



Universidad de San Andrés

Trabajo de Graduación
Licenciatura en Finanzas

Análisis técnico: desarrollo e implementación de estrategia automatizada de trading de alta frecuencia con un modelo de redes neuronales.

Autores:

Juan Cao Lavignolle (28025) y Justo Ballester (28012)

Tutor:

Gabriel Basaluzzo

Buenos Aires, Argentina, febrero 2022

Índice

1. Introducción	3
2. Sobre análisis técnico	6
3. Sobre algoritmos financieros	7
4. Revisión de la literatura	8
5. Datos	11
6. Metodología	12
6.1. Indicadores	13
6.2. Modelo	16
6.3. Periodo de Estimación.....	18
6.4. Algoritmo	21
7. Resultados	24
7.1. Evaluación del modelo	24
7.2. Comparación de estrategias	27
8. Conclusión	29
9. Bibliografía	30
10. Anexo	31



Resumen

En este trabajo proponemos desarrollar una estrategia de trading algorítmico de alta frecuencia para múltiples activos. Los activos son de renta variable *-equity-* y son seleccionados del índice SP500. Proponemos una estrategia capaz de ser automatizada con el fin de administrar la cartera de manera activa y maximizar los resultados.

El período de estudio comienza el 1 de febrero de 2021 y finaliza el 14 de mayo 2021 y consta de datos con una frecuencia cada 10 minutos. La estrategia está basada en 5 indicadores de análisis técnico; medias móviles, índice de fuerza relativa, Momentum y bandas de Bollinger. Proponemos un modelo predictivo de redes neuronales que utiliza la información de los indicadores para intentar predecir si el precio del activo considerado va a aumentar o disminuir. La predicción es utilizada por otro algoritmo que se encarga de determinar qué tipo operación de mercado se debe implementar; compra, venta o neutral.

Una vez que el modelo está definido, comparamos los resultados con un modelo alternativo y una estrategia de compra pasiva. Para definir el mejor modelo consideramos aspectos financieros como el rendimiento y la volatilidad. También consideramos aspectos estadísticos como la *Sensibilidad*, *Accuracy* y el *F1-Score*. Con esto se busca que el modelo no solo tenga rendimientos significativamente mejores que el *benchmark* sino que también sea estadísticamente superior.

1. Introducción

El Análisis Técnico (AT) es un proceso por el cual se realizan predicciones de tendencias futuras basadas exclusivamente en información histórica de mercado. Las variables consideradas suelen ser precios de apertura, precios de cierre, mínimos, máximos y volumen de transacciones. El análisis técnico es una herramienta reconocida y utilizada en el mercado financiero. En un estudio desarrollado en 1992 demuestran que el 90% de los profesionales que operan en el mercado Forex utiliza esta metodología como elemento crítico dentro de sus decisiones profesionales (Prodomos et al., 2016). El AT suele ser utilizado para llevar adelante estrategias de asignación táctica de activos (*tactical asset allocation*). Esto es, ajustar dinámicamente las posiciones de un portafolio para mejorar la relación entre riesgo y rendimiento. En este trabajo utilizaremos los siguientes indicadores e instrumentos de AT: medias móviles, índice de fuerza relativa, *momentum* y bandas de Bollinger.

En este trabajo se diseña un modelo estadístico predictivo para el desarrollo de un sistema de *trading* algorítmico de alta frecuencia utilizando algunos de los indicadores más populares del análisis técnico. Los resultados de la estrategia obtenida serán comparados con los rendimientos de una estrategia de inversión pasiva y un modelo de regresión lineal.

Una estrategia de alta frecuencia requiere analizar datos en grandes cantidades y en tiempos reducidos. Por esto, resulta primordial que la descarga de datos, su análisis y la posterior toma de decisiones sea ejecutada por medio de algoritmos computacionales. Además, una estrategia automatizada permite la escalabilidad ya que se pueden monitorear cientos de activos en simultáneo. Se reducen los tiempos necesarios para la implementación y esto permite que se procese información de más activos, aumentando las probabilidades de encontrar señales que generen -estadísticamente- mayor rentabilidad. Por último, se elimina toda subjetividad que podría estar presente en el proceso de implementación. El AT es una disciplina de interpretación - a veces matemática y a veces gráfica- que depende de cada practicante. Con un algoritmo que decide numéricamente se elimina cualquier posibilidad de actuar distinto en circunstancias prácticamente iguales.

Se propone como campo de aplicación el mercado accionario de los Estados Unidos. Mercados más grandes implican mayor volumen de transacciones y mayor liquidez que reducen los costos de transacción y las diferencias entre precios de compra y venta (Prodomos et al., 2016). El mercado americano es el mercado más grande del mundo. En enero de 2021 la capitalización bursátil de los mercados americanos más que triplicaba al segundo más grande del mundo, el mercado de Shanghái. La capitalización bursátil de la suma de ambos mercados (NYSE y NASDAQ) fue 45 billones en comparación a los 6.5 billones del mercado de Shanghái y casi 12 billones si consideramos el segundo mercado chino, el Shenzhen Stock Exchange¹. Considerando, que se plantea una estrategia de alta frecuencia, donde se podrían abrir y cerrar posiciones en períodos de 10 minutos, es esencial reducir los costos de transacción al mínimo. El mercado accionario de Estados Unidos parecería cumplir con estas características.

Sin embargo, en un mismo mercado hay acciones más negociadas que otras. Aquellas con menor volumen tienen un precio de compra proporcionalmente mayor que el precio de venta (conocido como *spread*). Para evitar este problema se opta por estudiar acciones del SP500, un índice diversificado con las empresas públicas más grandes de las distintas industrias de Estados Unidos. Con las 500 empresas que componen el índice se abarca, en promedio, más del 80% de la capitalización bursátil de todo el mercado². Además, las estrictas políticas de inclusión del índice generan que la información de estas acciones sea extensa, clara y de fácil acceso.

Al limitar el estudio a los componentes del SP500 sería razonable utilizar el propio índice como punto de comparación o *benchmark*. Sin embargo, no es una comparación adecuada debido a que los 15 activos seleccionados podrían tener un rendimiento superior al del SP500. En consecuencia, utilizamos a modo de comparación la compra pasiva de los 15 activos considerados. Los resultados obtenidos a lo largo de este trabajo se comparan con los resultados obtenidos por la compra de una cartera ponderada en partes iguales de los 15 activos en consideración. Se

¹ Disponible en <https://www.statista.com/statistics/270126/largest-stock-exchange-operators-by-market-capitalization-of-listed-companies/#:~:text=The%20New%20York%20Stock%20Exchange,Exchange%2C%20and%20Tokyo%20Stock%20Exchange.>

² <https://www.spglobal.com/spdji/en/indices/equity/sp-500/#overview>

compara rendimiento y volatilidad para poder atribuir las diferencias a las estrategias que se plantean a lo largo del trabajo.

En primer lugar, se seleccionan un conjunto de indicadores de análisis técnico y se adaptan para procesar información intra diaria definiendo un umbral para puntos de entrada y salida. Se incluye una estrategia de inversión pasiva para comparar resultados. Para el desarrollo de una estrategia óptima se combinan algunos de los indicadores por medio de algoritmos predictivos. Utilizamos dos, redes neuronales y regresiones lineales. En esta instancia se consideran dos series temporales por separado pero consecutivas; en la más antigua se construyen y ajustan las estrategias (base de estimación) y en la más reciente, se evalúa el rendimiento de las estrategias (base de pruebas). Las estrategias serán evaluadas en dos aspectos. Por un lado, se evalúa la estrategia de inversión considerando retornos y volatilidades. Por el otro, se evalúa el algoritmo con porcentajes de aciertos y errores, cantidad de órdenes abiertas entre otras métricas operativas.

Este trabajo cuenta con nueve secciones. En la segunda sección (*2. Sobre análisis técnico*) haremos un breve repaso sobre los conceptos clave del análisis técnico. Luego, en *3. Sobre algoritmos financieros* recorreremos algunas de las características clave a la hora de realizar un algoritmo aplicado a las finanzas. En la sección cuatro (*4. Revisión de la bibliografía*) exponemos algunos estudios relacionados con la automatización de estrategias de *trading* complementados con el uso de modelos estadístico-predictivos con elementos del AT. En la sección (*5. Datos*) se explica brevemente como está compuesta la base que se utiliza para el trabajo. En la sección (*6. Metodología*) se exponen las fórmulas utilizadas para la composición de los indicadores que vamos a utilizar, la composición del algoritmo y el manejo de riesgo que vamos a estar aplicando en nuestra estrategia. En la sección (*7. Resultados*) exponemos los resultados finales del algoritmo basados en las señales tanto del modelo de redes neuronales como el modelo de regresión lineal, comparándolos entre sí. A su vez comparamos ambos modelos con una estrategia de compra pasiva. En la sección (*8. Conclusiones*) analizamos los resultados expuestos a lo largo del trabajo determinando posibles falencias y mejoras para futuros estudios. En la sección (*9. Anexo*) se presentan algunos datos relevantes a la investigación realizada. Finalmente, la última sección (*10. Bibliografía*) se detalla el material utilizado en el trabajo.

2. Sobre análisis técnico

El Análisis Técnico puede ser definido como un marco metodológico basado en el análisis gráfico de evoluciones históricas de precios. Dicho análisis es utilizado para la predicción de precios futuros con el objetivo de generar inversiones rentables. Algunos elementos clave dentro de este marco son resistencias y soportes, continuación y reverso de tendencias, puntos de cambio y precios objetivo. Estos elementos son utilizados con el fin de identificar y clasificar el comportamiento reiterativo de los participantes del mercado, para una posterior generación de señales de compraventa. Es decir que un indicador cumple la función de, en el marco de una estrategia, impulsar una señal de mercado que pueda ser comprar el título correspondiente, venderlo o tomar una posición neutral (Prodomos et al., 2016).

El AT se utiliza de manera subjetiva tanto en la definición de los indicadores como en la interpretación gráfica de la evolución de precios. La subjetividad es tal que dos practicantes de análisis técnico pueden identificar patrones completamente opuestos con la misma información (Prodomos et al., 2016). El componente de subjetividad que tiene el AT genera una discusión entre profesionales que lo relacionan con el arte y otros con la ciencia. Esta dicotomía puede ser desarrollada explorando los conceptos de *inversión discrecional* (puramente subjetiva) e *inversión cuantitativa* (mayoritariamente objetiva).

La inversión discrecional se caracteriza por la toma de decisiones basadas en “intuición” que, se suele adquirir por medio de experiencia (Kestner, 2003). Sin embargo, son pocos los practicantes que pueden generar rentabilidad sostenida en el tiempo utilizando este método.

La inversión cuantitativa hace referencia a la generación de la estrategia y a la ejecución de órdenes de manera objetiva. Para ello propone utilizar testeos con el método científico y especifica tres elementos clave. La creación de una hipótesis que ha de ser evaluada con una serie histórica de precios. Se simula la implementación de la estrategia seleccionada para obtener

información bruta y su posterior procesamiento. Finalmente, obtener conclusiones de los datos que permitan comparar distintas estrategias, obtener resultados y retroalimentar el modelo seleccionado con esta nueva información procesada.

Un estudio generado por *The Barclays Group* evaluó los resultados de un grupo de inversores cuantitativos y otros discrecionales durante 1996 y 2001. Los resultados fueron categóricos: las estrategias cuantitativas lograron un rendimiento promedio anual de 7.12% en comparación de un 0.58% de las inversiones discrecionales (Kestner, 2003). Con estos resultados y las nuevas capacidades computacionales se procede a desarrollar un algoritmo automatizado que ejecute una estrategia cuantitativa.

3. Sobre algoritmos financieros

Un algoritmo se define como un conjunto de instrucciones para llevar adelante una tarea. Un algoritmo de *trading* es un conjunto de reglas claras y bien definidas para llevar adelante transacciones bursátiles para la administración de un portafolio. Una práctica común es definir las reglas en dos subgrupos: las reglas *macro* son aquellas relacionadas con la estrategia mientras que las reglas *micro* tienen que ver con la ejecución y tecnicismos (Jhonson, 2010). Por ejemplo, una regla macro es comprar cuando el precio sube al menos un 5%. La micro, hacerlo con un *orden límite* o con un *orden de mercado*. Al establecer esta segmentación se logra definir diversas funciones (i.e. reglas) de manera individual que en conjunto hacen a una estrategia integral. Esto permite modificar o agregar funcionalidades a una estrategia ya desarrollada de manera más eficiente.

Existen distintos tipos de algoritmos de *trading* y se pueden categorizar en tres. En primer lugar, los *schedule-driven*, que tienen como objetivo seguir una estrategia definida sin importar las condiciones generales del mercado. Generalmente estas estrategias están basadas en datos históricos. Luego tenemos los algoritmos oportunistas, aquellos que buscan reaccionar cuando el mercado general se encuentra en alza y reducir la operatoria cuando el mercado se encuentra a la

baja. Son considerados algoritmos dinámicos pues su manera de operar se adapta. Finalmente tenemos los algoritmos evaluativos que son un punto medio entre los primeros dos. Suelen comportarse como algoritmos *schedule-driven* a nivel macro, pero como oportunistas en niveles micro.

4. Revisión de la bibliografía

Los trabajos académicos que consideramos para nuestra investigación son aquellos que se centran en análisis técnico, validan empíricamente distintos indicadores e incluyen algoritmos predictivos como redes neuronales o regresiones logísticas. Si bien la mayoría de los estudios tienen como característica una frecuencia baja (datos diarios o semanales) para el desarrollo de las estrategias planteadas, existen varios trabajos que utilizan una frecuencia más alta, de hasta un minuto entre un dato y otro.

La optimización de estrategias utilizando algoritmos predictivos se ha popularizado con el auge de la tecnología y se pueden encontrar varios estudios de carácter científico desde hace ya varios años. Por ejemplo (Mizuno et al., 1998) utilizan el mercado de Japón como objeto de estudio, e implementan un modelo de redes neuronales para predecir los precios futuros. La red se entrena utilizando una serie de indicadores técnicos entre ellos, medias móviles, índice relativo de fuerza (RSI) y línea psicológica. Se logró un 63% de efectividad en las predicciones hechas por el algoritmo y obtuvieron un rendimiento anualizado de 20% comparando con un 21% obtenido con una estrategia de compra pasiva del mercado de Japón (TOPIX). Si bien prácticamente no hay diferencias entre ambas estrategias, sucede que en periodos con tendencia alcista una estrategia de compra pasiva de mercado suele obtener relativamente buenos resultados. En estos casos, comprar y mantener el activo en cartera genera retornos mayores que la compra y venta de alta frecuencia.

En (Sezer et al., 2017) se entrena un modelo de redes neuronales diferenciando dos aspectos algorítmicos esenciales: las señales de compra/venta y la determinación de tendencias del mercado.

Para el primero se utiliza exclusivamente el RSI mientras que para el segundo medias móviles. El trabajo plantea una comparación a nivel individual de cada activo que compone el índice *Dow Jones Industrial Average* (DJIA). En los resultados se incluye costos fijos de un dólar por cada transacción. Con información diaria de 29 empresas del 2006 al 2017 superan la estrategia de compra pasiva en un 16% de retorno de los activos con un modelo de redes neuronales. Una vez más, los resultados no se destacan demasiado por sobre la estrategia pasiva. Sin embargo, el algoritmo logró un 70% de efectividad en las transacciones ejecutadas. Es decir, 7 de cada 10 operaciones cerraron con retornos positivos. En caso de poder replicar la efectividad con tendencias bajistas, el algoritmo tendría potencialmente resultados por encima de la estrategia de compra pasiva.

Los modelos estadísticos predictivos tuvieron un gran avance en los últimos años. Las mejoras dieron lugar al incremento en la cantidad de modelos, lo que aumentó la variedad de estos para la utilización en estudios de características científicas, entre otras actividades. El estudio (Dash and Dash, 2016) compara rendimientos obtenidos por distintos modelos: redes neuronales, máquinas de vector soporte (*support vector machine*), modelos bayesianos naive, K vecinos más cercanos y árboles de decisión. Para entrenar los modelos se normalizan las variables (indicadores técnicos) a valores entre cero y uno. Valores cercanos a uno implican una señal de compra, cercanos a cero implican señales de venta y posiciones neutras son representadas con valores cercanos a 0,5. Este proceso es necesario para que los indicadores que generen valores nominales mayores por construcción no se impongan sobre aquellos que generen valores menores.

La literatura sugiere que el modelo de redes neuronales es la estrategia más efectiva para predecir los movimientos en los precios en baja frecuencia. Las redes neuronales se han vuelto populares en el tratamiento de las series financieras por su capacidad de procesar relaciones no lineales. Otros modelos como los árboles de decisión autorregresivos (CART) también mostraron tener buenos resultados. Estos modelos tienen la gran ventaja de ser de fácil interpretación. Por otro lado, los modelos que asumen linealidad, como los ARIMA o los GARCH, generalmente, no obtienen buenos resultados ya que las series de precios financieros suelen ser no lineales, no estacionarias y tener componentes aleatorios (Obi, 2019). Si bien el modelo de redes neuronales

parece ser el mejor, no hay mucha evidencia con datos de alta frecuencia. Por esto, a lo largo del trabajo utilizamos un modelo de redes neuronales que comparamos también con un modelo de regresión lineal.

Se menciona en (Chordia et al., 2013) que las estrategias de alta frecuencia son, en palabras de la Comisión de valores de Estados Unidos (SEC), aquellas que tienen la capacidad de generar grandes números de transacciones en cortos períodos de tiempo, por lo general menores a un día. Se caracterizan por ser ejecutadas con computadoras extremadamente rápidas, posiciones que se mantienen abiertas en cartera durante cortos períodos de tiempo y cerrando posiciones al final del día.

El impacto de las estrategias de alta frecuencia en el mercado es sujeto de estudio en numerosos informes. Algunos profesionales sugieren que las operaciones de alta frecuencia no son más que operaciones a mayor velocidad por lo que no tendrían impacto en el mercado (Chordia et al., 2013). Por otro lado, Hasbrouck y Saar (2013, citado en Chordia et al., 2013, p. 2 y 3) validan empíricamente que las estrategias de alta frecuencia son beneficiosas para el mercado en general. Más específicamente, en esta publicación se prueba que cuando hay un aumento en las transacciones de alta frecuencia se reduce drásticamente la volatilidad de corto plazo, reduciendo las diferencias de los precios de compra-venta y generando una mayor profundidad en el mercado. Estos beneficios fueron validados tanto en mercados alcistas como bajistas.

Otra de las preguntas relacionadas a la alta frecuencia trata la rentabilidad asociada a este tipo de estrategias. (Carrion 2013), citado en (Chordia et al., 2013, p. 5), hace referencia a esta cuestión. Según los resultados obtenidos en este estudio, se identificó que las estrategias de alta frecuencia generan una mayor rentabilidad agregada, en promedio, cuando se la utiliza para ofrecer liquidez y generan resultados negativos cuando demandan liquidez. En este caso no se incluyen las transacciones entre estrategias de alta frecuencia ya que la hipótesis estaba planteada sobre los resultados agregados que las mismas generan en el mercado. Otros estudios en donde se incluyen estas transacciones demuestran resultados positivos en ambos, ofreciendo y demandando liquidez.

De todas formas, las estrategias de alta frecuencia requieren de mercados desarrollados capaces de procesar decenas de miles de órdenes y cancelaciones. Esto se da cuando las estrategias son llevadas a cabo por grandes fondos que tienen la capacidad de modificar los precios con sus órdenes.

En el trabajo (Obi, 2019) se consideran ventanas temporales de un minuto para el desarrollo de su estrategia. Se comparan 8 modelos predictivos y tres de ellos obtienen resultados notablemente superiores: Árboles de decisión, *Random Forests* y *Boositng* de gradiente extremo. La metodología del trabajo es la siguiente: si el modelo predice que el activo va a subir de precio, entonces se compra en la próxima ventana y se vende automáticamente al cierre de la misma. Es decir, las posiciones están abiertas un minuto excepto que la señal vuelva a sugerir que el activo debe ser comprado nuevamente. Con información de una semana, se ejecutaron un total de 527 operaciones y los resultados multiplicaron por 10 a los retornos de una estrategia de compra pasiva.

5. Datos

Los datos utilizados se obtuvieron del API (Aplicación de Interfaz de Programación) de TD AmeriTrade, un *bróker* de inversores minoristas de Estados Unidos, y consisten en una serie temporal que comienza el 1 de febrero de 2021 y finaliza el 14 de mayo 2021. La frecuencia es de 10 minutos y el total de observaciones por empresa seleccionada es de 2928. Con respecto a las empresas, se seleccionaron 15 empresas del SP500. Las 15 empresas son seleccionadas de distintas industrias para validar que la estrategia desarrollada funcione de manera similar sin importar el sector. En la Tabla 1 se pueden ver las empresas seleccionadas y su industria.

Tabla 1: Empresas del SP500 consideradas a lo largo del trabajo

TICKER	COMPAÑÍA	SECTOR
T	AT&T	Servicios de comunicación
HAS	HASBRO	Consumo discrecional
AMZN	AMAZON	Consumo discrecional
KO	Coca-Cola Company	Consumo básico
CL	Colgate-Palmolive	Consumo básico
OXY	Occidental Petroleum	Energía
MMC	Marsh & McLennan	Financiero
JPM	JPMorgan Chase & Co.	Financiero
CVS	CVS Health	Salud
GILD	Gilead Sciences	Salud
TXT	Textron Inc.	Industria
INTC	Intel Corp.	Tecnología
XEL	Xcel Energy Inc	Utilidades
WRK	WestRock	Materiales
ARE	Alexandria Real Estate Equities	Bienes Raíces
SPY	sp 500	Índice

6. Metodología

Un sistema de estrategias tiene tres bloques definidos: entradas, salidas y filtros (Kestner, 2003). Las entradas consisten en señales que indican la apertura de nuevas posiciones en largo o en corto. Los bloques de salidas indican que una posición debe cerrarse pues las expectativas se ven afectadas negativamente. Finalmente, los filtros tienen el objetivo de que solo se ejecuten las operaciones con mejor perspectiva de ganancias.

Con respecto a las entradas y las salidas nuestro sistema de estrategia utiliza 4 indicadores con un procesamiento previo. Como parte de ese procesamiento el primer paso consiste en detectar matemáticamente los puntos de compra y venta que generan estos indicadores. Como segundo paso estos puntos de compra y venta se utilizan como *inputs* dentro de la generación de un modelo predictivo que termina de generar las señales de compraventa a utilizar por el algoritmo.

Finalmente se aplican filtros por medio de un algoritmo que determina si estas señales van a ser de entrada o de salida. Al mismo tiempo, el algoritmo administra el riesgo de la cartera, determina la factibilidad de las señales y las categoriza en bloques de entrada o salida.

A continuación, haremos un repaso de todo este proceso en detalle comenzando por la generación de las señales de compraventa de cada uno de los indicadores, siguiendo por la composición del modelo y la generación de las señales que este mismo nos devuelve, y finalmente revisaremos los filtros generados por el algoritmo que determinan de qué manera utilizar las señales del modelo.

6.1. Indicadores

El primero, y uno de los más conocidos, es la media móvil (MA por sus siglas en inglés) que consiste en promediar el precio en los últimos períodos de manera recursiva. La cantidad de datos que se ponderan puede variar y suele ser elegido por el operador. Hay distintas formas de computar la media móvil. Nosotros consideramos dos. La media móvil tradicional (MA) consiste en promediar los últimos precios de una serie de tiempo de manera recursiva hasta llegar a la observación más reciente de la serie. Mientras menos datos se consideren, más sensible a cambios es el indicador (Prodomos el al., 2016).

$$MA_t = \frac{P_t + P_{t-1} + \dots + P_{t-n+1}}{n} \quad \forall t \in [n, l],$$

donde t es el momento temporal al que le corresponde el indicador calculado,

n es la cantidad de datos que se quiere considerar

l es la observación más reciente

Por otro lado, la Media Móvil Exponencial (EMA) toma las observaciones más recientes dándoles una mayor ponderación que las antiguas con la utilización de un parámetro lambda ($0 < \lambda < 1$). Se multiplica el precio de hoy por el parámetro lambda y el EMA de ayer por la diferencia entre 1 y lambda. El primer dato (EMA_0) es una media móvil simple.

$$EMA_t = (1 - \lambda) EMA_{t-1} + \lambda P_t \quad \forall t \in [l - w + 1, l],$$

donde λ es el multiplicador

t es el momento en el que estamos parados

P el precio del activo para cada momento considerado

l la observación más reciente

w el ancho de la muestra, es decir la cantidad de datos que se quiere considerar para calcular el indicador

Las señales de compra ocurren cuando el precio supera el valor de la media móvil y las de venta cuando el precio cruza de arriba hacia abajo la media móvil. También, se pueden establecer señales con dos medias móviles en simultáneo con distintos n . Cuando la media móvil con menor n supera el valor de la media móvil de mayor n es una señal de compra mientras que cuando la de mayor n supera a la de menor n es una señal de venta. A esta estrategia se la conoce como cruce de medias móviles (Prodomos et al., 2016).

Otro indicador que utilizamos es el Índice Relativo de Fuerza (RSI), que es un oscilador técnico que varía entre 0 y 100 introducido por J. Welles Wilder Jr. en 1978 (Prodomos et al., 2016). El primer paso para su cálculo es seleccionar qué ventana temporal (w) se utilizará. Suele ser común utilizar 14 días. Luego, definir los cambios positivos y negativos según la siguiente fórmula con t entre $[2; l]$ donde l es la observación más reciente. Es decir, t se mueve entre la segunda observación de la base y la última l iterando de a uno a la vez.

$$\Delta P_t^+ = \max(P_t - P_{t-1}, 0) ,$$

$$\Delta P_t^- = |\min(P_t - P_{t-1}, 0)| .$$

Es decir, se calculan $n - 1$ cambios positivos y negativos. Luego, la fuerza relativa (RS) se calcula dividiendo la suma de los valores de los cambios positivos por la suma de los valores de los cambios negativos.

$$RS_{t|w} = \frac{\sum_{t=t-w+1}^t \Delta P_t^+}{\sum_{t=t-w+1}^t \Delta P_t^-} \quad \forall t \in [l - w + 1, l]$$

donde l es la observación más reciente

t es el momento del tiempo

ΔP el cambio en el precio

w la cantidad de datos que se consideran para cada valor el RS para cada momento del tiempo t

El Índice de Fuerza Relativa, que es el indicador sobre el cual tomaremos decisiones, toma los siguientes valores dependiendo si el RS está definido o no (el divisor es distinto a cero).

$$RSI_{t|w} = \begin{cases} 100 & \text{si } \sum_{t=t-w+1}^t \Delta P_t^- = 0 \\ 100 - \frac{100}{1 + RS_{t|w}} & \text{otro} \end{cases}$$

Para las señales de compra y venta del RSI es necesario definir bandas inferiores y superiores. Es de práctica común usar un valor de 30 como límite inferior y 70 como límite superior. Cuando el RSI cruza el límite inferior con tendencia alcista se considera como señal de compra. Las señales de venta se generan cuando el RSI perfora el límite superior con tendencia bajista.

Otro de los indicadores que utilizamos es el de *Momentum* (MOM) que se define como la resta entre el precio actual y algún precio pasado:

$$MOM_{t|n} = P_t - P_{t-w} \quad \forall t \in [l-w+1, l] ,$$

donde t es el momento del tiempo

w es la cantidad de periodos pasados se define saltar para restarle al precio actual

l es la observación más reciente

w igual a 12 es lo más usado en la práctica (Rosillo et al 2013). Para obtener señales de entrada se utiliza una media móvil simple sobre los MOM de n períodos que se conoce como línea de señal (SL). De esta forma, se logra una línea atenuada en los cambios y un conjunto de reglas para la toma de decisiones. Cuando el MOM cruza de abajo hacia arriba al SL es una señal de compra mientras que cuando lo hace de arriba hacia abajo es una señal de venta.

Las bandas de Bollinger (BB) es el último indicador que utilizamos para la construcción de la estrategia. Fueron introducidas por J. Bollinger la década de 1980 (Prodomos et al., 2016) y consisten en tres bandas clasificadas como superior, mediana e inferior. La mediana es una media móvil simple (SMA). La banda inferior consiste en la resta entre la SMA y su desvío estándar mientras que la superior consiste en la suma de la SMA y su desvío estándar. El desvío estándar está acompañado por un factor de multiplicación K que suele ser 1,5. El n que se suele usar para computar la media móvil y su desvío suele ser de 20 días. Las señales de compra se dan cuando el precio excede la banda superior (con tendencia alcista) o quiebra la banda inferior también con tendencia alcista. Por el contrario, las señales de venta se dan cuando el precio quiebra la banda superior (con tendencia bajista) o excede la banda inferior de arriba hacia abajo.

6.2. Modelo

Con una tabla de datos de estimación por acción, y un total de 15 tablas, utilizamos un único modelo para todos los activos. Para esto, juntamos las bases de cada activo dentro de una base final como muestra la Tabla 2.

Tabla 2: Composición de la base final utilizada para el entrenamiento del modelo

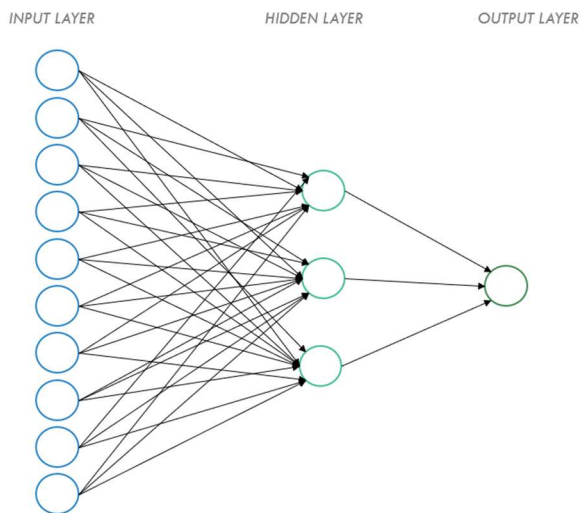
Activo 1	[0, 2328]
Activo 2	[2328, 4656]
[...]	[...]
Activo 15	[32592, 34920]

Mediante este proceso se pierde la linealidad temporal que tenían las bases. Cada vez que cambia de acción la fecha se reinicia al valor inicial y el total de las 34920 observaciones deja de presentar una secuencia continúa en el tiempo. De todas formas, esto no afecta el rendimiento del modelo ya que para la toma de decisiones el modelo genera un resultado para cada período independientemente de las predicciones o datos pasados.

En el trabajo proponemos trabajar con un modelo de redes neuronales. Los modelos de redes neuronales consisten en capas de procesamiento de información con el objetivo de encontrar patrones que permitan generar predicciones sobre la variable dependiente. Las capas suelen estar divididas en tres categorías: la primera capa, llamada capa de entrada, recibe la información inicial; la segunda capa, denominada como capa oculta, busca identificar patrones procesando la información de la capa inicial; por último, la capa de salida devuelve las predicciones finales del modelo.

En el modelo planteado en este trabajo la capa de entrada considera todos los indicadores de la base explicados anteriormente. En esta capa hay una neurona para cada indicador con un total de 10 neuronas. Debido a la cantidad de variables de nuestra base, nuestro modelo consta de una capa oculta donde se procesa la información generada por la capa de entrada. Aquí se proponen 5 neuronas donde cada una procesa, en diferente medida, la información otorgada por cada una de las neuronas de la primera capa. Finalmente, la información generada por la capa oculta sirve de *input* a nuestra última capa: la capa de salida. Esta última capa otorga como *output* la probabilidad de que la acción suba o baje en los próximos 5 períodos. El modelo de redes seleccionado es secuencial y en consecuencia el resultado de una capa es el *input* de la próxima capa. No se permite que el resultado de una capa sirva como *input* para una capa anterior. En la Figura 1 presentamos la estructura de un modelo secuencial como el que utilizamos.

Figura 1: estructura de las capas de una red neuronal



Por último, en el entrenamiento del modelo utilizamos la base de datos 100 veces para la reducción del error y calibración³ de las predicciones. El *batch size*, cantidad de datos que el modelo procesa antes de ajustar los parámetros para reducir la función de error, está definido en 10; es decir que el modelo utiliza parámetros (inicialmente aleatorios) y luego de procesar 10 datos se ajustan los parámetros según el error obtenido. Este proceso se itera hasta utilizar cada uno de los datos de la base 100 veces.

6.3. Periodo de Estimación

En el período de estimación utilizamos el 80% de los datos de la base para entrenar y calibrar el modelo buscando maximizar la capacidad predictiva. Los datos de precios considerados se extienden desde el 1 de febrero de 2021 (10:30 hs) hasta el 26 de abril de 2021 (17:00 hs). Para cada uno de los activos se considera un total de 2342 observaciones dado que se obtiene un dato cada 10 minutos.

Con los precios de cierre considerados computamos los indicadores (6. Metodología) para entrenar al modelo. Cada indicador es calculado dos veces cambiando la ventana temporal y, en el

³ Epoch = 100 como se lo conoce en la literatura de machine Learning

caso del RSI, los parámetros utilizados para computar el indicador. Se consideran un total de 10 variables. En la Tabla 3 se puede observar el detalle:

Tabla 3: Indicadores y sus parámetros utilizados

	MA	EMA	RSI	MOM	BB
Ventana 7 períodos	-	-	Low = 35 High = 65	-	K = 1.5
Ventana 14 períodos	-	-	Low = 30 High = 70	-	K = 1.5

Computar los indicadores con 14 períodos de ventana implica que recién en el período 15 se obtienen valores para poder tomar decisiones. De la misma forma, los indicadores con 7 períodos de ventana presentan resultados a partir del octavo período. Para poder entrenar el modelo con los 10 indicadores a lo largo de toda la base eliminamos los indicadores con ventana de 7 días computados entre el período 8 y 14. De esta forma, la base de indicadores para entrenar al modelo comienza el 1 de febrero 12:50 hs (fecha de inicio más 14 períodos) y consta de una matriz de 2328 Filas y 10 columnas. Estas 10 variables que se utilizan como *input* son las variables independientes del modelo que intentan explicar (predecir) el resultado de la variable dependiente.

Nuestra variable dependiente predice si el precio de una acción subirá o bajará con una tendencia acentuada. Para esto consideramos el precio de la acción en un momento dado (T), el precio 5 períodos atrás ($T-5$) y el precio 5 períodos adelante ($T+5$)⁴. Si el precio en ' T ' es inferior al de ' $T-5$ ' y ' $T+5$ ', entonces se considera que la acción está en un mínimo local, la tendencia en períodos anteriores a T es revertida y el resultado final implicaría comprar ese activo en T . En este caso, nuestra variable dependiente toma un valor nominal de '1'. En el caso opuesto, cuando el precio en ' T ' es superior al de ' $T-5$ ' y al de ' $T+5$ ', entonces el precio se encuentra en un máximo local y habría que vender. En este caso, nuestra variable independiente toma un valor de '0'. En todos los casos contrarios la variable independiente toma un valor de '0.5'. El modelo no puede predecir si el precio del activo correspondiente va a aumentar o disminuir y por ende se toma una posición neutral.

⁴ 1) Según H. Mizuno, M. Kosaka, H. Yajima. (1998)

Figura 2: representación de un escenario de venta


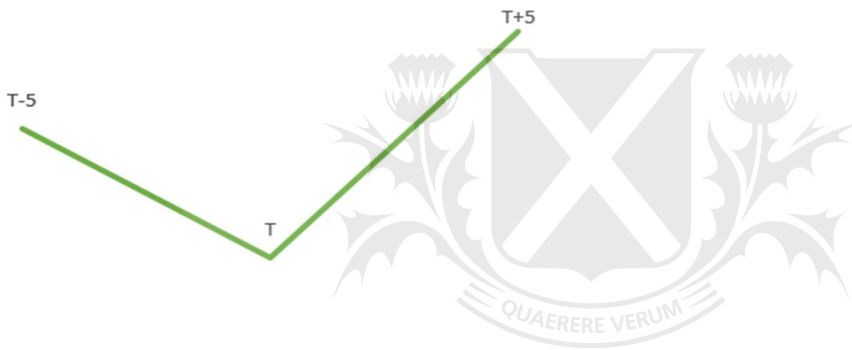


Figura 3: representación de un escenario de compra



En los siguientes gráficos vemos cómo se va entrenando el modelo con respecto a *accuracy* y la función de pérdida. El modelo mejora en base a la *accuracy* de forma continua. Al finalizar las 100 iteraciones de la base de entrenamiento, el rendimiento mejora casi en un 10% pasando de una *accuracy* del 24.5% al 27.5%. La función de pérdida prácticamente no se reduce.

Figura 4: *Accuracy* del entrenamiento

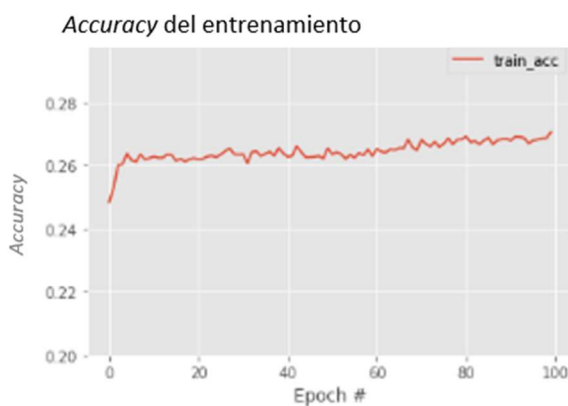
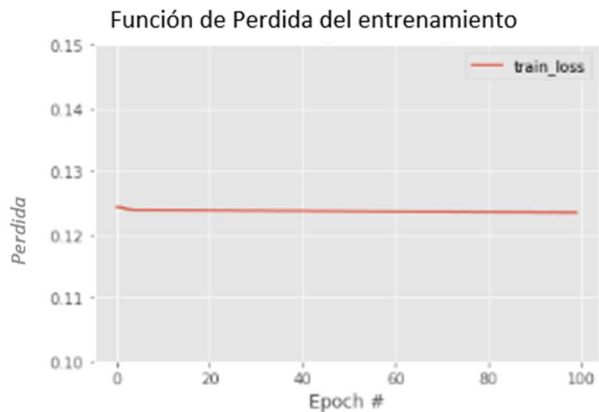


Figura 5: Función de pérdida del entrenamiento



El modelo de redes neuronales es solo la primera parte del desarrollo de una estrategia automatizada. Para una estrategia integral es necesario llevar una contabilidad de dinero, posiciones abiertas y otros datos que permitan filtrar las señales que se obtienen a través del modelo de redes neuronales. En la siguiente sección, se explica cómo las señales recibidas por el modelo son filtradas y ejecutadas

6.4. Algoritmo

Si lo que se busca es generar un algoritmo completamente automatizado para operar en el mercado entonces no es suficiente predecir si el precio va a subir o bajar. Es necesario armar una estrategia consistente para todas las posibles combinaciones que se pueden llegar a dar en el mercado, administrar el riesgo según las necesidades del inversor y registrar la información de manera adecuada para que esta pueda ser utilizada a la hora de aplicar señales correspondientes recibidas por el modelo.

Lo primero que recibe el algoritmo es una señal para cada uno de los activos. Esta señal puede ser un 1 que significa que el precio del activo va a subir en los próximos periodos, un 0 cuyo significado es que el precio del activo va a disminuir en los próximos periodos o finalmente un 0.5 que significa que el modelo no pudo determinar si el precio va a subir o bajar. Por lo tanto, el primer paso plantea que el algoritmo convierta esa señal en una operación de mercado. Existen varias operaciones para obtener rendimientos según la tendencia esperada de un activo, pero para los fines de este trabajo consideramos las siguientes: para una tendencia esperada alcista se ejecuta la compra del activo o el cierre de una venta en corto. Para las tendencias bajistas consideramos abrir una posición de venta en corto o vender activos que se encuentran en cartera. Por lo tanto, una vez que el algoritmo detecta una señal del modelo y la categoriza entre una predicción alcista, bajista o neutra, debe decidir, bajo un criterio sistemático, si la operación a

tomar va a ser comprar el activo, vender en corto, no hacer nada o cerrar una posición abierta si hubiere. No se considera abrir posiciones con apalancamiento, mercado de futuros ni opciones.

La estrategia implementada para cerrar posiciones abiertas requiere de una señal contraria. Es decir, si el modelo contradice mediante otra señal la posición actual del activo en la cartera entonces el algoritmo cierra la posición. Por ejemplo, si la posición que se mantiene sobre un activo es en corto y se recibe una señal indicando que el precio de ese activo va a subir ('1') entonces se liquida la posición dejándola en cero.

En el caso de que un activo tenga una posición larga (corta) y se reciba otra señal en la misma dirección siendo I ('0') entonces el algoritmo vuelve a comprar (vender) la acción correspondiente aumentando la exposición del activo en la cartera. Si bien parece riesgoso, la hipótesis detrás de esta estrategia es que si el algoritmo viene ratificando constantemente señales en una dirección esa posición ganadora podría más que compensar aquellas perdedoras. El algoritmo debe decidir en qué casos una señal de compra (venta) es correspondiente a: la apertura de una posición en largo (corto), el agregado de una posición en la misma tendencia, la liquidación de la posición contraria correspondiente o no generar ninguna acción.

Para poder aplicar todas estas reglas sistemáticamente es necesario llevar la contabilidad y métricas tanto del portafolio como del algoritmo. Se generan constantemente tablas de datos para poder llevar la operatoria de la estrategia planteada. Los datos almacenados más importantes son el valor de la cartera en la moneda que se está usando para operar, compuesto por el efectivo más el valor de mercado de las posiciones que actualmente se mantienen en el portafolio. Para ello es necesario llevar un registro actualizado de todas las operaciones que se realizan, de cada posición por separado a valor mercado y en cantidad de acciones, y la liquidez actualizada cada vez que se procesa una señal para cada activo por separado.

Funcionalmente el algoritmo creado tiene el fin de efectivizar, dentro de lo posible, las señales de compraventa que emite el modelo mencionado anteriormente. Para ello el siguiente paso es hacer un chequeo de factibilidad; que el algoritmo entienda si es posible llevar a cabo la operación generada por la señal que envió el modelo. Por lo tanto, el algoritmo calcula cuanta

liquidez hay y si se puede llevar a cabo la operación deseada. Es necesario llevar un registro de efectivo para corroborar el monto total de la operación con la liquidez total de la cartera. En caso de que la liquidez sea menor al monto se opera por la diferencia, siendo un monto menor que el inicialmente previsto. Al mismo tiempo se configura un monto mínimo operable es decir que si la diferencia calculada previamente es menor al monto mínimo operable, el algoritmo desestima la operación y la finaliza como una señal neutra.

Un pilar fundamental en toda estrategia de trading es administrar correctamente el riesgo de la cartera. Para ello el algoritmo construido tiene distintos filtros configurables. Por un lado, determina el monto (en U\$) a operar para cada señal recibida utilizando como base el valor total de la cartera. Es decir que cada vez que el algoritmo recibe una señal, calcula el monto de compraventa deseado según el valor de la cartera en el momento que se recibió la señal. Por otro lado, es necesario controlar la exposición de la cartera a cada activo. En particular, poner límite al porcentaje que una acción puede representar del valor total de la cartera con el fin de reducir riesgo. Es decir que cada vez que se procesa una señal, el algoritmo ratifica que la operación a efectuarse, sumado a la posición actual que se mantiene de ese activo, no supere un cierto porcentaje con relación al valor total de la cartera. La configuración de capital por operación es de un 7% mientras que el máximo de sobreexposición de un activo en la cartera es de un 30%. Esto permite que el algoritmo agrande una posición hasta 4,2 veces. En caso de que un activo se encuentre en el límite configurado y reciba señales en la misma tendencia, el algoritmo es capaz de omitirla. Para poder volver a abrir una posición en ese activo es necesario recibir una señal opuesta o que el resto de los activos eleve su valor para que el activo principal represente menos del 30% mencionado.

7. Resultados

7.1. Evaluación del modelo

Para evaluar los resultados del modelo es necesario validar su rendimiento con una base de datos que no haya sido utilizada para el entrenamiento. Para esto utilizamos el 20% de datos que no fue considerado en la base de entrenamiento. Se consideran en total 8790 observaciones donde cada acción aporta 586 datos. En fechas, la base de prueba se extiende desde el 26 de abril (13:30 hora Buenos Aires) hasta el 14 de mayo (17:30 hora Buenos Aires).

En la Tabla 4 presentamos un resumen de los números finales del modelo. En un total de 18 días corridos y 14 con el mercado abierto nuestro algoritmo operó 40 posiciones largas y 13 cortas. Cada uno de los 15 activos fue operado al menos una vez por alguna de las dos posiciones y se obtuvo un rendimiento de 4.5% con una volatilidad (anualizada) de 14.8%. Dos acciones se dividieron prácticamente la mitad de las ganancias (\$OXY y \$GILD) mientras que 5 de las 15 acciones operadas terminaron con rendimiento negativos. En promedio, por cada acción, el algoritmo estuvo con posición larga abierta en 238 intervalos, posición en corto abierta 24 períodos y 324 con posición neutral. Para una visualización detallada sobre las operaciones con cada acción ver el anexo.

Tabla 4: resultados finales por acción operada

	Posición Larga	Posición Corta	Ganancia
T	1	2	\$678.9
HAS	1	2	-\$11.2
AMZN	3	0	\$250.3
KO	4	0	\$47.1
CL	4	1	-\$206.4
OXY	2	0	\$1,429.5
MMC	3	2	-\$231.4
JPM	2	0	\$489.1
CVS	3	1	\$736.5
GILD	3	1	\$974.1

TXT	3	1	\$204.1
INTC	4	1	-\$29.3
XEL	2	1	\$6.4
WRK	3	0	\$240.9
ARE	2	1	-\$127.4

Para un análisis cuantitativo del modelo utilizamos una matriz de confusión de 3 filas por 3 columnas dadas las tres categorías de predicciones que nuestro modelo puede hacer (ver Tabla 5). Los valores verdaderos (filas) acumulados se distribuyen casi de manera simétrica, con ~50% de las posiciones neutrales, y un ~25% para compras y ventas. Comparándolo con las predicciones del modelo (columnas) observamos que el modelo es más propenso a las señales neutrales. Menos del 5% de las señales fueron de compra y el 1% de venta. Es evidente la dificultad de predecir con que tendencia se moverán los mercados. Un modelo será mejor a medida que logre reducir este problema y predecir con mayor precisión los precios futuros.

Tabla 5: Análisis cuantitativo del modelo

Predicción Actual	Venta	Neutral	Compra	Total
Venta	20	2147	76	2243
Neutral	37	4168	180	4385
Compra	24	2005	133	2162
Total	81	8320	389	8790

Con la matriz de confusión armamos algunas métricas para explicar el rendimiento del modelo con sus respectivas ventajas y desventajas: utilizamos *Accuracy*, *Precisión*, *TP rate* y *F1-Score* (Tabla 6). Estas métricas son calculadas de manera binaria. Es decir, se evalúa si sucedió una categoría o si no sucedió. Por esto, separamos las métricas en el algoritmo para la compra (con todo el resto siendo neutral y venta) y con el algoritmo para la venta (con todo el resto siendo neutral y compra).

La primera métrica, *accuracy*, nos indica el porcentaje de observaciones clasificadas correctamente. Por ejemplo, para el algoritmo de venta, son bien clasificadas las 20 observaciones donde se predijo venta y era venta más todas las observaciones donde no se predijo venta y no fue venta (4168 de neutral-neutral, 2005 de neutral-compra, 180 de compra-neutral y 133 de compra-compra). Si bien el *accuracy* es bastante alto (74%) no parece ser la mejor métrica para nuestro modelo al considerar como aciertos predicciones que tendrían que haber sido compra, pero fueron neutrales. Por esto utilizamos la segunda métrica que es *precisión*. Aquí solo se mide las predicciones positivas, es decir solo aquellas en las que se predice que algo ocurrirá. Para el algoritmo de venta, se acertaron 20 señales de compra sobre un total de 81 que hubo realmente (~25%). Esta métrica demuestra que tan confiable es el algoritmo en la predicción de alguna variable. En este caso, cada vez que el algoritmo predice una venta se espera que 1 de cada 5 señales sean exitosas. El algoritmo de compra tiene un poco mejor de *precisión* que el de venta con un porcentaje de 34%. Esto significa que nuestro algoritmo es más confiable para detectar señales alcistas que bajistas. Si bien estos números no parecen altos, pueden ser suficiente para obtener rendimientos por encima que los del mercado. Luego tenemos la *Sensibilidad* que mide que porcentaje de aciertos tuvo el modelo sobre todas las veces que ocurrió determinado evento. Nuestro modelo tiene muy bajo *Sensibilidad* dado que muchas veces el mercado sube (o baja) con poca fuerza resultando en una señal de compra (venta) que es muy difícil que un modelo pueda detectar. Un modelo ideal debería tener alto *Sensibilidad* y *precisión*. Para esto tenemos nuestra última métrica que combina las explicadas anteriormente denominada *F1-Score*. El ideal es tener un buen *F1-Score* para poder hacer muchas operaciones con mucha certeza. Sin embargo, no es excluyente dado que nuestro modelo logra buena *precisión* con menos operaciones de lo deseado. Más aún si en aquellas operaciones en las que el modelo acierta obtiene rendimientos que compensen las pérdidas de las operaciones en las que no acierta (Tabla 4, \$OXY y \$GILD más que compensan las pérdidas de otras acciones)

Tabla 6: métricas del modelo de compras y modelo de ventas

	Accuracy	Precision	Sensibilidad	F1-Score
venta	74.02%	24.69%	0.89%	1.72%
compra	74.00%	34.19%	6.15%	10.43%

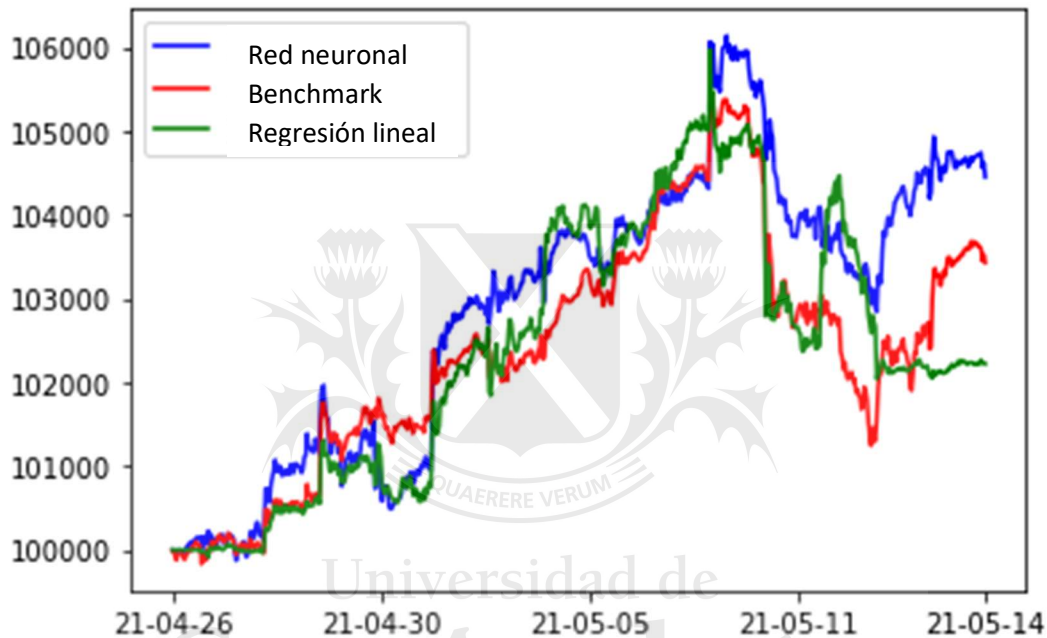
7.2. Comparación de estrategias

Para evaluar los resultados de nuestro modelo lo comparamos con una regresión lineal en la cual cada uno de los 10 indicadores son utilizados como variables independientes. A su vez, ambos modelos son comparados con una estrategia de compra pasiva. La estrategia de compra pasiva que se propone es ponderar en igual cantidad cada una de las 16 acciones seleccionadas y no venderlas hasta el final del periodo.

En la Tabla 7 vemos la evolución de cada una de las estrategias. La estrategia de redes neuronales es la que mejores resultados obtiene, seguida por la de compra pasiva (*benchmark*) y por último la regresión lineal. Para poder establecer un orden jerárquico definitivo entre los tres modelos es necesario considerar también la volatilidad. Considerando el rendimiento y la volatilidad constituimos el ratio de Sharp según la siguiente formula: $ratio\ de\ Sharp = \frac{r_p - r_f}{\sigma_p} * 100$. Donde r_f es la tasa libre de riesgo, r_p el rendimiento del portafolio y σ_p la volatilidad de este. En nuestro caso utilizamos la tasa del tesoro americano que actualmente (octubre 2021) rinde al rededor del 1% anual. El ratio de Sharp nos indica qué rendimiento se obtiene por cada unidad adicional de riesgo que se asume. En este aspecto, el modelo de redes neuronales es el que mejor performance tiene, seguido por la compra pasiva y último la regresión lineal.

Tabla 7: Resultados de los distintos modelos

	NN	Benchmark	Regresión Lineal
Retorno	4.47%	3.44%	2.22%
Volatilidad anual	14.79%	12.62%	14.81%
Ratio de Sharpe	23.46	19.36	8.30



Si bien los números son contundentes con la superioridad del modelo de redes neuronales sobre la regresión lineal, podría deberse a algo específico de la muestra utilizada. Para asegurarnos que no es el caso proponemos la prueba de Diebold-Mariano. Con esta prueba buscamos validar si dos modelos predicen con diferente precisión. Con una significatividad al 1% obtenemos que efectivamente los modelos de redes neuronales y regresión lineal tienen distinta precisión⁵ y complementando con los números de retorno y ratio de Sharp concluimos que el modelo de redes neuronales es superior al de la regresión lineal.

8. Conclusiones

⁵ Ver anexo B: código

Diversos trabajos académicos se han llevado a cabo en los últimos años con respecto a la automatización de *trading*. Con el avance computacional de la última década han ido tomando mayor protagonismo trabajos que utilizan indicadores tradicionales de análisis técnico con modelos de *Big Data* y *Machine Learning*. En el presente trabajo creamos e implementamos un modelo de redes neuronales de alta frecuencia con el fin de obtener mejores resultados que una estrategia pasiva y un modelo alternativo (regresión lineal). Si bien hay mucho para mejorar, los resultados son alentadores con el modelo de redes neuronales superando en diversos aspectos a las otras dos estrategias propuestas.

En los indicadores clásicos para evaluar modelos predictivos propuestos a lo largo del trabajo, el algoritmo de redes neuronales no obtuvo los mejores resultados. Sin embargo, considerando el contexto de mercado de capitales, donde es muy complejo lograr alta precisión -pero condición no necesaria- en las predicciones los resultados son positivos. A diferencia de modelos en otros campos como medicina o criminología donde es necesario predecir con gran certeza para evitar el diagnóstico incorrecto en el mercado de capitales solo se necesita ganar más dinero -y en lo posible en más operaciones- del que se pierde. Es por esto por lo que nuestro modelo logra superar al modelo de regresión lineal y a la estrategia de compra pasiva.

Con los resultados obtenidos concluimos que nuestro modelo es superior para predecir las tendencias alcistas que las bajistas. Sería interesante, como futuro desarrollo en el trabajo explorar un algoritmo distinto para la detección de tendencias bajistas y complementar ambos algoritmos con la finalidad de obtener un mejor resultado. Aunque hoy en día las comisiones de los *brokers* americanos (*TD Ameritrade*, *RobinHood*, *InteractiveBrokers*) tienden a cero la diferencia de precios entre compra y venta siguen existiendo. Es por esto por lo que entender el impacto de los costos de transacción en las perspectivas de cada operación y luego en la rentabilidad final de la estrategia sería de gran utilidad para próximos desarrollos. En este punto, resulta relevante destacar que la diferencia de compra y venta suele ser mayor en activos con poco volumen y por esto la decisión de nuestros 15 activos: pertenecientes al SP500, altos volúmenes y muy bajos *spreads*.

9. Bibliografía

T. Chordia, A. Goyal, B.N. Lehman, G. Saar. (2013). *High frequency trading*. Johnson School Research Paper Series.

R.Dash & P.K Dash A. (2016). *Hybrid stock trading framework integrating technical analysis with machine learning techniques*. ScienceDirect.com

Sebastian Donadio and Sourav Ghosh. (2019). *Learn Algorithmic Trading: Build and develop algorithmic trading systems and strategies using python and advances data analysis*. Packt Publishing LTD.

Barris Jhonson. (2010). *Algorithmic trading & DMA: An introduction to direct access trading strategies*. 4Myeloma Press, London.

Lars Kestner. (2003). *Quantitative Trading Strategies: harnessing the power of quantitative techniques to create a winning trading program*. McGraw-Hill Companies

H. Mizuno, M. Kosaka, H. Yajima. (1998). *Application Of Neural Network To Technical Analysis Of Stock Market Prediction*. Department of Information Systems Engineering, Faculty of Engineering, Osaka University.

O.B Obi. (2019) *Application of Machine Learning in High Frequency Trading of Stocks*. International Journal of Scientific & Engineering Research Volume 10, Issue 5.

O.B. Sezer, M. Ozbayoglu & E. Dogdu (2017). *Deep Neural-Network Based Stock Trading System Based on Evolutionary Optimized Technical Analysis Parameters*. ScinceDirect.com

Prodomos E Tsinaslanidis & Achilleas D Zaporinis. (2016). *Technical Analysis for Algorithmic Pattern Recognition*. Springer International Publishing Switzerland.

10. Anexo A

Tabla A1: Posiciones cerradas por acción con su resultado.

Ticker	Número Periodo	Ganancia / perdida	Acción
T	37	\$74.6	Corto cerrado
T	124	-\$71.3	Corto cerrado
T	585	\$675.6	Largo cerrado
HAS	98	\$68.7	Largo cerrado
HAS	184	-\$40.2	Corto cerrado
HAS	348	-\$39.7	Corto cerrado
AMZN	78	\$276.3	Largo cerrado
AMZN	259	\$10.0	Largo cerrado
AMZN	306	-\$36.0	Largo cerrado
KO	124	\$28.6	Largo cerrado
KO	165	-\$45.8	Largo cerrado
KO	330	\$86.3	Largo cerrado
KO	466	-\$22.8	Largo cerrado
KO	585	\$0.7	Largo cerrado
CL	9	-\$3.1	Largo cerrado
CL	46	-\$41.1	Largo cerrado
CL	269	-\$22.6	Largo cerrado
CL	346	-\$88.2	Corto cerrado
CL	386	-\$51.4	Largo cerrado
OXY	136	\$980.0	Largo cerrado
OXY	399	\$449.4	Largo cerrado
MMC	23	\$21.2	Corto cerrado
MMC	102	\$14.9	Largo cerrado
MMC	146	\$46.2	Largo cerrado
MMC	265	-\$13.4	Corto cerrado
MMC	493	-\$300.2	Largo cerrado
JPM	239	\$277.2	Largo cerrado

JPM	330	\$89.1	Largo cerrado
JPM	585	\$122.7	Largo cerrado
CVS	25	\$27.6	Corto cerrado
CVS	205	\$618.8	Largo cerrado
CVS	263	\$5.8	Largo cerrado
CVS	430	\$84.2	Largo cerrado
GILD	248	\$693.2	Largo cerrado
GILD	302	-\$18.0	Largo cerrado
GILD	341	\$79.2	Largo cerrado
GILD	380	-\$24.0	Corto cerrado
GILD	585	\$243.7	Largo cerrado
TXT	41	\$52.2	Largo cerrado
TXT	152	-\$105.1	Corto cerrado
TXT	286	\$163.7	Largo cerrado
TXT	585	\$93.3	Largo cerrado
INTC	17	\$16.6	Largo cerrado
INTC	123	-\$276.5	Largo cerrado
INTC	355	\$29.3	Largo cerrado
INTC	423	\$188.7	Corto cerrado
INTC	451	\$12.6	Largo cerrado
XEL	34	-\$43.6	Largo cerrado
XEL	282	\$127.9	Corto cerrado
XEL	525	-\$77.9	Largo cerrado
WRK	181	\$258.4	Largo cerrado
WRK	280	-\$13.8	Largo cerrado
WRK	425	-\$3.7	Largo cerrado
ARE	125	\$39.6	Largo cerrado
ARE	347	-\$173.2	Largo cerrado
ARE	368	\$6.2	Corto cerrado

Tabla A2: Operatoria detallada del modelo por acción.

Ticker	Número Período	Acción	Precio	Acciones en Cartera
T	14	Corto abierto	\$31.0	-226.14
T	37	Corto cerrado	\$30.7	0.00
T	100	Corto abierto	\$31.0	-228.65
T	124	Corto cerrado	\$31.3	0.00
T	127	Largo abierto	\$31.3	226.01
T	128	Largo añadido	\$31.3	451.81
T	145	Largo añadido	\$31.3	678.31
T	207	Largo añadido	\$31.6	906.12
T	264	Largo añadido	\$31.9	1132.64
T	346	Largo añadido	\$32.4	1357.62
T	354	Largo añadido	\$32.2	1584.21
T	364	Largo añadido	\$32.2	1811.12
T	401	Largo añadido	\$32.9	2036.78
T	585	Largo cerrado	\$32.2	2036.78
HAS	20	Largo abierto	\$97.1	72.20
HAS	42	Largo añadido	\$98.3	143.51
HAS	98	Largo cerrado	\$98.2	0.00
HAS	120	Corto abierto	\$98.5	-71.86
HAS	184	Corto cerrado	\$99.1	0.00
HAS	332	Corto abierto	\$98.9	-73.53
HAS	348	Corto cerrado	\$99.4	0.00
AMZN	3	Largo abierto	\$3,344.0	2.09
AMZN	78	Largo cerrado	\$3,476.0	0.00
AMZN	255	Largo abierto	\$3,291.7	2.20
AMZN	259	Largo cerrado	\$3,296.2	0.00
AMZN	262	Largo abierto	\$3,288.9	2.20
AMZN	306	Largo cerrado	\$3,272.5	0.00
KO	10	Largo abierto	\$53.8	130.15

KO	124	Largo cerrado	\$54.0	0.00
KO	145	Largo abierto	\$54.3	130.83
KO	165	Largo cerrado	\$53.9	0.00
KO	251	Largo abierto	\$54.1	133.52
KO	306	Largo añadido	\$54.0	267.65
KO	330	Largo cerrado	\$54.4	0.00
KO	360	Largo abierto	\$54.5	133.98
KO	466	Largo cerrado	\$54.3	0.00
KO	526	Largo abierto	\$54.7	133.50
KO	585	Largo cerrado	\$54.7	133.50
CL	1	Largo abierto	\$79.3	88.32
CL	9	Largo cerrado	\$79.2	0.00
CL	20	Largo abierto	\$79.4	88.31
CL	46	Largo cerrado	\$78.9	0.00
CL	254	Largo abierto	\$81.2	89.11
CL	269	Largo cerrado	\$80.9	0.00
CL	306	Corto abierto	\$81.3	-89.07
CL	346	Corto cerrado	\$82.3	0.00
CL	362	Largo abierto	\$82.3	88.65
CL	386	Largo cerrado	\$81.8	0.00
OXY	7	Largo abierto	\$25.1	279.23
OXY	10	Largo añadido	\$24.9	559.85
OXY	46	Largo añadido	\$24.8	842.48
OXY	121	Largo añadido	\$26.0	1114.84
OXY	136	Largo cerrado	\$26.1	0.00
OXY	250	Largo abierto	\$25.8	279.92
OXY	331	Largo añadido	\$26.6	553.40
OXY	399	Largo cerrado	\$27.0	0.00
MMC	14	Corto abierto	\$127.5	-54.94
MMC	23	Corto cerrado	\$127.1	0.00
MMC	100	Largo abierto	\$133.6	53.05

MMC	102	Largo cerrado	\$133.8	0.00
MMC	118	Largo abierto	\$135.1	52.48
MMC	146	Largo cerrado	\$136.0	0.00
MMC	256	Corto abierto	\$135.0	-53.60
MMC	265	Corto cerrado	\$135.2	0.00
MMC	399	Largo abierto	\$138.9	53.42
MMC	493	Largo cerrado	\$133.3	0.00
JPM	20	Largo abierto	\$151.2	46.38
JPM	22	Largo añadido	\$151.0	92.71
JPM	239	Largo cerrado	\$154.1	0.00
JPM	306	Largo abierto	\$157.6	45.95
JPM	330	Largo cerrado	\$159.6	0.00
JPM	527	Largo abierto	\$161.3	45.28
JPM	585	Largo cerrado	\$164.0	45.28
CVS	4	Corto abierto	\$76.1	-92.03
CVS	25	Corto cerrado	\$75.8	0.00
CVS	125	Largo abierto	\$76.1	92.79
CVS	129	Largo añadido	\$76.1	185.88
CVS	144	Largo añadido	\$76.3	278.77
CVS	182	Largo añadido	\$76.7	370.95
CVS	205	Largo cerrado	\$78.0	0.00
CVS	259	Largo abierto	\$80.9	89.38
CVS	263	Largo cerrado	\$81.0	0.00
CVS	362	Largo abierto	\$84.9	85.95
CVS	430	Largo cerrado	\$85.9	0.00
GILD	11	Largo abierto	\$65.5	106.86
GILD	13	Largo añadido	\$65.5	213.77
GILD	78	Largo añadido	\$64.3	323.66
GILD	121	Largo añadido	\$63.5	435.26
GILD	141	Largo añadido	\$63.7	546.75
GILD	248	Largo cerrado	\$65.8	0.00

GILD	281	Largo abierto	\$66.7	108.93
GILD	302	Largo cerrado	\$66.6	0.00
GILD	307	Largo abierto	\$65.9	109.88
GILD	334	Largo añadido	\$65.9	220.11
GILD	341	Largo cerrado	\$66.3	0.00
GILD	367	Corto abierto	\$66.7	-109.30
GILD	380	Corto cerrado	\$66.9	0.00
GILD	452	Largo abierto	\$67.4	107.93
GILD	493	Largo añadido	\$67.4	215.16
GILD	585	Largo cerrado	\$68.6	215.16
TXT	1	Largo abierto	\$61.1	114.65
TXT	41	Largo cerrado	\$61.5	0.00
TXT	120	Corto abierto	\$62.7	-112.96
TXT	152	Corto cerrado	\$63.6	0.00
TXT	240	Largo abierto	\$64.6	111.68
TXT	249	Largo añadido	\$65.3	222.20
TXT	286	Largo cerrado	\$65.7	0.00
TXT	466	Largo abierto	\$67.1	108.53
TXT	585	Largo cerrado	\$68.0	108.53
INTC	15	Largo abierto	\$58.9	118.97
INTC	17	Largo cerrado	\$59.0	0.00
INTC	20	Largo abierto	\$58.9	118.98
INTC	22	Largo añadido	\$58.7	238.11
INTC	123	Largo cerrado	\$57.7	0.00
INTC	146	Largo abierto	\$58.2	122.15
INTC	205	Largo añadido	\$57.0	248.39
INTC	348	Largo añadido	\$57.6	374.53
INTC	355	Largo cerrado	\$57.7	0.00
INTC	361	Corto abierto	\$57.6	-126.62
INTC	423	Corto cerrado	\$56.1	0.00
INTC	430	Largo abierto	\$55.2	132.93

INTC	451	Largo cerrado	\$55.3	0.00
XEL	20	Largo abierto	\$70.7	99.13
XEL	22	Largo añadido	\$70.6	198.26
XEL	34	Largo cerrado	\$70.4	0.00
XEL	249	Corto abierto	\$71.5	-100.86
XEL	282	Corto cerrado	\$70.2	0.00
XEL	332	Largo abierto	\$71.6	101.59
XEL	368	Largo añadido	\$71.6	203.54
XEL	525	Largo cerrado	\$71.2	0.00
WRK	20	Largo abierto	\$53.6	130.84
WRK	181	Largo cerrado	\$55.6	0.00
WRK	207	Largo abierto	\$57.2	125.68
WRK	259	Largo añadido	\$57.6	251.27
WRK	280	Largo cerrado	\$57.4	0.00
WRK	362	Largo abierto	\$59.7	122.24
WRK	425	Largo cerrado	\$59.7	0.00
ARE	103	Largo abierto	\$178.8	39.62
ARE	125	Largo cerrado	\$179.8	0.00
ARE	239	Largo abierto	\$180.7	39.91
ARE	281	Largo añadido	\$177.1	80.94
ARE	286	Largo añadido	\$177.5	121.88
ARE	332	Largo añadido	\$176.4	163.10
ARE	347	Largo cerrado	\$176.8	0.00
ARE	356	Corto abierto	\$177.9	-41.03
ARE	368	Corto cerrado	\$177.7	0.00

Anexo B. Código

```
In [9]: y_pred_lr.signals.value_counts()
Out[9]:
0.5    9302
1.0     46
0.0     28
Name: signals, dtype: int64

In [10]: y_pred_test.signals.value_counts()
Out[10]:
0.5    8875
1.0    415
0.0     86
Name: signals, dtype: int64

In [11]: mariano_test
Out[11]: dm_return(DM=10.511963189525368,
p_value=1.0572762623209398e-25)
```



Universidad de
San Andrés