



**Colegio de Estudios
Superiores de Administración**

**Optimización de Estrategia de Trading en el Colcap, a partir de la optimización
estocástica con redes neuronales.**

Nicolás Aguilera Peña

Colegio de Estudios Superiores de Administración - CESA

Maestría en Mercados Bursátiles

Bogotá

2022

Optimización de Estrategia de Trading en el Colcap, a partir de la optimización estocástica con redes neuronales.

Nicolás Aguilera Peña

Tutor: Jhon Alexander Jiménez Triviño

Colegio de Estudios Superiores de Administración - CESA

Maestría en Mercados Bursátiles

Bogotá

2022

Tabla de contenido

Capítulo I: Justificación.....	5
Capitulo II: Marco Teórico	8
Propuesta metodológica:.....	12
Optimización:	16
Costos de transacción:.....	19
Performance de la estrategia vs el Benchmark:	21
Conclusiones:.....	24
Referencias:.....	25

Abstract:

En este trabajo se evalúa una estrategia de trading teniendo como *benchmark* al *Colcap* y sus criterios de riesgo y retorno para evaluar si la optimización de la misma, mediante el uso de un software que utiliza las redes neuronales y los algoritmos genéticos como herramienta, resulta en retornos significativamente más altos que los que ofrece el índice bursátil Colombiano, teniendo en cuenta información rezagada del mismo. Esta evidencia tiene la intención de contribuir con el desarrollo del mercado de capitales en Colombia e invitar a los lectores de este documento a investigar el mismo en busca de más y mejores oportunidades de inversión. En los resultados del experimento, este trabajo descubre que mediante la estrategia descubierta se pueden obtener mejores retornos que invirtiendo en el índice *Colcap* por sí solo, lo que demuestra la hipótesis planteada que propone que mediante el uso de redes neuronales se pueden construir estrategias óptimas rentables, cuyos parámetros de riesgo y retorno son medibles y a su vez brindan la posibilidad de mejorar la asignación de recursos de inversión.

Capítulo I: Justificación.

Introducción

La presente investigación es un esfuerzo por traer a la discusión académica en Colombia los avances en modelación de series financieras, que las mejoras en el campo de la computación han hecho posible hacia los últimos 30 años. Si bien es cierto que prácticas tradicionales como la *Econometría* se beneficiaron de estos progresos para continuar evolucionando, el surgimiento de disciplinas paralelas como la *Inteligencia Artificial (IA)* y sus avances, han venido llamando la atención, especialmente en el campo de los modelos predictivos. Entre estos, pueden encontrarse los llamados *Modelos de Redes Neuronales Artificiales (RNA)*, cuyas aplicaciones a las finanzas vienen siendo materia de estudio y debate alrededor del mundo.

Puesto que la *IA* ha tenido su nicho de desarrollo en las ciencias computacionales, y los científicos financieros normalmente surgen de campos relacionados a la administración, la economía, la contaduría o la ingeniería, en consecuencia, en Colombia se ha hecho práctica común abordar la investigación cuantitativa de los mercados financieros desde la estadística y la econometría. Como resultado de este fenómeno, la gran mayoría de trabajos académicos, enfocados en el mercado accionario colombiano, se basan en modelos lineales, o, supuestos traídos de las teorías económicas que raramente hacen parte de la realidad.

Ejemplo de estos son los aportes de Sierra, Duarte y Ortiz (Sierra Suárez, Duarte Duarte, & Rueda Ortiz, 2015) y Rodríguez e Yáñez (Kristjanpoller Rodríguez & Arenas Yáñez, 2015). Como ejemplos de los otros trabajos, mucho más escasos, que se centran en una estrategia en concreto, puede encontrarse a Agudelo y Arroyave (Arroyave C & Agudelo R, 2012) quienes muestran la rentabilidad de una estrategia *ex dividendo* en distintas acciones colombianas.

Esto supone un problema puesto que, la ausencia de estudios en estas nuevas técnicas en el mercado colombiano, desincentivan la inversión en este, en consecuencia, inhibe la formación de portafolios, usando acciones colombianas, por parte de los gerentes de

inversión al no poder basar sus metodologías o estrategias en evidencia científica para soportarlas. Por otra parte, representa un costo de oportunidad en cuanto los patrimonios de los clientes y la liquidez del mercado podrían verse aumentados si se lograra sacar ventaja de los patrones encontrados mediante técnicas de *IA*.

Como resultado de la situación planteada y el problema que esto supone en cuanto a la escasez de literatura sobre estrategias, el uso desmesurado de la linealidad y la ausencia de estudios sobre la *IA* en el mercado bursátil colombiano surge la siguiente pregunta:

¿Qué tan rentable es una estrategia de trading en el *Colcap*, usando redes neuronales para optimizarla?

Responder a esta interrogante es importante ya que, como muestran Pernagallo y Torrisi (Pernagallo & Torrisi, 2019), los mercados accionarios emergentes aportan evidencia de tener memoria de largo plazo, de igual forma lo hacen Ftiti y Hadri (Ftiti & Hadhri, 2019), mostrando que es posible explotar patrones como el sesgo de la distribución de los retornos, para obtener mejores rentabilidades en los *mercados emergentes (ME)* respecto a los desarrollados. Estas son características que los modelos de *RNA* podrían explotar en busca de retornos anormales respecto a determinado benchmark o la misma aleatoriedad.

Por otra parte, responder a esta interrogante incentiva a más científicos financieros a investigar sobre las ventajas que puede tener el uso del *Machine Learning (ML)* en el mercado financiero colombiano, lo mismo que a descubrir nuevas metodologías y estrategias cuyos resultados, como por ejemplo los parámetros de riesgo y retorno, serían insumos muy valiosos para el mercado tanto en la toma de decisiones, como en la formación de portafolios más eficientes y con mejor desempeño.

Por último, resolviendo esta duda en particular, daría pie a que los traders en las mesas de dinero de Colombia, puedan anticipar movimientos en el mercado y a partir de los retornos esperados de este, generen sus propias estrategias en distintos activos relacionados al *Colcap*. Por otra parte, los fondos extranjeros que replican el *Colcap* podrían tener más demanda por sus acciones, mientras los inversionistas tratan de explotar cualquier oportunidad de arbitraje, lo cual los incentivaría a emitir más participaciones, lo mismo que a invertir más en las acciones de la *Bolsa de Valores de Colombia (BVC)*, lo cual mejoraría la liquidez en el mercado bursátil colombiano gracias al aumento en la participación tanto local como extranjera.

Con lo anterior en mente, es el propósito de este trabajo aplicar los descubrimientos que se han hecho en el campo del *ML*, especialmente en el uso de *RNA*, al mercado accionario colombiano. De manera que se pueda contribuir al acervo de casos documentados sobre el uso de esta tecnología en mercados emergentes y, por otra parte, se profundice en la discusión a nivel local sobre las características del mercado accionario colombiano bajo estas nuevas perspectivas.

Para ello, esta investigación enfoca el uso de las *RNA* a la construcción de una estrategia de *trading* en el *índice Colcap*, estudio mediante el cual se pretende, por la metodología de *backtesting*, inferir estadísticamente el riesgo y retorno de esta estrategia para mostrar su efectividad y aportes a la optimización de portafolios.

Como fue mencionado, esta investigación se centra en el *Índice Colcap*, por ser este el indicador bursátil que agrupa a las acciones con mayor capitalización bursátil en Colombia. Por otra parte, es una referencia muy observada en tanto teorías como el *CAPM* (Sharpe, 1964), proponen que este es un insumo para evaluar la rentabilidad esperada de otros activos. Añadido a lo anterior, este también replica a los *ETF's*, que son fondos de inversión que cotizan en *EEUU*, cuyos portafolios están conformados por las mismas acciones y proporciones que el *Índice Colcap*. En otras palabras, prediciendo la dirección de este índice se pueden crear estrategias para los *ETF's*, lo mismo que predecir la rentabilidad esperada en otros activos.

Complementariamente, otra razón para fijarse en el Colcap, son las investigaciones que se han hecho sobre la eficiencia de los mercados, puesto que se ha demostrado que a medida que los mercados van madurando y concentrando más participantes y liquidez, estos tienden a ser más eficientes (Sullivan, Timermann, & White, 1999). Esta circunstancia hace que sea más complicado poder explotar algún patrón para obtener rentabilidades en los mismos, véase a Gatev y Rouwenhorst (Gatev, Goetzmann, & Rouwenhorst, 2006).

Así, de acuerdo con esta lógica, ya que Colombia es un mercado emergente, o, lo que es lo mismo en desarrollo, cabe inferir que esta condición propicia el surgimiento de ineficiencias. Como ejemplo de esto puede encontrarse el mercado en Kuala Lumpur, donde Lai y Nor (Lai, Balachandher, & Nor, 2002) descubren que este, en su condición de mercado emergente, no sigue una caminata aleatoria. En cuanto a la evidencia en Colombia, Contreras, Stein y Arenas (Contreras, Stein Bronfman, & Vecino Aenas, 2015) muestran que, mediante el uso de un algoritmo, se puede encontrar que el mercado colombiano es ineficiente.

En base a lo anterior, es la hipótesis de este trabajo que, el mercado Colombiano al presentar condiciones que persisten en los mercados emergentes, como por ejemplo la baja liquidez (García, González Bueno, & Oliver, 2015), tiene, al igual que se mencionó en el párrafo anterior, ineficiencias que mediante el uso de *RNA* pueden hallarse mejor que lo harían otros modelos, ya que las *RNA* se pueden adaptar a la no linealidad en las distintas relaciones predictivas que los modelos tradicionales de la econometría no podrían detectar, a menos que se haga una búsqueda exhaustiva en la especificación del modelo.

Por lo tanto, lo mencionado anteriormente, daría al operador una ventaja sobre sus competidores, ya que puede modelar distintas relaciones con más velocidad y eficiencia, lo cual le permitiría explotar cualquier patrón o ineficiencia encontrada antes que sus competidores. Así, hace parte de la hipótesis de este trabajo, que estas ineficiencias permiten crear una estrategia cuando la red neuronal las detecta. Es decir, cada vez que la red neuronal emite una señal, se puede emprender una acción en el mercado que, ejecutada de manera sistemática, asegura que en promedio se puede salir del mercado con rentabilidades positivas. De acuerdo con lo expuesto se puede entonces encontrar o inferir cual es el retorno esperado de seguir la estrategia relacionada a la señal de la *RNA*, junto a su riesgo asociado.

Como resultado de este proceso los operadores del mercado colombiano podrán tener no solo una nueva estrategia para usar en el mercado colombiano, sino también la

posibilidad de incorporar el riesgo y el retorno asociados para construir un portafolio de estrategias en base a la señal de la *RNA* que, de acuerdo con la correlación de los activos, podrán usar para optimizar la cantidad de dinero que arriesgan en cada activo con esta estrategia.

Esto da solución al problema planteado, brindando al inversionista esa medida concreta de rentabilidad, mientras que por otra parte solucionaría muchos de los inconvenientes mencionados anteriormente como la falta de liquidez ya que con este procedimiento aplicado no solamente al Colcap, sino a otros activos en el mercado que por sus condiciones de liquidez son potencialmente ineficientes, podrían atraer inversionistas locales y extranjeros, así como la creación de más *ADRs* basados en otros activos del mercado Colombiano. Por último, atraería la atención de los científicos financieros, para en base a estos resultados profundizar en nuevas aplicaciones, variaciones o mejores procedimientos para explotar los patrones que surgen en el mercado colombiano y desarrollar los círculos virtuosos que nacen cuando los inversionistas se enteran y tratan de sacar ventaja de estos.

Capítulo II: Marco Teórico

Revisión de Literatura en Redes Neuronales y mercados bursátiles:

Comenzando la revisión literaria Wong, Wang, Goh y Quek (Goh, Wong, Wang, & Quek, 1992) dicen que las acciones y el uso de información que revela niveles de creencias pueden usarse para elaborar herramientas inteligentes mediante la modelación de redes neuronales con la intención de obtener mejores consejos de inversión.

Ese mismo año Swales Jr y Yoon (Swales Jr & Yoon, 1992) hacen al poder predictivo de las redes neuronales en términos de su discriminación cualitativa, específicamente en las calificaciones crediticias de los bonos. En base a ello, se enfocan en clasificar las firmas de acuerdo con su posición financiera, partiendo de las comunicaciones del CEO a sus inversionistas. Como resultado encuentran que hay un gran porcentaje de éxito al usar las redes neuronales como mecanismo clasificatorio, en comparación con los modelos lineales.

Al siguiente año Kryzanowski, Galler y Wright (Kryzanowski, Galler, & Wright, 1993), experimentan que el uso de redes neuronales, en lo que respecta a resultados muestrales, tiene gran potencial para el stock picking. En línea con Swales Jr y Yoon (1992), usan el modelo de redes neuronales para discriminar, usando como inputs razones financieras e indicadores contables, las acciones que tienen el potencial de generar mejores retornos que el benchmark. Como resultado, el modelo discriminó con una tasa de éxito del 66% las acciones que tuvieron mejor rendimiento.

Dos años después Kuan y Liu (Quang & Liu, 1995) usan la metodología de PSC (Predictive Stochastic Complexity) para aplicar el uso de redes neuronales a un conjunto de divisas, a partir de lo cual concluyen que no es posible generalizar el modelo. Lo anterior porque solo dos de las cinco tasas de cambio tuvieron resultados satisfactorios al

usar el modelo. Esto demuestra que el éxito de las redes neuronales depende de su compatibilidad con el activo financiero y las características de la serie financiera.

Finalizando la década Qi (Qi, 1999) propuso un backtesting a una estrategia de inversión en portafolios compuestos por acciones y bonos. Ahí descubre que las redes neuronales tienen mejor desempeño en la estrategia que el uso de modelos lineales, lo cual coincide con el hallazgo de Swales Jr y Yoon (1992), respecto a la inferioridad de los modelos lineales frente al uso de redes neuronales.

Durante el mismo año Walczak (Walczak, *Gaining Competitive Advantage for Trading in Emerging Capital Markets with Neural*, 1999) usa las redes neuronales, en el índice accionario de Singapur, para predecir la dirección que tendrá el mercado un periodo hacia adelante. Como resultado, el modelo logró predecir correctamente 60% de las veces la dirección del mercado. Este resultado se asimila al de Kryzanowski, Galler y Wright (1993) donde se demostró el poder de clasificación de las redes neuronales al predecir las acciones que superarían los retornos del benchmark.

Iniciando el nuevo milenio Walczak (Walczak, *An Empirical Analysis of Data Requirements for Financial Forecasting with Neural Networks*, 2001), evalúa el efecto que tiene la cantidad de datos sobre la calidad predictiva de las redes neuronales. Tras probar en varias series financieras, concluye que la capacidad predictiva de esta mejora cuando son entrenadas con pocos datos.

Luego Chen, Leung, Daouk (Chen, Leung, & Daouk, 2003), usan las redes neuronales probabilísticas para estimar la probabilidad que tiene el índice de la bolsa Taiwanesa de subir o bajar. El resultado mostró que las redes neuronales fueron más exitosas que los modelos tipo GMM y *Random Walk*. Así, este trabajo coincide con Walczak (1999), en tanto ambos se fijan en la predicción del signo, más que en la predicción del retorno. Por otro lado, también coincide con Walczak (2001), en que se busca la ventana de tiempo ó cantidad de datos óptima para entrenar las redes neuronales.

Un año después Versace, Bhatt, Hinds y Shiffer (Versace, Bhatt, Hinds, & Shiffer, 2004), proponen el uso de redes neuronales mixtas, en conjunción con la aplicación de algoritmos genéticos, para encontrar la arquitectura, mezcla de modelos y ventanas de tiempo óptimas para predecir el comportamiento del ETF DIA. Con este enfoque se logra encontrar una solución al problema de cuál es la forma correcta de diseñar una red neuronal.

Después, Johnson y Padilla (Johnson & Padilla, 2005) descubren que los enfoques no lineales refutan la hipótesis de mercados eficientes, y que estas relaciones no lineales pueden aproximarse mediante los modelos de redes neuronales. Esto se relaciona con el trabajo de Walczak (1999) que usa redes neuronales para explotar relaciones que no son perceptibles con los modelos lineales, lo cual también coincide con Qi (1999) y Swales Jr y Yoon (1992) quienes afirmaban sobre la superioridad de las redes neuronales frente a los modelos lineales.

Durante el periodo de la crisis financiera, Ni e Yin (Ni & Yin, 2009), exponen el uso de redes neuronales regresivas en combinación con metodologías de support vector regression y mapas de clasificación, con la intención de predecir las tasas de cambio.

Este enfoque resultó en la posibilidad de obtener mejor rentabilidad en comparación a la obtenida con los modelos de la familia GARCH.

En esa misma época, Chang, Liu, Lin, Fan y Ng (Chang, Liu, Lin, Fan, & S.P. Ng, 2009), hablan de cómo las redes neuronales, unidas a otros tipos de análisis, pueden dar señales de entrada y salida que resultan en decisiones rentables al momento de invertir en los distintos tipos de mercados (alcistas, bajistas y planos). Lo cual sugiere que las redes neuronales son solo un elemento de análisis que debe ir unido a otros hechos fácticos en el proceso de toma de decisiones de inversión.

Tres años después, Vanstone, Finnie, y Hahn (Vanstone, Finnie, & Hahn, 2012), evalúan los fundamentales de las empresas, para crear una estrategia de trading en base a las predicciones de las redes neuronales. Con esto en mente, usan como inputs indicadores contables que consideran asociados a la creación de valor obteniendo resultados muy volátiles por fuera de la muestra. De ahí concluyen que es necesario usar, en conjunto con los fundamentales, otras variables que puedan describir la volatilidad y tendencia del mercado, para obtener mejores resultados. Esta metodología se asemeja a la de Kryzanowski, Galler y Wright (Kryzanowski, Galler, & Wright, 1993), en cuanto estos usaban variables fundamentales para clasificar las empresas, lo que al contrastar ambos trabajos demuestra la importancia de comprobar la efectividad de los modelos en entornos extramuestrales.

Al siguiente año, Arango Llanos y López (Ortiz Arango, Cabrera Llanos, & López Herrera, Pronóstico de los índices accionarios DAX y, 2013) implementan el uso de redes neuronales diferenciales en el pronóstico de los índices bursátiles de Alemania y EEUU. Ahí concluyen que, en el corto plazo, el mercado es predecible y añaden la relevancia de la ventana temporal que tienen los inputs, aspecto en el que se parecen a Walczal (2001) cuando señaló la incidencia de la cantidad de datos en el resultado de las estimaciones.

Ese mismo año, Pappas y Xhafa (Evans, Pappas, & Xhafa, 2013) usan el algoritmo de “feed forward”, obteniendo distintos resultados según el tipo de arquitectura asignada a la red neuronal. La conclusión es que con este modelo se logró predecir con una tasa de éxito del 72,5% las tasas de cambio, mientras que la optimización en la estrategia de trading usando como insumo estas técnicas, rentó el 23,3% anual. De acuerdo con lo anterior, este trabajo al igual que el de Bhatt, Hinds y Shiffer (2004), muestra la relevancia de la arquitectura de las redes neuronales en sus predicciones.

En contraste Wiles y Enke (Wiles & Enke, 2014) hacen un estudio del uso de distintos modelos y algoritmos de redes neuronales para predecir los contratos de soya. En este estudio descubren que el mejor algoritmo es el *de Levenberg-Marquardt Back Propagation*, resultado opuesto al trabajo de Evans, Pappas y Xhafa (2013) en cuanto ellos proponen una metodología “*Feed Forward*”. Lo anterior muestra que distintos tipos de *Asset Class* pueden requerir algoritmos y arquitecturas de redes neuronales diferentes.

En la línea de comparación entre modelos econométricos y redes neuronales, Ortiz (Ortiz Arango, Pronóstico de precios de petróleo una comparación entre modelos GARCH y redes neuronales diferenciales, 2017) descubre que, en el WTI, el uso de redes neuronales diferenciales tiene resultados muy similares a los de la mejor especificación

encontrada para los modelos GARCH. Así, queda clara la ventaja de los modelos de redes neuronales, en cuanto al ahorro de tiempo respecto al requerido para encontrar la especificación correcta bajo el enfoque lineal.

Por otro lado, continuando con el enfoque en indicadores técnicos, Di Pierro y Sang (Sang & Di Pierro, 2019) muestran que, usando las señales de las redes neuronales, en lo que se asemejan con Chang, Liu, Lin, Fan y Ng (2009), se puede obtener mejor rentabilidad que usando otros indicadores tradicionales.

Comenzando la tercera década del siglo XXI, Carosia, Coelho y Da Silva (Palermo Coelho, De Oliveira Carosia, & Antunes Da Silva, 2021) proponen el uso de información contenida en los diarios más famosos de Brasil, para ser analizados por una red neuronal convolucional, con el fin de elaborar una estrategia de inversión que resulta ser más rentable que las estrategias de *Random Walk* y *Buy and Hold*.

Eachempati, Srivastava, Kumar, Tan y Gupta (Eachempati, Srivastava, Kumar, Tan, & Gupta, 2021) construyen una red neuronal recurrente de aprendizaje profundo bajo el modelo LSTM donde prueban que usando análisis de sentimiento a través de las redes sociales, medios financieros e información contable, se puede predecir la tendencia del mercado, en el NIFTY50, mejor que lo que lo harían otros mecanismos de machine learning. En consecuencia, proponen que la superioridad de este modelo invita a su aplicación a otros sectores y mercados mediante su recalibración.

Liu y Ma (Liu & Ma, 2022) proponen incorporar la tecnología de doble cadena y algoritmos genéticos traídos de la física cuántica, con el fin de incorporarlos a las redes neuronales y mejorar la capacidad de predicción de estas. Sin embargo, este procedimiento, aunque mejora la capacidad de predicción, aumenta el costo en tiempo y capacidad computacional requerido para poder correr estos algoritmos. Por lo anterior se sugiere pensar en cómo podrían desarrollarse estos en un ambiente de computación cuántica.

Conclusión:

Las redes neuronales han mostrado tener éxito como mecanismo clasificatorio (Swales Jr y Yoon, 1992). Estas han demostrado, por mucho, ser mejores que las estimaciones lineales (Ortiz, 2017 y Ni e Yin, 2009). Esto último hace que sean ideales en la predicción de signo (Walczak, 1999), más que en la de niveles, ya que en niveles requiere otras variables para identificar la volatilidad y la tendencia (Vanstone, Finnie, y Hahn, 2012). Por otra parte, deben hacerse predicciones a corto plazo (Ortiz Arango, Cabrera Llanos, & López Herrera, 2013), ya que pueden explotarse ineficiencias no lineales en los mercados (Johnson & Padilla, 2005), pero es crítico seleccionar la arquitectura y ventana de tiempo de inputs más óptima.

En esta última tarea los algoritmos genéticos han mostrado más eficiencia (Walczak, 2001 y Bhatt, Hinds y Shiffer, 2004), sin embargo hay que elegir entre una gran variedad de modelos, de los cuales el mejor ha sido el LSTM en comparación a otros mecanismos de machine learning (Eachempati, Srivastava, Kumar, Tan y Gupta, 2021). Por último, queda evaluar la complejidad de los algoritmos y modelos a usar puesto que su alcance y sofisticación dependen de que tanto costo computacional se pueda asumir (Liu y Ma, 2022)

Propuesta metodológica:

De acuerdo con lo presentado hasta el momento la intención central de este trabajo es correr una red neuronal con el objetivo de tomar ventaja sobre los movimientos que puede tener el índice Colcap. Para esto se tiene que seleccionar, en primera instancia, el tipo de variables y el horizonte de pronóstico en el que va a basarse este experimento. Por lo tanto, de acuerdo con Ortiz Arango, Cabrera Llanos y López Herrera (2013), esta investigación se hará en el corto plazo. Para este caso, el presente trabajo se enfocara en los movimientos diarios del Colcap. Pero en vez de predecir la dirección en la que se moverá el Colcap, al cierre de la jornada bursatil, este se centrará en un objetivo intradiario.

Lo anterior se debe a que al tomar un horizonte de tiempo diario, se va a tener más cantidad de datos, lo que por una parte hace que el experimento sea más robusto y por otra parte permite obtener buenas muestras para hacer contrastes entre los resultados muestrales y extramuestrales, entre otras cosas para evitar el error de Vanstone, Finnie, y Hahn (2012). Por otra parte, en cuanto al objetivo intradiario, aumenta las probabilidades de poder encontrar un patrón relacionado, puesto que su objetivo no es predecir el movimiento total en signo del retorno, sino si el precio logrará moverse lo suficiente hasta alcanzar cierto nivel, independientemente de si en la jornada termina alcista o bajista.

Para las variables, como lo proponen Sierra, Duarte y Ortiz (2015), para su estudio sobre la predictibilidad del mercado colombiano, usaremos información rezagada del mismo índice Colcap. Esto tiene su lógica en que, si el índice es ineficiente al ser comparado respecto a si mismo, entonces las *RNA* pueden captar estas ineficiencias al procesar los datos rezagados del índice. Por otra parte, estudios técnicos como el de *Velas Japonesas*, véase Lan, Zhang y Xiong (Lan, Zhang, & Xiong, 2011), se enfocan en los datos rezagados como las aperturas, máximos, mínimos y cierres.

Continuando con esta línea de estudios, trabajos como el de Heinz, Jamalooden, Saxena y Pollacia (Heinz, Jamalooden, Saxena, & Pollacia, 2021), muestran también la efectividad de las aperturas máximos, mínimos y cierres rezagados en la formación de patrones, con información rezagada, llamados *Engulfing patterns*. De acuerdo con esto, el presente trabajo usara como variables input para la RNA el rezago del cambio porcentual, el cambio porcentual al precio máximo, el cambio porcentual al precio mínimo y el cambio porcentual del rezago del precio de cierre al precio de apertura.

Estas variables se computaron de la siguiente forma:

Cambio porcentual al máximo: $H_t = (h_t - o_t)$, donde “o” y “h” representan el logaritmo natural de precio de apertura y máximo de forma respectiva.

Por otra parte, también está el cambio porcentual al precio mínimo que se expresa de la siguiente manera:

$L_t = (l_t - o_t)$, donde “l” es el logaritmo del precio mínimo.

En cuanto al cambio porcentual al precio de cierre, este se expresa como:

$C_t = (c_t - o_t)$, donde “c” es el logaritmo del precio de cierre.

Así, el rezago del cambio porcentual al cierre es: $C_{t-1} = (c_{t-1} - o_{t-1})$.

Por último, el cambio porcentual a la apertura es: $O_t = (o_t - c_{t-1})$.

La idea de usar estas variables es tomar la distribución de cada una de ellas teniendo en cuenta su Inter-correlación. De esta forma, se puede simular a partir de sus correlaciones y distribuciones empíricas, que niveles son adecuados para entrar, tanto en corto (*short*) como en largo (*long*), con la ayuda de las redes neuronales. Esta metodología asegura que, al simular las distribuciones, teniendo en cuenta, no solo la correlación con los máximos y mínimos, sino también la correlación con el rezago del cambio porcentual al cierre, se esté teniendo en cuenta el impacto que causa la información rezagada sobre la formación de la *vela*.

De esta forma se procede a modelar dos estrategias, una estrategia en largo y otra estrategia en corto, donde cada una de ellas tendrá de manera respectiva un punto de entrada (*E*), un punto de freno de las pérdidas (*SL*) y un punto de toma de ganancias (*TP*). Estos puntos son los que la red neuronal va a ir cambiando con la intención de maximizar, mediante un *algoritmo genético*, la riqueza y cada punto tendrá una función de activación respectiva donde la del punto de entrada será:

$$A_{E_{Largo}} = \begin{cases} 1, & \text{si } (O_t + H_t) \geq E_{Largo} \\ 0, & \text{dnc} \end{cases} \quad \forall E_{Largo} = \mathbb{R}^+ \in (0,1]$$

En cuanto a la que corresponde al punto de toma de ganancias esta será:

$$A_{TP_{Largo}} = \begin{cases} 1, & \text{si } (O_t + H_t - E_{Largo}) \geq TP_{Largo} \\ 0, & \text{dnc} \end{cases} \quad \forall TP_{Largo} = \mathbb{R}^+ \in (0,1]$$

Del mismo modo, la función de activación del freno de pérdidas (*SL*) se definirá cómo:

$$A_{SL_{Largo}} = \begin{cases} 1, & \text{si } (O_t + L_t - E_{Largo}) \leq SL_{Largo} \\ 0, & \text{dlc} \end{cases} \forall SL_{Largo} = \mathbb{R}^- \in [-1,0)$$

Con esto presente, la función de ganancias de la estrategia en *largo* será:

$$P_{Largo} = A_{E_{Largo}} ((A_{TP_{Largo}} (1 - A_{SL_{Largo}}) TP_{Largo}) + ((1 - A_{TP_{Largo}}) (1 - A_{SL_{Largo}}) (C_t + O_t - E_{Largo})) + (A_{SL_{Largo}} SL_{Largo}))$$

Por otra parte, las funciones de activación de la estrategia en *corto* serán:

$$A_{E_{Corto}} = \begin{cases} 1, & \text{si } (O_t + L_t) \leq E_{Corto} \\ 0, & \text{dlc} \end{cases} \forall E_{Corto} = \mathbb{R}^- \in [-1,0)$$

$$A_{TP_{Corto}} = \begin{cases} 1, & \text{si } (O_t + L_t) \leq TP_{Corto} \\ 0, & \text{dlc} \end{cases} \forall E_{Corto} = \mathbb{R}^- \in [-1,0)$$

$$A_{SL_{Corto}} = \begin{cases} 1, & \text{si } (O_t + H_t) \geq E_{Corto} \\ 0, & \text{dlc} \end{cases} \forall E_{Largo} = \mathbb{R}^+ \in (0,1]$$

Para una función de ganancias de la forma:

$$P_{Corto} = -A_{E_{Corto}} ((A_{TP_{Corto}} (1 - A_{SL_{Corto}}) TP_{Corto}) + ((1 - A_{TP_{Corto}}) (1 - A_{SL_{Corto}}) (C_t + O_t - E_{Corto})) + (A_{SL_{Corto}} SL_{Corto}))$$

Añadido a lo anterior también se determinará una variable de estrategia la cual tomara el valor de 1, si se debe invertir en la estrategia en *largo* cuando el rezago del cierre fue positivo, 0, si se debe invertir en el mercado independientemente de la dirección que tuvo el rezago del cierre y -1 si se debe invertir en *largo* cuando el rezago del cierre del mercado fue negativo.

Para esta variable de estrategia en *corto* esta tomará el valor de 1, si hay que invertir en la estrategia en *corto* cuando el mercado el día anterior cerró a la baja, 0, si hay que invertir en la estrategia independientemente de la dirección del cierre de mercado el día anterior y -1, si hay que invertir en el mercado cuando el rezago del cambio porcentual al cierre fue positivo.

Con esto presente podemos redefinir las estrategias cómo:

$$P_{Largo}^* = P_{Largo} * D_{Largo} \forall D_{Largo} := \begin{cases} \text{si } Estrategia_{Largo} = 1, \text{ entonces } \begin{cases} 1, & \text{si } C_{t-1} > 0 \\ 0 & \text{dlc} \end{cases} \\ \text{si } Estrategia_{Largo} = -1, \text{ entonces } \begin{cases} 1, & \text{si } C_{t-1} < 0 \\ 0 & \text{dlc} \end{cases} \\ \text{si } Estrategia_{Largo} = 0, \text{ entonces } 1 \end{cases}$$

De la misma forma redefinimos la estrategia en *corto* como:

$$P_{Corto}^* = P_{Corto} * D_{Corto} \forall D_{Corto} := \begin{cases} Estrategia_{Corto} = 1, \text{ entonces } \begin{cases} 1, & \text{si } C_{t-1} < 0 \\ 0 & \text{dlc} \end{cases} \\ Estrategia_{Corto} = -1, \text{ entonces } \begin{cases} 1, & \text{si } C_{t-1} > 0 \\ 0 & \text{dlc} \end{cases} \\ Estrategia_{Corto} = 0, \text{ entonces } 1 \end{cases}$$

Esta estrategia, que logre optimizar la rentabilidad, también será buscada por la Red Neuronal. Con esto presente, el valor del retorno después de repartir el dinero en las distintas estrategias, eligiendo a la variable "W" como la proporción de la riqueza destinada a cada una de ellas será:

$$P_{Total_t} = ((W)e^{P^*_{Largo}}) + ((1 - W)e^{P^*_{Corto}})$$

Donde la riqueza añadida por esta rentabilidad, un periodo adelante será:

$$Equity_{t+1} = Equity_t * P_{Total_{t+1}}$$

Del mismo modo por iteración se llegará al Equity o riqueza acumulada después de la 20ava apuesta.

Por último, el indicador a tener en cuenta para maximizar la riqueza será la ganancia promedio dividida entre la caída máxima de capital. Siendo esta última, la distancia absoluta máxima entre el Equity en cualquier momento dado y el Equity más bajo encontrado en cualquier momento futuro, de manera que si esta caída máxima llega a ser negativa o igual a cero la estadística computada a maximizar será castigada como un -1, de lo contrario se computará la estadística según el resultado de la simulación. Esto hará que la búsqueda de los parámetros óptimos sea más robusta y no tenga en cuenta soluciones que lleven a valores irracionales en los mismos.

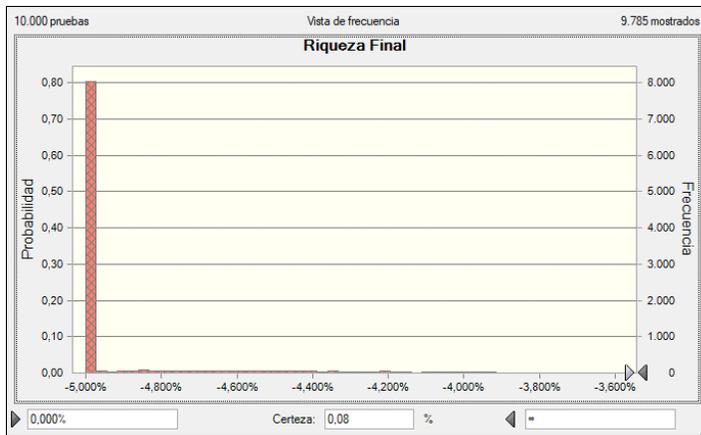
De esta forma se simularán los resultados de haber entrado en distintos puntos del mercado en 20 ocasiones de forma aleatoria y su resultado, medido por el indicador descrito anteriormente, sobre una riqueza inicial de COP \$1 miles de millones. La idea de este ejercicio es que la red neuronal encuentre cual es el punto de entrada, toma de ganancias y freno de pérdidas óptimo, para hacer que la ganancia promedio sobre la máxima caída de capital, sea lo más alta posible, luego de simular estas 20 apuestas, tantas veces como lo requiera el número de muestreos adecuados para alcanzar un error estándar promedio de 0.01% en el indicador.

Con el propósito de ver cuál es esta cantidad de simulaciones que se deben hacer para que, según el teorema central del límite (*TLC*), el promedio tenga este error elegido al gusto y perfil de riesgo del modelador, se procede resolver la siguiente formula despejando "N":

$Z = \frac{USD \$200}{\frac{\sigma_{eq}}{N}}$, asumiendo que "Z" tiene valor de 2, lo que denota aproximadamente un nivel de confianza del 95% en una distribución normal, entonces se tiene que:

$N = \left(\frac{Z\sigma_{eq}}{USD \$200}\right)^2$, donde la desviación estándar corresponde al parámetro obtenido después de hacer una cantidad arbitraria de muestreos preliminares, en este caso 500. De ahí se encontró que la desviación estándar correspondió a 0.46%, dando como resultado una cantidad de muestras de 8321 para poder alcanzar el error promedio de 0.01%, véase el histograma a continuación. Esto se hizo tomando puntos de entrada al 1% del cierre de la jornada anterior tanto al alza como a la baja para las estrategias *Long* y *Short* respectivamente. Para la toma de ganancias y freno de pérdidas se escogió también un valor arbitrario de 1% respecto al valor de entrada, finalmente para cada estrategia se escogió repartir la riqueza 50%/50%, escogiendo la estrategia de invertir siguiendo la dirección de cierre del rezago anterior simulado.

Gráfico 1: Histograma del muestreo para hallar la cantidad de muestras a simular.



Fuente: Crystal Ball, elaboración propia.

Tabla 1: Estadísticos del histograma:

SD	0,4561%
Desired MSE	0,0100%
Needed N	8.320,0274
Z	2,00

Fuente: Elaboración propia, Crystal Ball.

Optimización:

Así, se procedió con la optimización de este indicador, tomando 8,321 muestras de 20 apuestas cada una, en 5,000 iteraciones para encontrar los parámetros óptimos con la ayuda del software de *Crystal Ball*. Luego de la optimización, se obtuvieron los siguientes resultados, ver tabla 2.

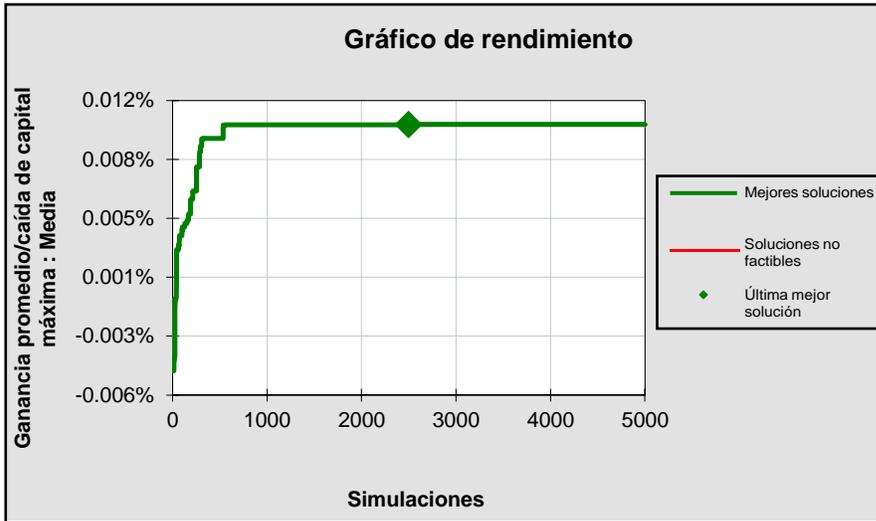
Tabla 2: Parámetros óptimos escogidos por la Red Neuronal y el Algoritmo Genético de *Crystal Ball*.

Óptimo Largo		Óptimo Corto	
Entry point	0,010%	Entry point	-0,010%
Stop Loss point	-45,246%	Stop Loss point	31,452%
Strategy	0,000%	Strategy	0,000%
Take Profit point	1,886%	Take Profit point	-100,000%

Fuente: Elaboración propia con Crystal Ball.

Estos Parámetros se escogieron luego de probar 2,428 iteraciones, donde la proporción óptima de inversión “W”, fue destinar la mitad de la riqueza a la estrategia en *Largo* y la otra mitad a la estrategia en *Corto*. En este proceso de iteración la estadística pasó de computar un -4.85% a computar un +10.38%. Esto puede observarse en el gráfico 2 a continuación.

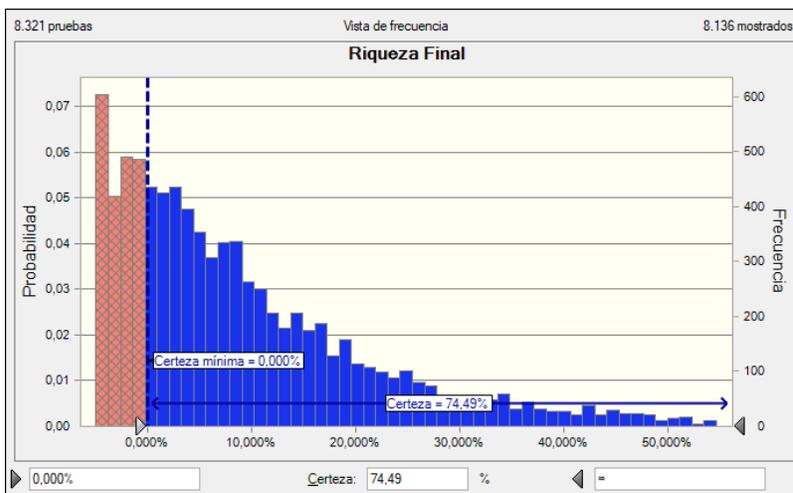
Gráfico 2: Valores máximos hallados con cada iteración para la variable objetivo a maximizar.



Fuente: Elaboración propia con Crystal Ball.

Como se ve a continuación en el gráfico 3, Las ganancias monetarias promedio divididas entre la caída máxima de capital, llegó, bajo los parámetros óptimos a tener un 74.49% de probabilidad de ser positivo luego de 20 apuestas. Dicho de otra forma, al usar los parámetros óptimos hay mayor probabilidad de terminar con más capital tras apostar varias veces en el mercado a que la estrategia tendrá resultados.

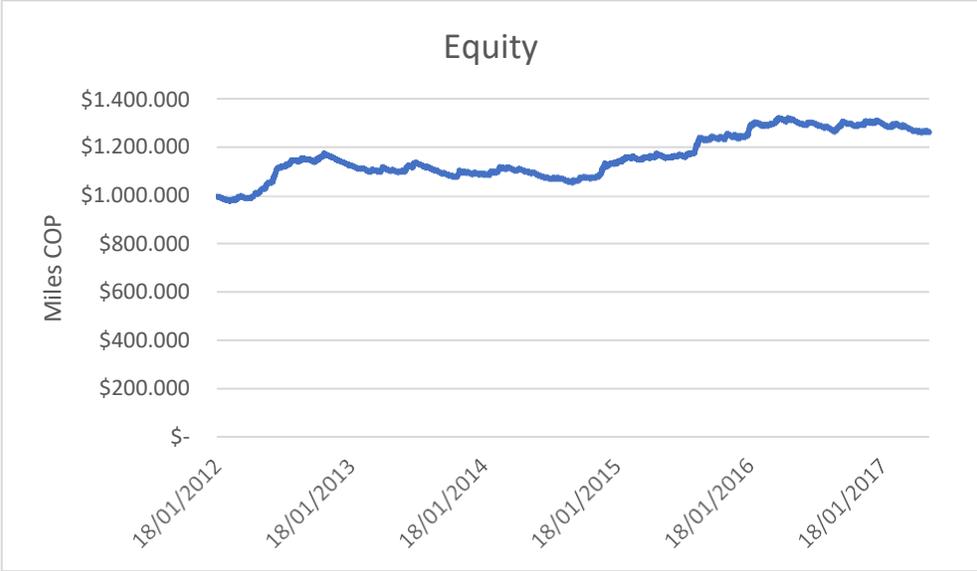
Gráfico 3: Distribución de la ganancia promedio dividida entre la caída máxima de capital, en 20 apuestas, usando parámetros óptimos de la simulación.



Fuente: Elaboración propia con Crystal Ball.

Lo mencionado en el párrafo anterior puede verse con más claridad al haber usado la estrategia en los datos intra-muestrales, donde, asumiendo costos de transacción del 0.1% se logró multiplicar el capital de COP \$1 miles de millones a COP \$1.26 miles de millones desde enero del 2012 hasta mayo del 2017, para un retorno de +4.41% EA.

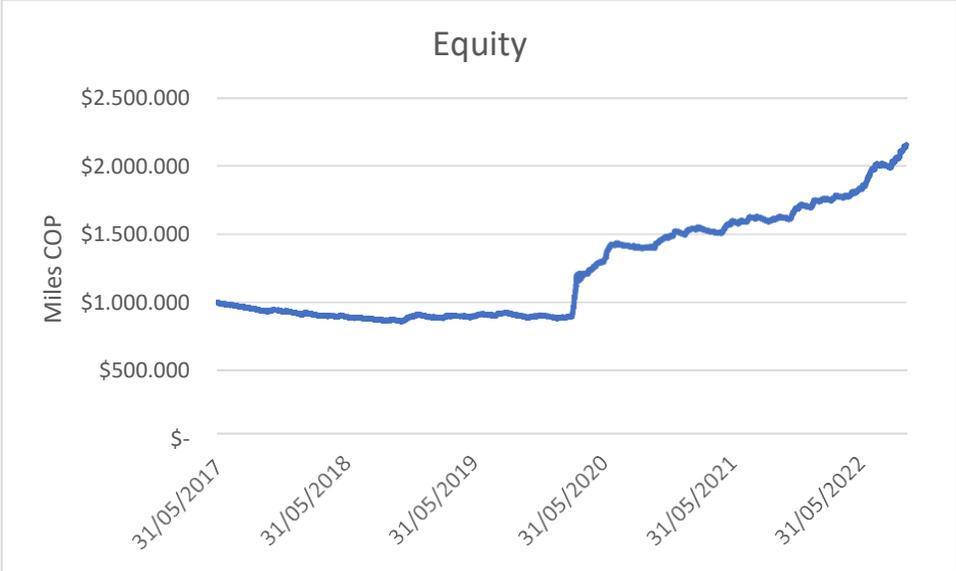
Gráfico 4: Ingresos intra-muestrales de haber invertido en la estrategia.



Fuente: Elaboración propia.

En cuanto al resultado extra-muestral, este transformo COP \$1 miles de millones en COP \$2.15 miles de millones entre mayo del 2017 y octubre del 2022, para un retorno de +15.38% EA asumiendo costos de transacción del 0.1%, véase el gráfico 5.

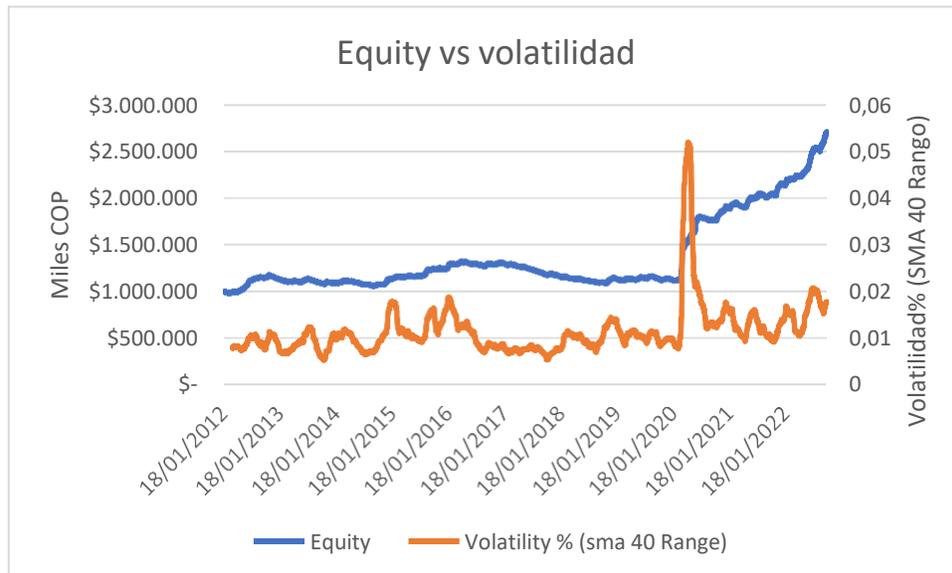
Gráfico 5: Curva de Equity resultado de aplicar la estrategia en los datos extra-muestrales.



Fuente: Elaboración propia.

De este resultado es preciso resaltar que la estrategia muestra mejores resultados a partir de la fecha del surgimiento del COVID-19 como una pandemia mundial, lo cual imprimió volatilidad en los mercados. De esto se puede deducir que, esta estrategia es más efectiva en periodos de alta volatilidad. Esto se puede apreciar en el gráfico 6 donde, cuando el promedio de la volatilidad llegó a oscilar alrededor y por encima del 1%, la estrategia dio mejores rendimientos que cuando la volatilidad estuvo por debajo del 1%. Véase el gráfico a continuación:

Gráfico 6: Estrategia y volatilidad.



Fuentes: Elaboración propia.

Costos de transacción:

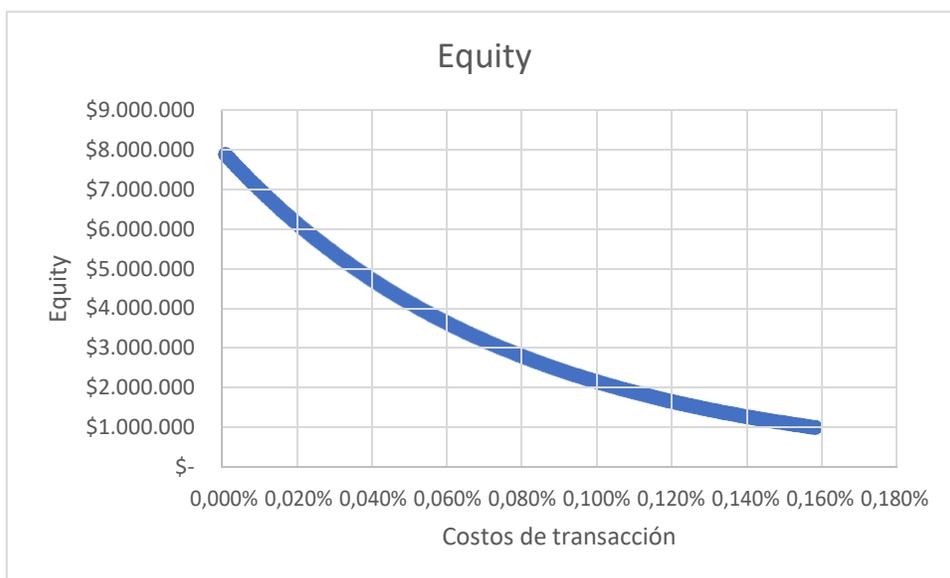
Como se puede observar en el gráfico 7, los costos de transacción tienen gran incidencia en el desempeño de la estrategia en entornos de volatilidad. Como se puede observar, el Equity final tiene una caída exponencial a medida que los costos de transacción incrementan. Haciendo una transformación logarítmica y regresando el logaritmo natural del Equity final respecto a los costos de transacción (*CT*) se puede observar que cada 0,01% de incremento en los costos de transacción llevan a un cambio porcentual compuesto continuo del Equity de -13,08%. Lo que muestra la importancia de entrar en esta estrategia, no solo entornos de alta volatilidad, sino que también en entornos de alta liquidez. Debido a que muchas plataformas de negociación presentan costos de comisión nulos, se puede entender que todos los costos de transacción reposan sobre el Spread al cual se negocian. De forma que el incentivo más importante para los inversionistas será un costo bajo de spread.

Con esto presente podemos encontrar que, en los datos simulados, el costo de transacción a partir del cual el Equity final permanecería inalterado sería:

$\frac{\ln(COP\ 1M)-m}{b} = CT$, donde “CT” sería el costo de transacción que mantiene inalterada la riqueza al final de los datos por fuera de la muestra, “b” es la pendiente de la regresión y “m” es el punto de corte de la regresión. Esto muestra que ese costo de transacciones a partir del cual sería óptimo invertir en la estrategia sería de aproximadamente 0,158%. De esta forma hay dos mecanismos distintos mediante los que se podría entrar al mercado.

Poniendo de ejemplo la estrategia en *largo*, el primer mecanismo es esperar a que, si el *bid* no ha tocado el *TP* y el precio se dirige a la baja en el intradía, entonces se puede entrar en la estrategia apenas el *offer* esté por debajo del punto de entrada. La otra estrategia es sencillamente ver que el spread sea lo suficientemente bajo como para representar menos del 0,158% mientras el *bid* sea igual o menor al del punto de entrada de la estrategia, al mismo tiempo que todavía no se haya alcanzado el *TP*.

Gráfico 7: Incidencia de los costos de transacción sobre el Equity final.



Fuente: Elaboración propia.

Tabla 3: resultados de la regresión entre el logaritmo natural del Equity y los costos de transacción:

<i>Estadísticas de la regresión</i>	
Coefficiente de correlación múltiple	1
Coefficiente de determinación R ²	1
R ² ajustado	1
Error típico	7,3E-15
Observaciones	158

	<i>Coe</i>
Intercepción	
CT	

Fuente: Elaboración propia.

Performance de la estrategia vs el Benchmark:

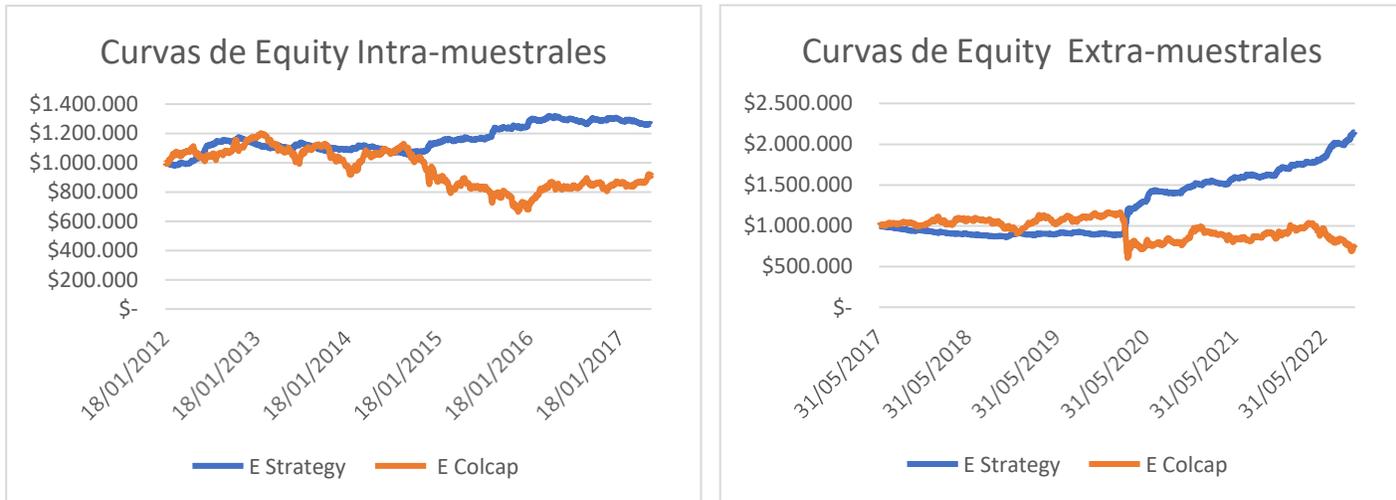
Para este análisis se decidió tomar como *Benchmark* al Colcap, debido a que nuestro problema está enfocado en Colombia y este último refleja el riesgo sistemático al que se ven expuestos los inversionistas con algún tipo de interés en los equities locales. Por la misma lógica, al centrarse la estrategia en una inversión intradiaria en el Colcap, el Benchmark elegido también debe reflejar el riesgo sistemático al que se ve expuesta la estrategia. De esta forma, se proceden a hacer dos análisis para evaluar el rendimiento de la estrategia con relación al Benchmark, donde la estrategia se puede entender, a su vez, como si fuera el resultado de invertir en las acciones de una empresa que se dedica a comprar y vender el Colcap intradiario, de acuerdo a las reglas de optimización encontradas. Así, se procedió a comparar la evolución del equity en cada una de estas estrategias para elegir la de mejor rendimiento, mediante distintas metodologías como lo son la comparación gráfica, el capture ratio, una regresión y el information ratio.

De esta forma, como se aprecia en el gráfico 8, la curva de Equity de la estrategia (*E Strategy*) se mantuvo más estable que la del Colcap (*E Colcap*), desde la fecha que comenzó hasta aproximadamente la mitad de la muestra, momento a partir del cual el Colcap comenzó a descender en consecuencia a la coyuntura de la economía colombiana, con el consecuente incremento de la volatilidad, que terminó favoreciendo a los retornos de la estrategia, mientras los retornos del Colcap continuaban siendo en su mayor parte negativos.

Algo similar ocurrió en los datos extra-muestrales, donde el Colcap, al final de los datos intra-muestrales empezó a mostrar una recuperación que lo llevó a tener retornos más estables y comenzar su curva de equity en los datos extra-muestrales con una baja volatilidad. Esto causó que la estrategia tuviera peores rendimeintos que el mismo Colcap, hasta aproximadamente la mitad de los datos, donde de nuevo resurgió la volatilidad como

consecuencia de la repentina caída en el Colcap. Lo anterior hizo que la curva de equity de la estrategia tomara la delantera y lograra aumentar en mayor medida el patrimonio respecto al Benchmark.

Gráfico 8: comparación gráfica de ambas estrategias en datos intra-muestrales y extra muestrales.



Fuente: Elaboración propia.

En cuanto al *Capture Ratio*, como se observa en la tabla 4, se puede ver qué, tanto en la muestra, como fuera de ella, el *upside capture* estuvo cercano al nivel del 0.5, lo que sugiere que la estrategia captura aproximadamente la mitad del movimiento alcista del Benchmark. Más interesante aún, es el *downside capture*, que en ambas muestras estuvo muy cercano al nivel de 0.3, indicando que cada vez que el Benchmark baja, la estrategia captura cerca de 0.3 veces ese movimiento. Estos resultados sugieren que, los buenos resultados de la estrategia provienen de que cuando el Benchmark baja la estrategia captura menos de la mitad del movimiento bajista, pero cuando el Benchmark sube, la estrategia captura más de este movimiento, esto se ve claramente en los *Capture Ratio* de las dos muestras, que superan el nivel de 1.

Tabla 4: Capture Ratio de la estrategia en los datos intra-muestrales y extra-muestrales.

In Sample		Out of Sample	
Upside Capture	0,482	Upside Capture	0,598
Downside Capture	0,300	Downside Capture	0,285
Capture ratio	1,607	Capture ratio	2,101

Fuente: Elaboración propia.

Al evaluar el *Information Ratio* (IR) se puede notar que, como muestra la tabla 5, tanto dentro como por fuera de la muestra, el retorno promedio de la estrategia fue mayor al del Benchmark, aunque al comparar estas diferencias en los promedios con el *Tracking Error*

(TE), se puede notar que la estrategia apenas logra retener de un 2,% a un 5% de su diferencia en retornos con el Colcap. Estos montos tan bajos en el *IR*, podrían indicar que, aunque la cifra es positiva podría tratarse de un efecto que no es significativo. Con esto presente se propone el análisis de regresión a continuación.

Tabla 5: *Tracking Error*, retornos promedio e *Information Ratio* de la estrategia respecto al *Benchmark*.

In Sample		Out of Sample	
TE	0,951%	TE	1,625%
Avg Strategy	0,018%	Avg Strategy	0,059%
Avg Colcap	-0,007%	Avg Colcap	-0,024%
IR	2,568%	IR	5,115%

Fuente: Elaboración propia.

Análisis de Regresión:

Para despejar la incertidumbre sobre si los retornos entre la estrategia y el *Benchmark* son distintos de cero, como en primera instancia sugiere el *Capture Ratio* y en segunda el *Information Ratio*, entonces se procede a hacer un análisis de regresión entre los retornos del *Colcap* y los retornos de la estrategia, para ver su significancia tanto dentro como por fuera de la muestra. Con esto presente, se evalúa la significancia del intercepto en la regresión lineal usando los retornos del *Colcap* como variable independiente y los retornos de la estrategia como variable dependiente, donde, como puede verse en la tabla 6, en las dos muestras el intercepto fue significativamente positivo al nivel del 5% de significancia estadística, demostrando que, a pesar de que el *IR* estuvo cercano a cero, estos valores son robustos y su signo positivo es consistente con la hipótesis de que la estrategia genera mejores retornos que el *Benchmark*. Al pasar los datos de los interceptos expresados en retornos diarios a retornos anuales se puede ver que dentro de la muestra el patrimonio de la estrategia retorna aproximadamente un 6.54% EA más que el *Benchmark*, mientras que fuera de la muestra el retorno en exceso aumentó considerablemente a un 22% EA.

Tabla 6: Intercepto de la regresión y valor-p entre los retornos de la estrategia y el *Benchmark* para los datos dentro y fuera de la muestra.

In Sample		Out of Sample	
Intercepción	0,017%	Intercepción	0,054%
Probabilidad	2,049%	Probabilidad	0,000%

Fuente: Elaboración propia.

Conclusiones:

De este ejercicio podemos concluir que como lo preveía la hipótesis, en escenarios de alta volatilidad del *Colcap*, la *Red Neuronal* del *Crystal Ball* junto el *Algoritmo Genético* para hacer optimizaciones estocásticas, lograron encontrar a través de la simulación de las distribuciones empíricas y la incidencia del rezago anterior en ellas, una estrategia optima que logra explotar las ineficiencias que el mercado sufre, específicamente en altos entornos de variabilidad de precios. Especialmente cuando la *desviación estándar* del *Colcap* logra mantenerse en promedio igual o superior al target del 1%. En línea con lo propuesto se logró optimizar una estrategia de trading que logró encontrar puntos de entrada y salida en una estrategia *long/short*, maximizando las adiciones promedio al equity como proporción de la máxima caída de capital simulada. Esto llevo a un mecanismo de mercado que logra aumentar el equity del inversionista en comparación con los retornos que ofrece una estrategia *buy and hold* en el mismo *Colcap* (Benchmark).

Por otra parte, se logró demostrar que la superioridad de la estrategia frente al *Benchmark* no es un resultado aleatorio o de simple error de percepción, ya que, al someterla a las pruebas de *Capture Ratio*, *Information Ratio* y Regresión lineal, siendo el tercer test una confirmación de los dos primeros, se logró encontrar que el patrimonio resultante de la estrategia es no solo mayor que el del *Benchmark*, sino también significativamente más rentable, lo que deja abierta la posibilidad de ir a una fase superior donde, a manera de un laboratorio, se pueda poner esta estrategia en practica para evaluar los efectos de la misma en un entorno de mercado real y sujeto a las demás fricciones de los mismos, como lo es el *Market Latency* y los distintos y cambiantes entornos de liquidez.

En otras cosas, se encontró que para que estas estrategias rindan frutos, es necesario asegurar unos costos de transacción bajos, para este caso menores a aproximadamente 0,158% con respecto al precio de cierre anterior, más específicamente en costo por spreads, cuyos altos valores obligarían a los operadores a agredir un *offer (bid)* más bajo (alto) que el precio de entrada, para ejecutar la estrategia en *largo (corto)*. Sin embargo, esto requeriría de la experticia y paciencia de los operadores, mientras que si se logra una alternativa de mercado para que los spreads puedan representar un costo de transacción inferior al sugerido, los inversionistas tendrían incentivos para aumentar la demanda por los ETF's lo cual conviene a los fondos por sus ganancias en comisiones y a la bolsa colombiana, porque los fondos aumentarían la demanda por activos locales, por último, también ganarían los inversionistas al poder explotar una estrategia que les acabaría dando rendimientos.

Para finalizar, respecto al futuro de la estrategia, mientras los mercados continúen mostrando inestabilidad, se espera que, ante las tasas históricas de inflación, la necesidad de mantener las políticas monetarias restrictivas, el consecuente efecto sobre la economía mundial de las tasas altas y los ciclos económicos más cortos a causa de los factores explicados anteriormente, se mantenga la incertidumbre y alta volatilidad alrededor de los distintos activos. Con esto presente, se prevé que esta estrategia pueda seguir vigente hasta que nuevas medidas de liquidez logren transmitirse a los mercados y se traduzcan en menos volatilidad, lo que significará rangos menos amplios en el futuro y la disminución en la probabilidad de que los precios alcancen los niveles de toma de ganancias una vez abiertas las operaciones, lo que se traducirá en más pérdidas y un deterioro de la rentabilidad de la estrategia.

Referencias:

- Arroyave C, E. T., & Agudelo R, D. A. (2012). Rendimiento ex-dividendo como indicador de eficiencia en un mercado emergente: caso colombiano 1999–2007. *Journal of Economics Finance and Administrative Science*, 38-47.
- Chang, P.-C., Liu, C.-H., Lin, J.-L., Fan, C.-Y., & S.P. Ng, C. (2009). A neural network with a case based dynamic window for stock trading prediction. *Expert Systems with Applications*, 6889–6898.
- Chen, A.-S., Leung, M. T., & Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers & Operations Research*, 901–923.
- Contreras, O. E., Stein Bronfman, R., & Vecino Aenas, C. E. (2015). Estrategia de inversión optimizando la relación rentabilidad-riesgo:. *ESTUDIOS GERENCIALES*, 383-392.
- Eachempati, P., Srivastava, P. R., Kumar, A., Tan, K. H., & Gupta, S. (2021). Validating the impact of accounting disclosures on stock market: A deep neural network approach. *Technological Forecasting & Social Change*.
- Evans, C., Pappas, K., & Xhafa, F. (2013). Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation. *Mathematical and Computer Modelling*, 1249-1266.
- Ftiti, Z., & Hadhri, S. (2019). Asset allocation and investment opportunities in emerging stock markets: Evidence from return asymmetry-based analysis. *Journal of International Money and Finance*, 187-200.
- García, F., González Bueno, J. A., & Oliver, J. (2015). Mean-variance investment strategy applied in emerging financial markets: Evidence from the Colombian stock market. *Intellectual Economics*, 22-29.
- Gatev, E., Goetzmann, W. N., & Rouwenhorst, K. G. (2006). Pairs Trading: Performance of a Relative-Value Arbitrage Rule. *The Review of Financial Studies*, 797-828.
- Goh, T. H., Wong, F. S., Wang, P. Z., & Quek, B. K. (1992). Fuzzy Neural Systems for Stock Selection. *Financial Analysts Journal*, 47-74.
- Heinz, A., Jamaloodeen, M., Saxena, A., & Pollacia, L. (2021). Bullish and Bearish Engulfing Japanese Candlestick patterns: A statistical analysis on the S&P 500 index. *The Quarterly Review of Economics and Finance*, 221-224.
- Johnson, C. A., & Padilla, M. A. (2005). REGULARIDADES NO LINEALES EN ÍNDICES ACCIONARIOS: Una aproximación con redes. *El Trimestre Económico*, 765–821.
- Kryzanowski, L., Galler, M., & Wright, D. W. (1993). Using Artificial Neural Networks to Pick Stocks. *Financial Analysts Journal*, 21–27.

- Kristjanpoller Rodríguez, W., & Arenas Yáñez, T. (2015). El efecto fin de mes en los principales mercados accionarios latinoamericanos. *Contaduría y Administración*, 53-86.
- Lai, M.-M., Balachandher, K. G., & Nor, F. M. (2002). An Examination of the Random Walk Model and Technical Trading Rules in the Malaysian Stock Market. *Quarterly Journal of Business and Economics*, 81-104.
- Lan, Q., Zhang, D., & Xiong, L. (2011). Reversal Pattern Discovery in Financial Time Series Based on Fuzzy Candlestick Lines. *Systems Engineering Procedia*, 182-190.
- Liu, G., & Ma, W. (2022). A quantum artificial neural network for stock closing price prediction. *Information Sciences*, 75-85.
- Ni, H., & Yin, H. (2009). Exchange rate prediction using hybrid neural networks and trading indicators. *Neurocomputing*, 2815–2823.
- Oracle. (29 de 10 de 2022). *docs.oracle.com*. Obtenido de https://docs.oracle.com/cd/E17236_01/epm.1112/cb_user/toc.htm
- Ortiz Arango, F. (2017). Pronóstico de precios de petróleo una comparación entre modelos GARCH y redes neuronales diferenciales. *Investigación Económica*, 105-126.
- Ortiz Arango, F., Cabrera Llanos, A. I., & López Herrera, F. (2013). Pronóstico de los índices accionarios DAX y. *Contaduría y Administración*, 203-225.
- Palermo Coelho, G., De Oliveira Carosia, A. E., & Antunes Da Silva, A. E. (2021). Investment strategies applied to the Brazilian stock market: A methodology based on Sentiment Analysis with deep learning. *Expert Systems with Applications*.
- Pernagallo, G., & Torrisi, B. (2019). An empirical analysis on the degree of Gaussianity and long memory of financial returns in emerging economies. *Physica A: Statistical Mechanics and its Applications*, 121296.
- Qi, M. (1999). Nonlinear Predictability of Stock Returns Using Financial and Economic Variables. *Journal of Business & Economic Statistics*, 419–429.
- Quang, C.-M., & Liu, T. (1995). Forecasting Exchange Rates Using Feedforward and Recurrent Neural Networks. *Journal of Applied Econometrics*, 347–364.
- Sang, C., & Di Pierro, M. (2019). Improving trading technical analysis with TensorFlow Long Short-Term Memory (LSTM) Neural Network. *The Journal of Finance and Data Science*, 1-11.
- Sharpe, W. F. (1964). Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *The Journal of Finance*, 425-442.
- Sierra Suárez, K. J., Duarte Duarte, J. B., & Rueda Ortíz, V. A. (2015). Predictibilidad de los retornos en el mercado de Colombia e hipótesis. *ESTUDIOS GERENCIALES*, 411-418.
- Sullivan, R., Timermann, A., & White, H. (1999). Technical Trading Rule Performance, and the Bootstrap. *The Journal of Finance*, 1647-1691.
- Swales Jr, G. S., & Yoon, Y. (1992). Applying Artificial Neural Networks to Investment Analysis. *Financial Analysts Journal*, 78–80.

- Vanstone, B., Finnie, G., & Hahn, T. (2012). Creating trading systems with fundamental variables and neural networks: The Aby case study. *Mathematics and Computers in Simulation*, 78–91.
- Versace, M., Bhatt, R., Hinds, O., & Shiffer, M. (2004). Predicting the exchange traded fund DIA with a combination of genetic algorithms and neural networks. *Expert Systems with Applications*, 417–425.
- Walczak, S. (1999). Gaining Competitive Advantage for Trading in Emerging Capital Markets with Neural. *Journal of Management Information Systems*, 177–192.
- Walczak, S. (2001). An Empirical Analysis of Data Requirements for Financial Forecasting with Neural Networks. *Journal of Management Information Systems*, 203–222.
- Wiles, P. S., & Enke, D. (2014). Nonlinear Modeling using Neural Networks for Trading the. *Procedia Computer Science*, 234 – 239.