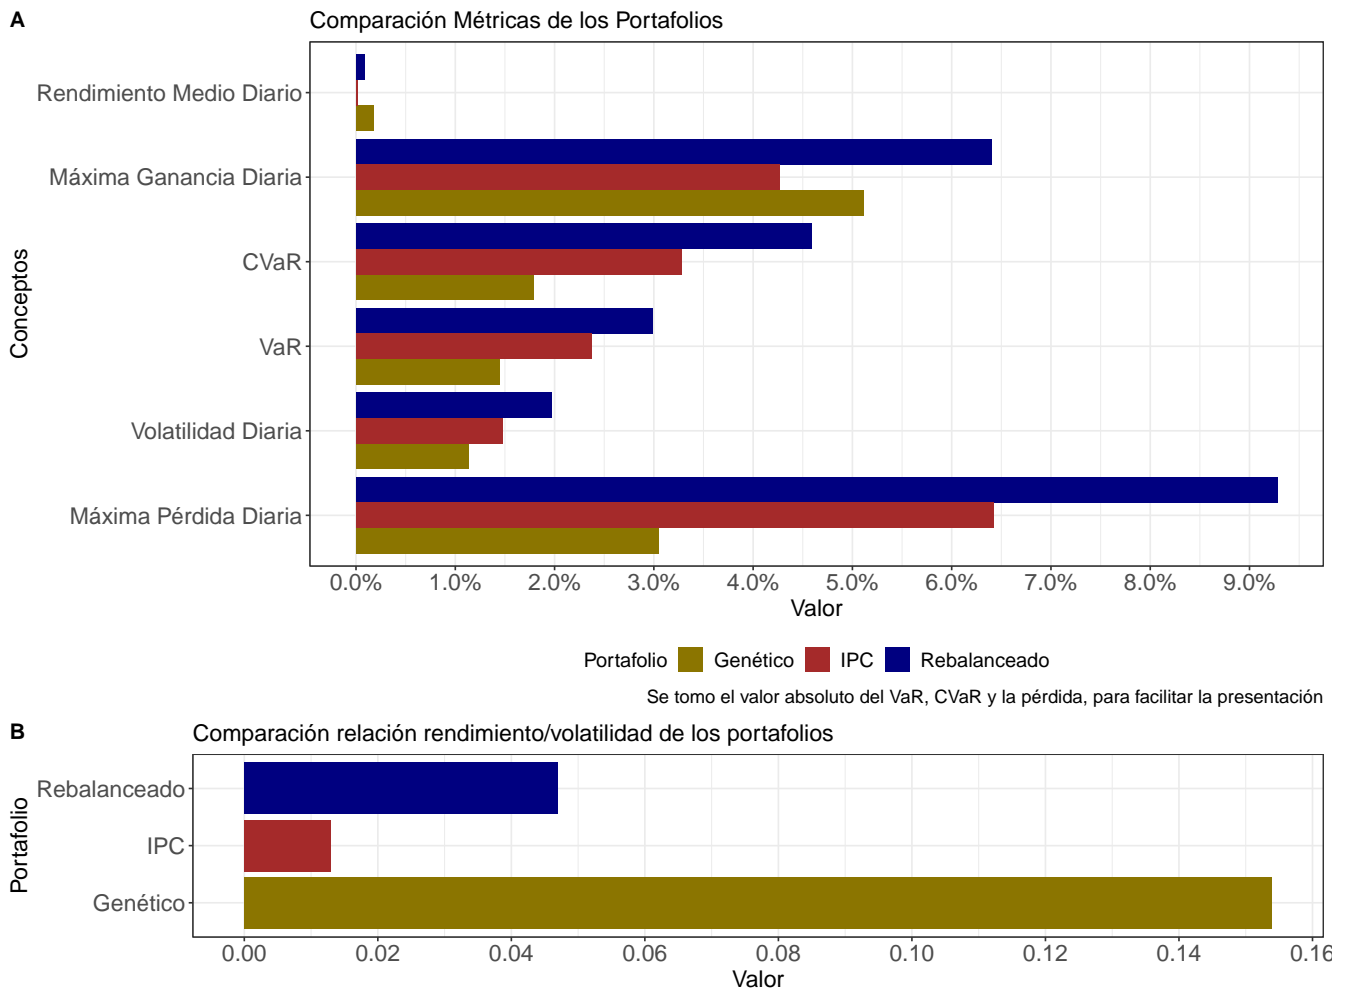


Figura 4.13: Comparación portafolios (Fuente: Elaboración Propia).

El portafolio basado en la estrategia genética es mejor en todos los ámbitos que el portafolio rebalanceado y el mercado (Figura 4.13 - Panel A). El portafolio basado en la estrategia genética es el que otorga mayor rendimiento por unidad de volatilidad (Figura 4.13 - Panel B).

El Comportamiento del portafolio genético fue mucho mejor durante la crisis del COVID-19 al no presentar una ligera caída en comparación con el mercado y al portafolio rebalanceado (Figura 4.14 - Panel A). Esto debido a la forma en que limitó y evitó las pérdidas en los activos, como se comentó en la sección anterior.

El portafolio rebalanceado y el IPC empezaron a tener utilidades hasta noviembre del 2020 y enero del 2021 respectivamente, mientras que el portafolio genético siempre estuvo en utilidades, solo el 1 de abril del 2020 estuvo ligeramente en pérdidas, aunque se recuperó inmediatamente (Figura 4.14 - Panel A).



4.3. DESEMPEÑO DEL PORTAFOLIO (CONJUNTO)

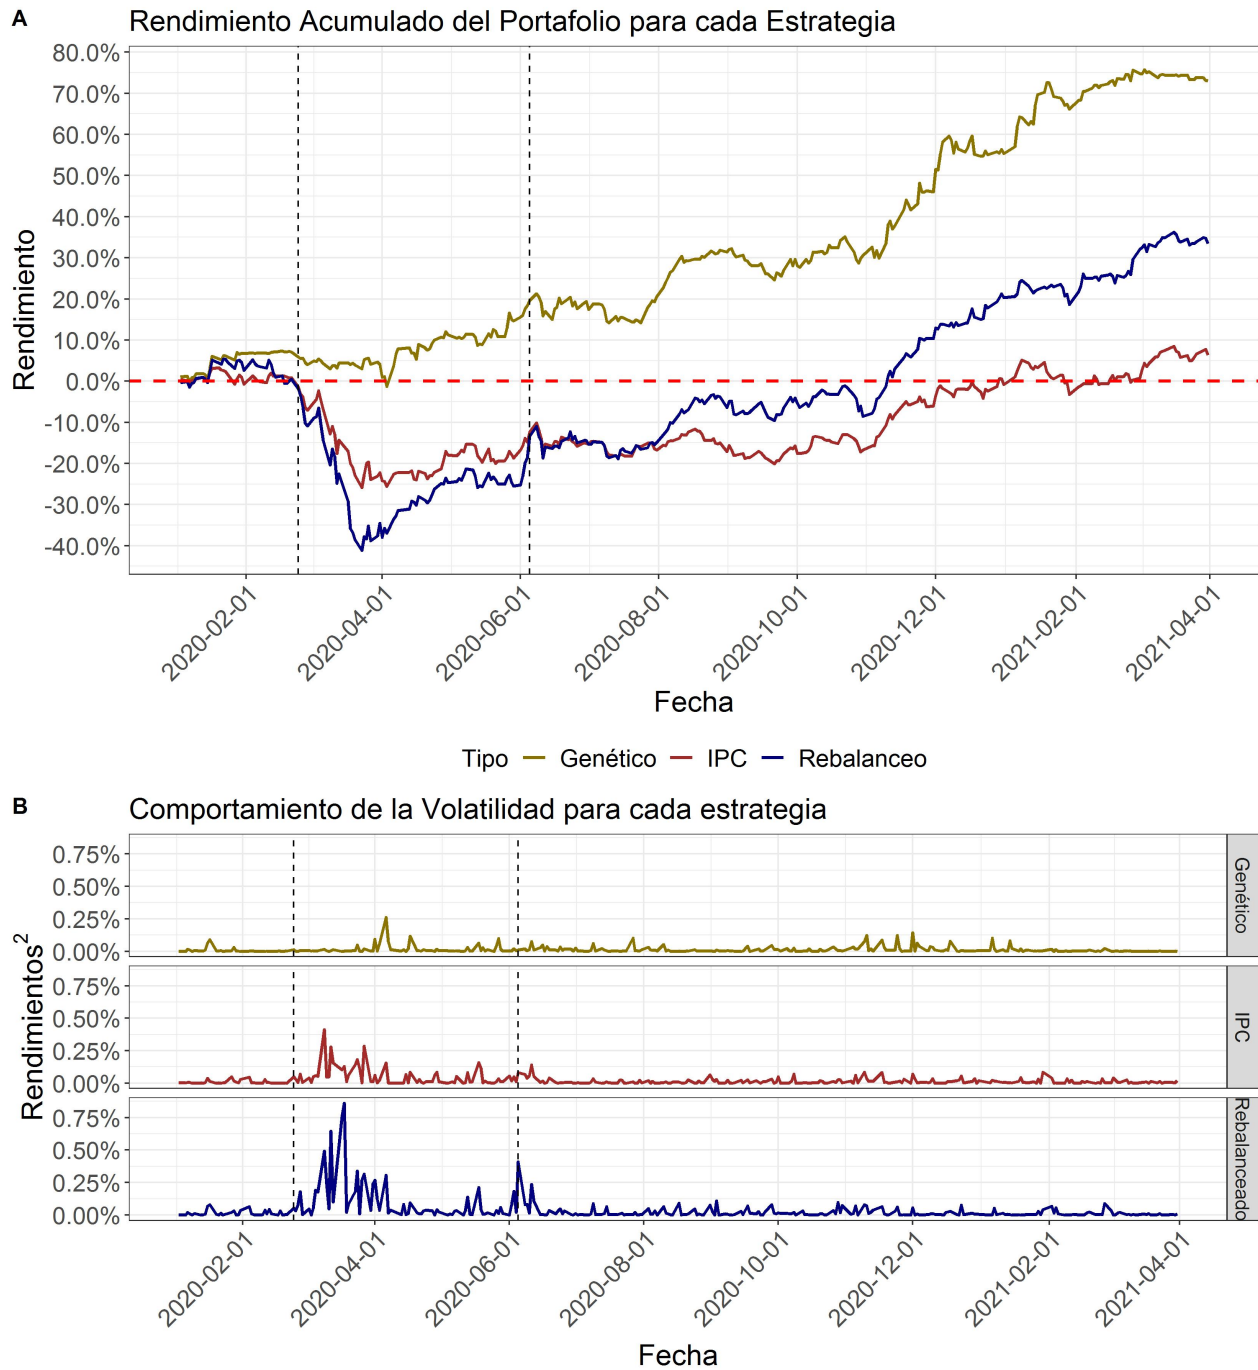


Figura 4.14: Comportamiento del rendimiento acumulado y de la voaltilidad de los portafolios (Fuente: Elaboración Propia).

El portafolio genético tuvo una recuperación más veloz y de mayor magnitud en comparación con el mercado y el portafolio rebalanceado. Aunque el portafolio rebalanceado y el genético parecen tener un rendimiento muy similar a partir de junio del 2020.



4.3. DESEMPEÑO DEL PORTAFOLIO (CONJUNTO)



La mayor volatilidad se presentó durante el periodo de la crisis COVID (2020-02-25 a 2020-06-04), pero el del portafolio genético es significativamente menor que el del IPC y el portafolio rebalanceado, siendo este último el de mayor volatilidad (Figura 4.14 – Panel B).

Los periodos de alta volatilidad del portafolio genético son mucho más cortos y de mucho menor magnitud que los del IPC y los del portafolio rebalanceado. La volatilidad del portafolio genético es bastante estable, por lo que gestionó mejor la volatilidad y el riesgo.

Con base a lo anterior, se dividió el periodo de inversión en tres secciones, la primera corresponde a un periodo pre-COVID (2020-01-01 a 2020-02-24), la segunda a la crisis COVID (2020-02-25 a 2020-06-04) y la tercera al periodo de recuperación y crecimiento (2020-06-25 a 2021-04-01) (Cuadro 4.4).

Cuadro 4.4: Comparación portafolios del rendimiento por periodo

	Rebalanceado	IPC	Genético
2020-01-01 a 2020-02-24	-1.82 %	-1.39 %	5.9 %
2020-02-25 a 2020-06-04	-17.12 %	-13.57 %	11.83 %
2020-06-25 a 2021-04-01	64.06 %	24.75 %	46.1 %
Total	33.5 %	6.32 %	73.01 %

Note:

Fuente: Elaboración Propia

En el periodo pre-COVID, el portafolio genético tuvo ganancias, mientras que los otros tuvieron pérdidas. Durante el periodo crisis COVID, sucede lo mismo, pero en este caso la diferencia es abismal, siendo considerablemente mejor el portafolio genético.

En el periodo de recuperación y crecimiento, el mercado (IPC) está muy por debajo de los portafolios, siendo mejor el portafolio rebalanceado. Aunque debido a las pérdidas que presentó el portafolio rebalanceado en los demás periodos, el rendimiento total del portafolio genético es ampliamente superior.

El portafolio con la estrategia genético resultó altamente rentable, logrando ser superior al mercado y al portafolio de rebalanceado trimestralmente al tener la mejor relación entre rendimiento con respecto a la volatilidad.

El desempeño observado es particularmente consistente en periodos de alta volatilidad, en donde se presente un comportamiento con muchas oscilaciones y/o altas correcciones, por lo que en el escenario COVID se desempeñó de mejor manera que el mercado y el portafolio rebalanceado. Así que en mercados alcistas no es recomendable el uso de la estrategia genética, ya que aunque la estrategia logra gestionar el riesgo de forma óptima se verá mermado el rendimiento, y la relación rendimiento con respecto a la volatilidad no será mejor que la del mercado.



V

Conclusiones



El portafolio genético (estrategia genética) demostró ser muy superior al mercado y al portafolio rebalanceado, logrando tener mucho mayor rendimiento con un menor riesgo ($\bar{r}_{gen} = 0.175\%$, $CVaR_{gen} = -1.78\%$ y $Rtotal_{gen} = 73\%$ vs $\bar{r}_{port} = 0.09\%$, $CVaR_{port} = -4.59\%$ y $Rtotal_{port} = 33.5\%$). Al aplicar la estrategia genética de forma individual a cada uno de los activos, se logró tener también una mejora sustancial a nivel del portafolio, por lo que la optimización individual también resulta en una optimización conjunta.

Las operaciones efectuadas mediante los indicadores optimizados por el algoritmo genético lograron gestionar el riesgo de forma eficiente, limitando y/o evitando las pérdidas en cada activo, lo que se tradujo en un portafolio mucho menos riesgoso y robusto, que evitó pérdidas durante el climax de la pandemia del COVID, con lo cual se logró una gestión eficiente e inteligente del riesgo tanto a nivel de cada activo como a nivel del portafolio, situación que fue mucho más notoria en periodos de alta volatilidad e incertidumbre.

La estrategia genética es recomendable para operar sobre activos que presenten un comportamiento en rango/lateral y/o que tengan una alta y/o media volatilidad. Logró reducir el riesgo en cada activo, anticipando la tendencia bajista y generando señales de venta antes de que se presentaran correcciones significativas en el mercado.

Para activos con una tendencia altamente alcista y/o activos con muy poca volatilidad no es recomendable la estrategia genética, ya que podría generar falsas señales de compra y ventas que repercutirán en el rendimiento. Para aquellos activos que presentaron una recuperación (tendencia alcista después de haber tenido grandes correcciones) la estrategia genética se desempeñó de forma eficiente, a pesar que durante el ciclo alcista no se efectuaron las transacciones eficientes, y en donde el *Buy and Hold* era la mejor opción.

Lo recomendable es operar con la estrategia genética durante un periodo con un mercado en rango/lateral y/o bajista, y cuando el activo comienza a dar señales de una tendencia alcista, esperar a tener una confirmación fehaciente para posteriormente dejar de utilizar la estrategia genética y retomar el *Buy and Hold* durante el nuevo ciclo alcista. En el momento que el activo empieza a dar señales de una posible caída y/o correcciones significativas (después de un ciclo alcista), lo recomendable es volver a operar con la estrategia genética para reducir el riesgo y minimizar las posibles pérdidas.

El uso de un algoritmo genético en conjunto con indicadores técnicos es una excelente alternativa como herramienta para la gestión del riesgo de un portafolio. Su mayor eficacia se observa en periodos de alta volatilidad, en donde el mercado se encuentra en comportamiento lateral y/o con una tendencia bajista, por lo que en el periodo más severo del COVID 19 (2020-03-01 a 2021-11-01) se redujo el riesgo y se minimizaron las pérdidas de forma considerable, siendo mucho más eficiente que el portafolio rebalanceado y que la estrategia de *Buy and Hold*.

Aunque en este trabajo se tomó a consideración las comisiones por transacción es importante recalcar que se consideraron otros supuestos. Se asumió que siempre se compra y vende al precio de cierre, cuando en la realidad no necesariamente se efectuará así, ya que puede existir brechas entre los precios de cierre y apertura (debido al “premarket”), o que no existe un comprador/vendedor que sirva de contraparte para la operación y/o para el precio.

Futuras Investigaciones

Aunque la estrategia demostró ser satisfactoria, aun no se puede garantizar la consistencia de la efectividad, se podría extender la investigación sobre un mayor rango de tiempo, por ejemplo cinco años, y hasta proporcionar periodos discontinuos, es decir, estudiar desde 1995 al 2000 y del 2005 al 2010, etc.



Otro enfoque para robustecer el método sería probar con un mayor número de indicadores técnicos, para analizar cuáles son los más efectivos con la estrategia genética y que combinación de indicadores es la más consistente con respecto a la eficiencia del modelo.

Por último, se propone que en lugar de utilizar la estrategia de *trading* a partir de las reglas de los indicadores técnicos, dichas reglas sean determinadas por un modelo de aprendizaje automático (*machine learning*), como podría ser un bosque aleatorio (*random forest*), “*Adaboost*”, “*xgboost*”, etc. De esta forma se utilizarán los indicadores técnicos optimizados por el algoritmo genético pero con una estrategia generada por el aprendizaje automático.



VI

Referencias



- Abu-Mostafa, Y. S., & Atiya, A. F. (1996). Introduction to financial forecasting. *Applied intelligence*, 6(3), 205-213.
- Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*.
- Alexander, S. S. (1961). Price movements in speculative markets: Trends or random walks. *Industrial Management Review (pre-1986)*, 2(2), 7.
- Alexander, S. S. (1964). Price Movements in Speculative Markets—Trends or Random Walks, Number 2. *IMR; Industrial Management Review (pre-1986)*, 5(2), 25.
- Alkhatib, K., Najadat, H., Hmeidi, I., & Shatnawi, M. K. A. (2013). *Stock Price Prediction Using K-Nearest Neighbor (kNN) Algorithm*. Recuperado de <https://www.semanticscholar.org/paper/Stock-Price-Prediction-Using-K-Nearest-Neighbor-Alkhatib-Najadat/1507329f5382a1550430657ebae7f70507f63410>
- Allen, F., & Karjalainen, R. (1999). Using genetic algorithms to find technical trading rules. *Journal of Financial Economics*, 51(2), 245-271. [https://doi.org/https://doi.org/10.1016/S0304-405X\(98\)00052-X](https://doi.org/https://doi.org/10.1016/S0304-405X(98)00052-X)
- Armano, G., Marchesi, M., & Murru, A. (2005). A hybrid genetic-neural architecture for stock indexes forecasting. *Information Sciences*, 170(1), 3-33.
- Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques—Part II: Soft computing methods. *Expert Systems with applications*, 36(3), 5932-5941.
- Bohnenblust, H., & Slovic, P. (1998). Integrating technical analysis and public values in risk-based decision making. *Reliability Engineering & System Safety*, 59(1), 151-159. [https://doi.org/https://doi.org/10.1016/S0951-8320\(97\)00136-1](https://doi.org/https://doi.org/10.1016/S0951-8320(97)00136-1)
- Bosworth, B., Hymans, S., & Modigliani, F. (1975). The stock market and the economy. *Brookings Papers on Economic Activity*, 1975(2), 257-300.
- Boudt, K., Peterson, B., & Croux, C. (2007). Estimation and decomposition of downside risk for portfolios with non-normal returns. *DTEW-KBI_0730*, 1-30.
- Brock, W., Lakonishok, J., & LeBaron, B. (1992). Simple technical trading rules and the stochastic properties of stock returns. *The Journal of finance*, 47(5), 1731-1764.
- Brown, D. P., & Jennings, R. H. (1989). On technical analysis. *The Review of Financial Studies*, 2(4), 527-551.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., & Oliveira, A. L. I. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, 194-211. <https://doi.org/https://doi.org/10.1016/j.eswa.2016.02.006>
- Chong, E., Han, C., & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187-205.
- Chong, T. T.-L., Ng, W.-K., & Liew, V. K.-S. (2014). Revisiting the Performance of MACD and RSI Oscillators. *Journal of Risk and Financial Management*, 7(1), 1-12. <https://doi.org/10.3390/jrfm7010001>
- Daniélsson, C. S., J; Keating. (2001). An Academic Response to Basel II. FMG Special Papers. *Financial Markets Group*.
- De Faria, E., Albuquerque, M. P., Gonzalez, J., Cavalcante, J., & Albuquerque, M. P. (2009). Predicting the Brazilian stock market through neural networks and adaptive exponential smoothing methods. *Expert Systems with Applications*, 36(10), 12506-12509.
- De Lara Haro, A. (2005). *Medición y Control de Riesgos Financieros*. Editorial Limusa.
- Dorffleitner, G., & Klein, C. (2003). *Technical Analysis as a Method of Risk Management*.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, 987-1007.



- Fama, Eugene F. (1965). The Behavior of Stock-Market Prices. *The Journal of Business*, 38(1), 34-105. Recuperado de <http://www.jstor.org/stable/2350752>
- Fama, Eugene F. (1991). Efficient Capital Markets: II. *The Journal of Finance*, 46(5), 1575-1617. Recuperado de <http://www.jstor.org/stable/2328565>
- Fama, Eugene F., & Blume, M. E. (1966). Filter rules and stock-market trading. *The Journal of Business*, 39(1), 226-241.
- Fang, Y., & Xu, D. (2003). The predictability of asset returns: an approach combining technical analysis and time series forecasts. *International Journal of Forecasting*, 19(3), 369-385. [https://doi.org/https://doi.org/10.1016/S0169-2070\(02\)00013-4](https://doi.org/https://doi.org/10.1016/S0169-2070(02)00013-4)
- Fong, W. M., & Yong, L. H. M. (2005). Chasing trends: recursive moving average trading rules and internet stocks. *Journal of Empirical Finance*, 12(1), 43-76. <https://doi.org/https://doi.org/10.1016/j.jempfin.2003.07.002>
- Franco Arbeláez, L. E., Luis CeferinoFranco Ceballos. (2005). El valor en riesgo condicional CVaR como medida coherente de riesgo. *Revista Ingenierías Universidad de Medellín*. Recuperado de <https://www.redalyc.org/articulo.oa?id=75040604>
- Franses, P. H., & Van Dijk, D. (1996). Forecasting stock market volatility using (non-linear) Garch models. *Journal of Forecasting*, 15(3), 229-235.
- Gerlein, E. A., McGinnity, M., Belatreche, A., & Coleman, S. (2016). Evaluating machine learning classification for financial trading: An empirical approach. *Expert Systems with Applications*, 54, 193-207.
- Gómez Vilchis, J., Hernández Álvarez, F., & Román de la Sancha, L. (2021). Autómata Evolutivo (AE) para el mercado accionario usando Martingalas y un Algoritmo Genético. *Revista Mexicana de Economía y Finanzas Nueva Época REMEF*, 16(4), 505. <https://doi.org/10.21919/remef.v16i4.505>
- Holland, J. H. (1976). *Adaptation in natural and artificial systems*. niversity of Michigan Press, Ann Arbor.
- Hsieh, T.-J., Hsiao, H.-F., & Yeh, W.-C. (2011). Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm. *Applied soft computing*, 11(2), 2510-2525.
- Ian H. Witten, E. F., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques: Practical Machine Learning Tools and Techniques* (3.^a ed., p. 664). Elsevier.
- Iskrich, D., & Grigoriev, D. (2017). *Generating long-term trading system rules using a genetic algorithm based on analyzing historical data*. 91-97. Recuperado de <https://www.fruct.org/publications/fruct20/files/Isk.pdf>
- Jegadeesh, N., & Titman, S. (1993). Returns to buying winners and selling losers: Implications for stock market efficiency. *The Journal of finance*, 48(1), 65-91.
- John, M. J. (1999). *Technical analysis of the financial markets: a comprehensive guide to trading methods and applications*. New York Institute of Finance.
- Karolyi, G. A. (1995). A multivariate GARCH model of international transmissions of stock returns and volatility: The case of the United States and Canada. *Journal of Business & Economic Statistics*, 13(1), 11-25.
- Kim, H., & Shin, K. (2007). A hybrid approach based on neural networks and genetic algorithms for detecting temporal patterns in stock markets. *Applied Soft Computing*, 7(2), 569-576.
- Kim, J. H., Shamsuddin, A., & Lim, K.-P. (2011). Stock return predictability and the adaptive markets hypothesis: Evidence from century-long US data. *Journal of Empirical Finance*, 18(5), 868-879.
- Kim, K., & Han, I. (2000). Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert systems with Applications*, 19(2), 125-132.



- Kumar, D. A., & Murugan, S. (2013). *Performance analysis of Indian stock market index using neural network time series model*. 72-78.
- Li, A. W., & Bastos, G. S. (2020). Stock Market Forecasting Using Deep Learning and Technical Analysis: A Systematic Review. *IEEE Access*, 8, 185232-185242. <https://doi.org/10.1109/ACCESS.2020.3030226>
- Lin, Q. (2018). Technical analysis and stock return predictability: An aligned approach. *Journal of Financial Markets*, 38, 103-123. <https://doi.org/https://doi.org/10.1016/j.finmar.2017.09.003>
- Lin, X., Yang, Z., & Song, Y. (2009). Short-term stock price prediction based on echo state networks. *Expert systems with applications*, 36(3), 7313-7317.
- Lo, A. W., & MacKinlay, A. C. (1999). *A non-random walk down Wall Street*. Princeton University Press.
- Lo, A. W., Mamaysky, H., & Wang, J. (2000). Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation. *The journal of finance*, 55(4), 1705-1765.
- Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91. <https://doi.org/https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- Ou, P., & Wang, H. (2009). Prediction of Stock Market Index Movement by Ten Data Mining Techniques. *Modern Applied Science*, 3(12), 28-42. <https://doi.org/10.5539/mas.v3n12p28>
- Pennacchi, G. G. (2008). *Theory of asset pricing*. Pearson/Addison-Wesley Boston.
- Pruitt, S. W., & White, R. E. (1988). The CRISMA Trading System: Who Says Technical Analysis Can't. *Journal of Portfolio Management*, 14(3), 55.
- R. Morta, E. D. (2015). *Proposed system for predicting Buy, Hold and Sell recommendations for a publicly listed Philippine company using computational intelligence*. IEEE.
- Rao, J. (1972). *Time Series Analysis Forecasting and Control*. JSTOR.
- Richards, D. W., Rutterford, J., Kodwani, D., & Fenton-O'Creedy, M. (2017). Stock market investors' use of stop losses and the disposition effect. *The European Journal of Finance*, 23(2), 130-152. <https://doi.org/10.1080/1351847X.2015.1048375>
- Rootzén, C., H; KlÄuppelberg. (1999). A single number can't hedge against economic catastrophes. *Royal Swedish Academy of Sciences*, 28(6), 550-555.
- S. Yodphet, S. Rimcharoen, & Leelathakul. (2016). *LARG: Loss avoidance technical trading rules using genetic algorithm*. In *Knowledge and Smart" Technology (KST)*.
- Shamsuddin, A. F. M., & Kim, J. (2003). Integration and interdependence of stock and foreign exchange markets: an Australian perspective. *Journal of International Financial Markets, Institutions and Money*, 13(3), 237-254. Recuperado de <https://EconPapers.repec.org/RePEc:eee:intfin:v:13:y:2003:i:3:p:237-254>
- Tay, F. E., & Cao, L. (2001). Application of support vector machines in financial time series forecasting. *omega*, 29(4), 309-317.
- Thorp, W. A. (2000). The MACD: A combo of indicators for the best of both worlds. *American Association of Individual Investors*.
- Treynor, J. L., & Ferguson, R. (1985). In defense of technical analysis. *The Journal of Finance*, 40(3), 757-773.
- Vose, M. D. (1991). Generalizing the notion of schema in genetic algorithms. *Artificial Intelligence*, 50(3), 385-396. [https://doi.org/https://doi.org/10.1016/0004-3702\(91\)90019-G](https://doi.org/https://doi.org/10.1016/0004-3702(91)90019-G)
- Wei, L.-Y., & Cheng, C.-H. (2012). A hybrid recurrent neural networks model based on synthesis features to forecast the Taiwan stock market. *Int. J. Innov. Comput. Inf. Control*, 8(8), 5559-5571.
- Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research.

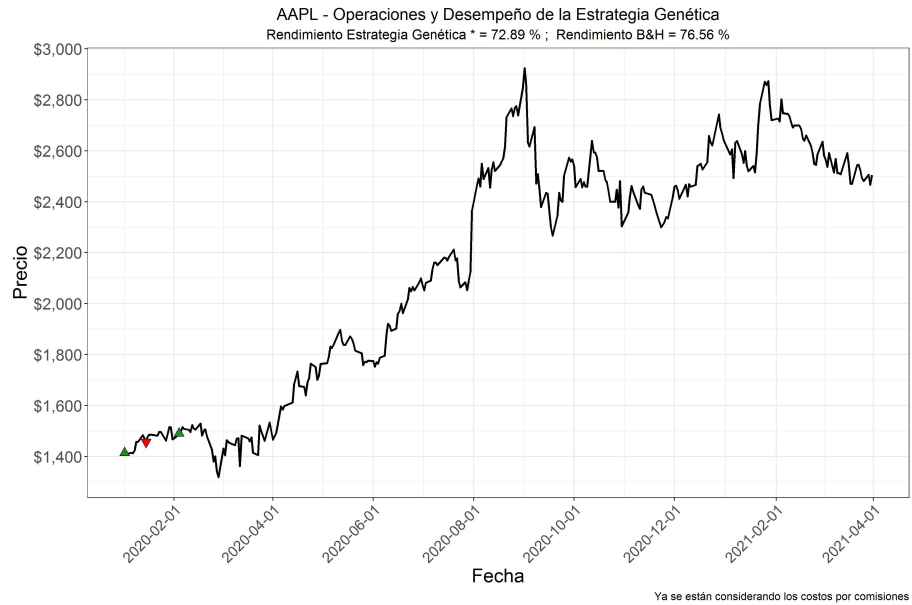


VII

Anexos



Desempeño de los activos con la estrategia genética



Operaciones de la estrategia genética para Apple



Operaciones de la estrategia genética para Alsea




BIMBOA - Operaciones y Desempeño de la Estrategia Genética
Rendimiento Estrategia Genética * = 0.73 % ; Rendimiento B&H = 22.38 %



Ya se están considerando los costos por comisiones

Operaciones de la estrategia genética para Bimbo

CEMEXCPO - Operaciones y Desempeño de la Estrategia Genética
Rendimiento Estrategia Genética = 111.48 % ; Rendimiento B&H = 100.39 %




Ya se están considerando los costos por comisiones

Operaciones de la estrategia genética para Cemex

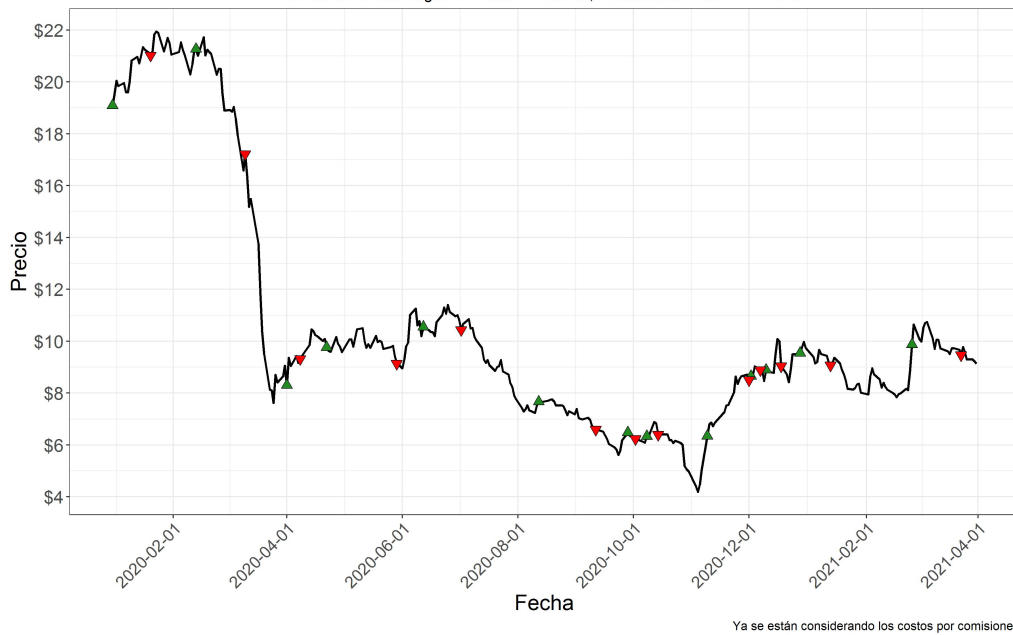


GCARSOA1 - Operaciones y Desempeño de la Estrategia Genética
Rendimiento Estrategia Genética = -19.17 % ; Rendimiento B&H = -20.34 %



Operaciones de la estrategia genética para Grupo Carso

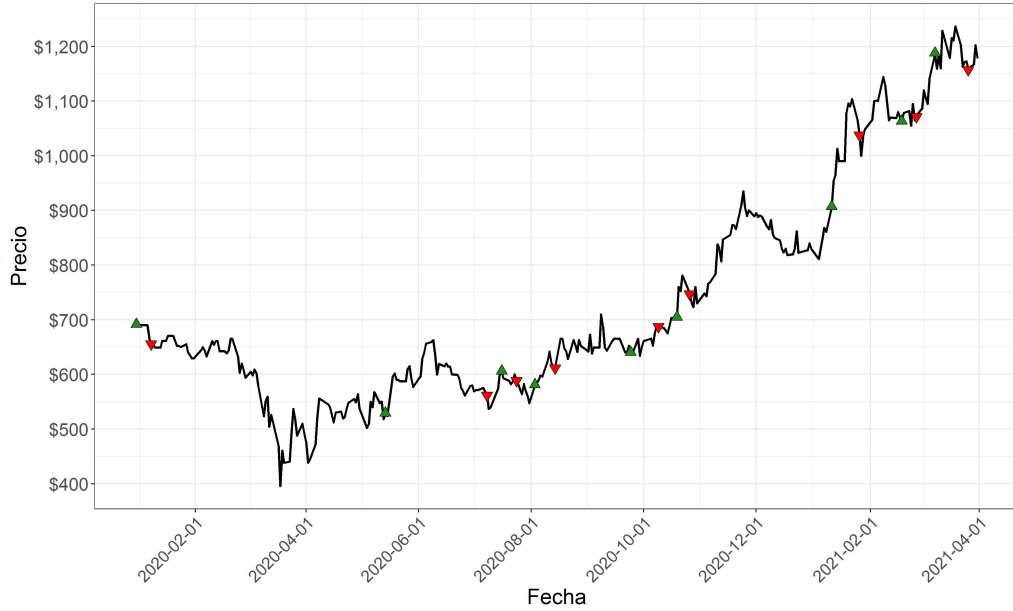
GENEREA - Operaciones y Desempeño de la Estrategia Genética
Rendimiento Estrategia Genética = -1.55 % ; Rendimiento B&H = -52.29 %



Operaciones de la estrategia genética para Gentera




GM - Operaciones y Desempeño de la Estrategia Genética
Rendimiento Estrategia Genética = 30.94 % ; Rendimiento B&H = 69.87 %



Ya se están considerando los costos por comisiones

Operaciones de la estrategia genética para GM

MGM - Operaciones y Desempeño de la Estrategia Genética
Rendimiento Estrategia Genética = 75.78 % ; Rendimiento B&H = 24.05 %




Ya se están considerando los costos por comisiones


Operaciones de la estrategia genética para MGM



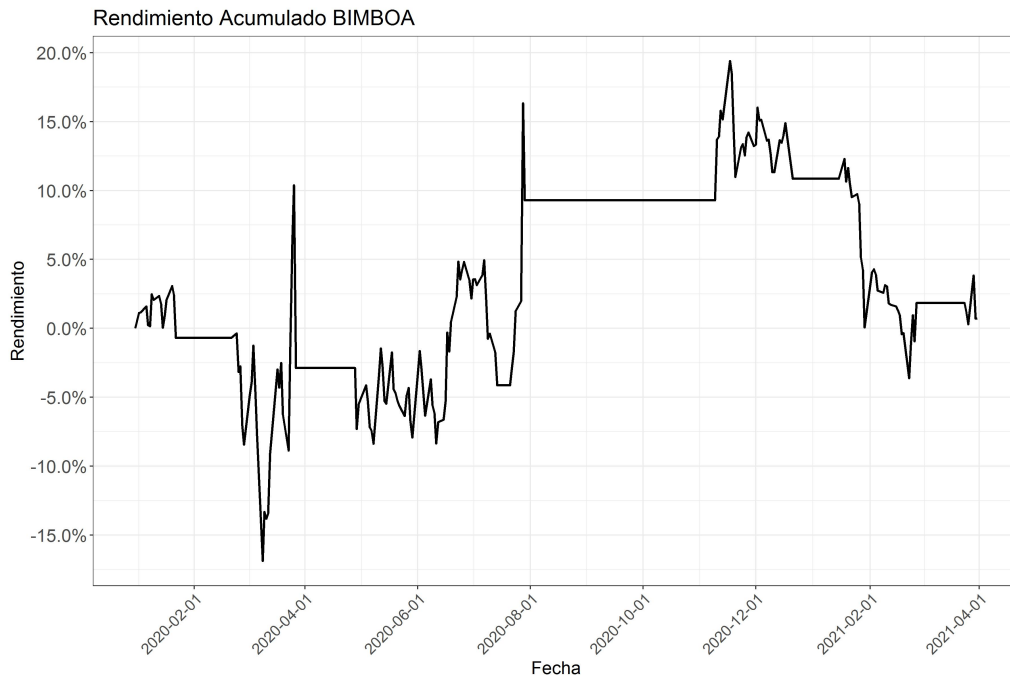
Rendimiento acumulado de los activos con la estrategia genética




Rendimiento Acumulado de Apple con la estrategia genética



Rendimiento Acumulado de Alesa con la estrategia genética




Rendimiento Acumulado de Bimbo con la estrategia genética



Rendimiento Acumulado de Cemex con la estrategia genética




Rendimiento Acumulado GCARSOA1



Rendimiento Acumulado de Grupo Carso con la estrategia genética


Rendimiento Acumulado GENTERA



Rendimiento Acumulado de Gentera con la estrategia genética




Rendimiento Acumulado GM



Rendimiento Acumulado de GM con la estrategia genética


Rendimiento Acumulado MGM



Rendimiento Acumulado de MGM con la estrategia genética

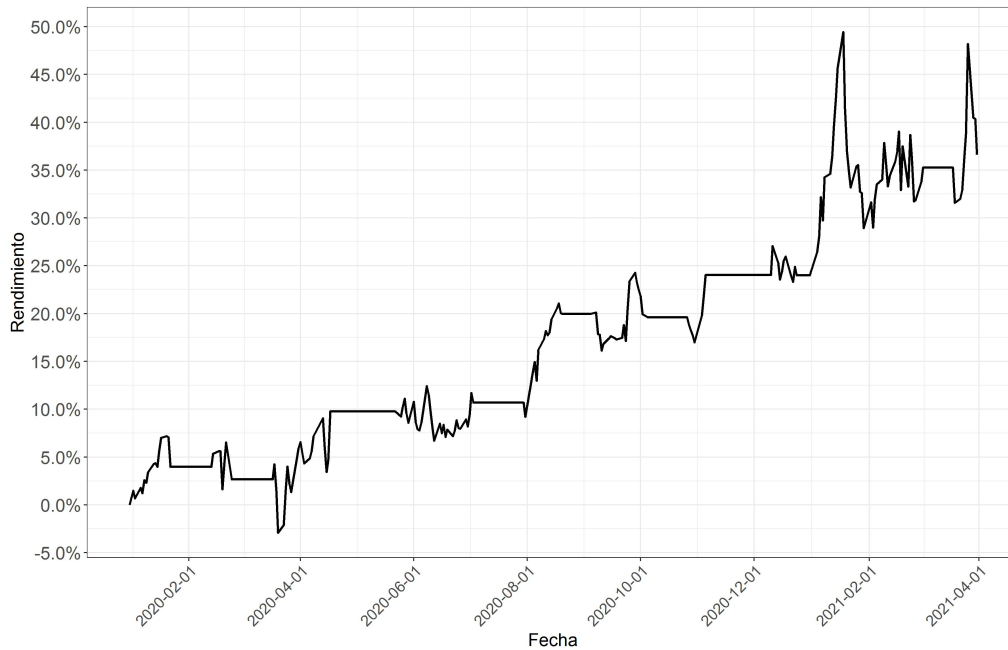


Rendimiento Acumulado PYPL



Rendimiento Acumulado de PayPal con la estrategia genética

Rendimiento Acumulado WALMEX



Rendimiento Acumulado de Walmart con la estrategia genética