



**Colegio de Estudios
Superiores de Administración**

**PREDICCIÓN DE TENDENCIA DE PRECIOS DE ACCIONES POR MEDIO DE UNA RED
NEURONAL DE MEMORIA A CORTO PLAZO**

CRISTINA BARRERO SANCLEMENTE
WANDA TATIANA VARGAS ÁLVAREZ

Colegio de Estudios Superiores en Administración - CESA

Maestría en Finanzas Corporativas

Bogotá

2021

**PREDICCIÓN DE TENDENCIA DE PRECIOS DE ACCIONES POR MEDIO DE UNA
RED NEURONAL DE MEMORIA A CORTO PLAZO**

CRISTINA BARRERO SANCLEMENTE
WANDA TATIANA VARGAS ÁLVAREZ

Director: Bernardo León Camacho

Colegio de Estudios Superiores en Administración - CESA

Maestría en Finanzas Corporativas

Bogotá

2021

Tabla de contenido

Resumen	6
1. Planteamiento del problema	7
2. Pregunta de investigación	10
3. Hipótesis	11
4. Objetivo General	12
4.1. Objetivos Específicos.....	12
5. Estado del Arte	13
6. Marco teórico	20
7. Desarrollo de la Metodología	26
7.1 Etapa 1 Metodología: Revisión y definición de variables explicativas de estudio con base en el precio histórico de precios de acciones	26
7.2 Etapa 2 Metodología: Recopilar datos históricos del precio de las acciones más relevantes del índice S&P500.....	28
7.3 Etapa 3 Metodología Realizar una proyección de precios de la data histórica por medio de promedios móviles ponderados a 5, 10 y 30 días.....	35
7.4: Etapa 4 Metodología: Construcción de algoritmo LSTM de análisis de datos, con y sin variables conductuales.....	39
7.5 Etapa 5 Metodología: Comparar las redes neuronales LSTM (con y sin variable conductual) vs modelos de promedios ponderados.....	52
8. Resultados	55
9. Conclusiones	72
Bibliografía	75

Índice de tablas

Tabla 1: Referencia columna de datos a importar a modelo LSTM.....	44
Tabla 2: Errores modelo promedios móviles AMZN.....	57
Tabla 3: Errores modelo promedios móviles TSLA.....	57
Tabla 4: Errores modelo promedios móviles MSFT.....	57
Tabla 5: Errores modelo promedios móviles APPL.....	58
Tabla 6: Errores modelo promedios móviles FB.....	58
Tabla 7: Resultados RMSE modelo LSTM.....	64

Índice de figuras

Figura 1: Variación Índice S&P500.....	8
Figura 2: Tweet Elon Musk.....	9
Figura 3: Red neuronal Long Short-Term Memory.....	15
Figura 4: Rendimiento AMZN vs. S&P500.....	31
Figura 5: Rendimiento TSLA vs. S&P500.....	32
Figura 6: Rendimiento MSFT vs. S&P500.....	33
Figura 7: Rendimiento APPL vs. S&P500.....	34
Figura 8: Rendimiento FB vs. S&P500.....	35
Figura 9: Importar Librerías.....	43
Figura 10: Importar Librerías.....	43
Figura 11: Entrenamiento de datos.....	45

Figura 12: Normalización de datos	46
Figura 13: Fase de entrenamiento LSTM	47
Figura 14: Inputs Modelo LSTM.....	48
Figura 15: Cálculo Epochs.....	49
Figura 16: Fase de testeo LSTM.....	50
Figura 17: Predicción del modelos LSTM.....	51
Figura 18: Cálculo RMSE.....	51
Figura 19: Grafica modelo LSTM y predicción	52
Figura 20: Promedio ventana móvil AMZN.....	59
Figura 21: Promedio ventana móvil TSLA.....	60
Figura 22: Promedio ventana móvil MSFT	61
Figura 23: Promedio ventana móvil APPL.....	62
Figura 24: Promedio ventana móvil FB.....	63
Figura 25: Predicciones LSTM AMZN	65
Figura 26: Predicciones LSTM TSLA.....	66
Figura 27: Predicciones LSTM MSFT	67
Figura 28: Predicciones LSTM APPL	68
Figura 29: Predicciones LSTM FB.....	69

Resumen

La toma de decisiones de inversión por parte de la alta gerencia corporativa se explica en modelos de teoría clásica de Behavioral Finance, en donde se asume que los accionistas no son del todo racionales sino psicológicamente influenciados al momento de la toma de decisiones. Usando como punto de partida la toma de decisiones, esta investigación abordará principalmente los agentes exógenos que no suelen considerarse, debido a que van dentro de la naturalidad y desempeño corporativo del día a día.

Por otro lado, en la teoría empírica, se evidencia como los incentivos de inversión suelen tener vacíos a la hora de explicar el comportamiento de las inversiones en el mercado de capitales. Es por esto que los autores Malmendier & Tate (2005), proponen incluir características personales como una variable fundamental y medible a la hora de tomar decisiones.

Para el desarrollo de este trabajo se estará evaluando si durante momentos de incertidumbre se cumple la “La Hipótesis de Mercado Eficiente” o si efectivamente se puede determinar un pronóstico de precios de acciones utilizando variables conductuales para tener una proyección de tendencia más acertada al comportamiento real del mercado.

En la propuesta de este trabajo se desarrolló un modelo de proyección de precios de acciones por medio de un algoritmo de inteligencia artificial llamado Long Short Term Memory (LSTM). La metodología implementada, siguió el cumplimiento de los objetivos específicos por medio de herramientas propias de Finanzas Corporativas y mercados bursátiles encontrando una propuesta de predicción de tendencias de precios de mercado.


1. Planteamiento del problema

Los precios de los valores financieros han sido explicados por múltiples autores bajo la Hipótesis de Mercados Eficientes. Los inversionistas en un Mercado Eficiente tienen la misma probabilidad de maximizar su rentabilidad, pues disponen de la misma información y el valor de los activos está dado por el riesgo. “A mayor riesgo mayor rentabilidad, de tal modo que si pudiésemos medir y otorgar valores al nivel de riesgo asumido, podríamos conocer el porcentaje exacto de rentabilidad potencial de los distintos activos” (Juste, 2020). La teoría explica en este contexto que los inversionistas son entes racionales cuyas decisiones están enfocadas en maximizar la utilidad de su portafolio, es decir que toman mayores riesgos a la hora de invertir y asumen que no existen subvaloraciones o sobre valoraciones.

Por otro lado, autores como Tversky y Kahneman (1973), expusieron que los mercados no siempre funcionan bajo el supuesto de racionalidad de los inversionistas, a causa de los límites del arbitraje y los efectos psicológicos, que afectan la decisión de inversión más allá de los modelos de utilidad esperada. Durante las crisis económicas, donde la incertidumbre del entorno supera los fundamentos de la Teoría Clásica, se evidencian más las contradicciones respecto a la Teoría del Mercado Eficiente y se empiezan a considerar las Teorías de Behavioral Finance, que analizan cómo el comportamiento psicológico puede influenciar el mercado de acciones y la volatilidad de precios.

“El desempeño de los mercados bursátiles, especialmente en Estados Unidos, durante la pandemia del coronavirus parece desafiar la lógica” (Shiller, 2020). Durante la crisis Económica del 2020, resultado de la Pandemia por el COVID-19, a pesar de una disminución en la inversión y el desempleo en EEUU, los precios de las acciones del S&P500 se mantuvieron a flote.

Figura 1: Variación Índice S&P500



Nota: Elaboración propia con datos de Yahoo Finance (2021)

Uno de los factores con mayor influencia en la tendencia al alza de estos valores durante el año 2020, fue el alto nivel de liquidez del mercado, como efecto de los incentivos de la FED y el gobierno de Estados Unidos. Los anteriores se dieron como medida de emergencia para la desaceleración económica a causa del COVID. La tasa de referencia estuvo desde marzo de 2020 en el rango entre 0% y 0.25 % , el nivel más bajo registrado en los últimos 5 años.

Si bien la tendencia general del mercado S&P fue bullish, una de las compañías cuya capitalización bursátil resaltó en el año 2020 fue la de TESLA, la cual hace parte del S&P desde diciembre del mismo año. El valor de mercado pasó de estar a principios de 2020 en US\$80.000 millones aproximadamente a estar por encima de los US\$600.000 millones en 2021; sin embargo, esto no es reflejo de su desempeño financiero. Algunos expertos atribuyen el crecimiento, al auge de la transición energética e innovación, pero otras empresas con políticas similares no han crecido

a estos niveles. De hecho, la volatilidad más alta se ha dado en momentos específicos que no involucran variables financieras, como un tweet de su CEO y mayor accionista individual, el cual generó la caída de la acción en un 10% en un solo día. (Musk, 2020)

Figura 2: Tweet Elon Musk



Nota: (Musk, 2020)

En periodos de incertidumbre financiera a nivel global se ha evidenciado como el supuesto de racionalidad no aplica en las decisiones financieras.

Después de todos los esfuerzos para defender la teoría de los mercados eficientes, todavía hay razón para pensar que, si bien los mercados no están totalmente locos, contienen un ruido bastante sustancial, tan sustancial que domina los movimientos en conjunto del mercado. El modelo de mercados eficientes, para el mercado de valores agregado, nunca ha sido respaldado por un estudio que vincule efectivamente las fluctuaciones del mercado de valores con fundamentos posteriores. (Shiller, 2003)

2. Pregunta de investigación

¿Existen sesgos conductuales que afectan la tendencia de los precios de las acciones en periodos de incertidumbre del mercado y actividades financieras?

3. Hipótesis

El mercado bursátil en momentos de incertidumbre no cumple con “La Hipótesis de Mercado Eficiente”. No es eficiente por sí mismo, pues involucra conductas financieras específicas como: “bullish” o “bearish”, esto es miedo y codicia, noticias y redes sociales que fortalecen la incertidumbre de los inversionistas y por ende afectan el precio y tendencia del activo financiero.

4. Objetivo General

Validar si existen conductas específicas que afectan la tendencia de los precios de las acciones durante momentos de incertidumbre del mercado y actividades financieras.

4.1. Objetivos Específicos

- Identificar las acciones a pronosticar y las variables explicativas de su tendencia en los periodos de tiempo establecidos.
- Realizar una Red Neuronal de Memoria a Corto Plazo (LSTM) sin variables conductuales para evaluar si la tendencia es pronosticable en momentos de incertidumbre.
- Incluir variables conductuales a la Red Neuronal de Memoria de Corto Plazo para evaluar si son explicativas en la tendencia de los precios del mercado.
- Comparar la tendencia esperada de los pronósticos y compararlo con el comportamiento real del mercado durante el periodo de tiempo escogido.
- Determinar si la Hipótesis de Mercado Eficiente se cumple o si existen sesgos conductuales que influyen en el valor de los precios de las acciones.

5. Estado del Arte

Según Pascale (2011) existen dos paradigmas en el marco de una toma de decisión de inversión financiera. El primer paradigma está basado en las explicaciones de las finanzas tradicionales las cuales exponen la racionalidad individual y colectiva de los agentes del mercado.

Según las finanzas tradicionales la toma de decisiones está basada en cálculos o variables cuantitativas que permiten maximizar los beneficios de los inversionistas. Uno de los modelos que sigue siendo más usado hasta el día de hoy es el CAPM (Capital Asset Pricing Model). Este fue expuesto por Sharpe (1964) y permite valorar activos financieros basado en el Riesgo Sistemático. Se basa en el equilibrio del mercado financiero: un ambiente de competencia perfecta, donde lo que determina el precio de un activo es la relación entre Oferta y Demanda. Al igual que otros autores (Markowitz (1952), Traynor (1962) , Litner (1962), Sharpe se basa en la relación Riesgo/Precio de Acción y considera que se deben otorgar valores a los niveles de riesgo asumidos, para encontrar la rentabilidad potencial de cada acción.

Según lo anterior la tendencia de los mercados bursátiles estarían dadas por la interacción de oferta y demanda y los precios cumplirían con la hipótesis de mercados eficientes (Fama,1970) reflejando toda la información disponible y permitiendo a los inversionistas tomar las decisiones correctas según sus niveles de riesgo.

Sin embargo, el segundo paradigma de Pascale se refiere a los aspectos psicológicos o comportamentales que afectan la toma de decisiones de inversión denominando a estos la corriente de Behavioral Finance o Finanzas Comportamentales. Con esta corriente los investigadores buscan darle a la interacción en el Mercado Bursátil un enfoque fuera del supuesto de racionalidad. Este

nuevo enfoque se logra mediante el estudio de variables de la psicología en los agentes del mercado y las conductas específicas que inciden en la interacción del Mercado de Acciones.

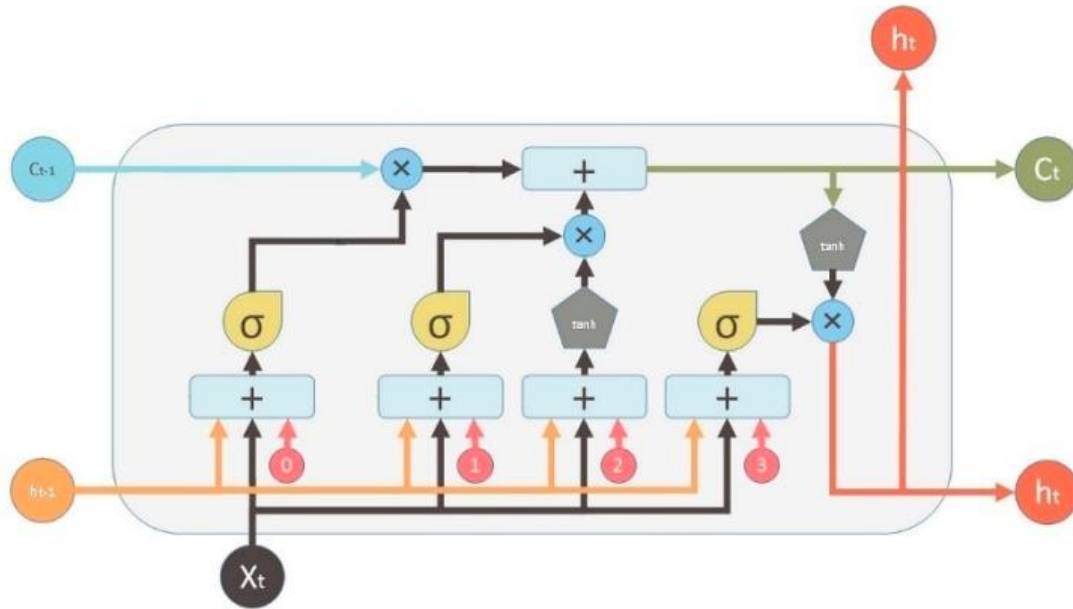
Crear modelos para predecir series financieras incluyendo variables no cuantitativas ha sido un tema de interés durante las últimas dos décadas, sobre todo por el carácter no lineal y no estacionario de algunas series de tiempo financieras. Se han empezado a implementar técnicas de inteligencia artificial (“Machine Learning”) que sean capaces de aprender de las secuencias que incluyen este tipo de variables.

Los autores Warren McCulloch y Walter Pitts (1943) intentaron simular el comportamiento del humano con tecnologías de información estructuradas al replicar el cerebro humano por medio de la simulación de las neuronas. Esta simulación llamada, redes neuronales son capaces de pronosticar valores futuros basados en la información actual. Al utilizar el conocimiento actual como variable de entrada, las neuronas viajan por la simulación del pensamiento humano, su peso ponderado indicará la importancia que tienen sobre la función de activación y así calcular el valor de la neurona de salida. Lo ideal es crear múltiples escenarios donde tanto las ponderaciones como los cruces entre neuronas creen resultados con mayor o menor fuerza. Autores como Yoon y Sales (1993) han utilizado estas técnicas analíticas de redes neuronales con variables cuantitativas y cualitativas en sistemas de inteligencia artificial para evaluar comportamientos de toma de decisiones en inversión.

En el año 1997 Hochreiter y Schmidhuber presentaron una red de “Long Short-Term Memory” como una mejora de las redes recurrentes neuronales, la cual tiene mayor capacidad de aprendizaje de dependencias a largo plazo, es decir, mayor capacidad de conectar información y

memorizar secuencias. La red está compuesta por una o varias celdas “LSTM” las cuales tienen la siguiente estructura:

Figura 3: Red neuronal Long short-term memory



Nota: Elaborado por Lopez, J. & Sales, O. (2020)

Cada línea horizontal representa un vector el cual lleva información desde un nodo hasta otro, los círculos rosados representan operaciones puntuales entre variables y los cuadros amarillos son las capas que se van creando dentro de la neurona que se dan por los aprendizajes específicos de la misma. Cada vez que el vector se divide significa que se está copiando información y se está trasladando a diferentes ubicaciones, en cambio cuando se fusiona con otra línea significa que la información se está concatenando. Esta transformación de los datos dentro de la celda “LSTM” genera unos datos de salida que pasarán a la capa de salida.

La información pasa dentro de la celda a través de las denominadas “puertas”. Hay 3 tipos de puertas: entrada, olvido y salida. Cada tipo de puerta está configurada con una función de activación la cual será multiplicada por los resultados de cada operación y según la configuración que se le haya dado a la puerta el aprendizaje o resultado pasará al siguiente nodo o se descarta.

En el caso del mercado de capitales, la determinación de precios futuros de una acción podría seguir esta metodología debido a que la predicción del comportamiento de los precios causa múltiples incertidumbres y la única información que se conoce son las variables de entrada.

Según la teoría de Behavioral Finance existen diferentes sesgos o errores en los que caen los individuos en el momento de inversión tales como son: la aversión a la pérdida, búsqueda de riesgo, dotación, disponibilidad, autocontrol, optimismo, exceso de confianza, el comportamiento del rebaño, entre muchos otros. El comportamiento del rebaño es uno de los sesgos más repetitivos al momento de invertir, si bien fue estudiado en la psicología a comienzos de la primera guerra mundial, este empezó a asociarse a las finanzas en la década de los 80's y se refiere a seguir el comportamiento de la mayoría. Lo anterior se da debido a la incertidumbre que genera el riesgo a los individuos, lo cual les impide hacer uso del segundo sistema de Kahneman (2011): no buscan la mejor respuesta sino aquella que les asegure la supervivencia, en este caso la utilidad. Por el contrario, confían en la reacción de su primer sistema, que es el de la familiaridad o donde se sienten más seguros, por lo cual copian el comportamiento de la mayoría. “El efecto de rebaño se intensifica cuando el punto de vista de los individuos está muy alineado” (Value School, 2019). Esto trae consigo otros efectos como el de la especulación y las burbujas de ciertos activos.

En la investigación realizada por Nick Bloom (2021), profesor investigador de Stanford University se muestra mediante una “LSTM” cómo la data histórica sobre el índice de precios de S&P500 tiene fuertes caídas en periodos relacionados con la gran depresión de 1929 y la coyuntura de Covid-19 durante marzo de 2020. Si bien durante la recesión económica del 2010-2019 tuvo un alto impacto en la economía mundial, (Baker, Bloom, Davis, Sammon, 2021) solo se evidenciaron 5.8 saltos por año versus 36 saltos en el índice durante 2020 (2021). El pánico e incertidumbre de los mercados se asimila a periodos post guerra, sin embargo, los motivos de estas fuertes fluctuaciones evidencian ser diferentes. Más del 36% de los saltos en EE. UU. se atribuyen a la política más que a las noticias macroeconómicas (23%) y a las ganancias corporativas (11%) (Baker, Bloom, Davis, Sammon, 2021). Si bien también existen factores que influyen para que estos saltos sean positivos, tales como la política macroeconómica y el gasto gubernamental, las fuertes caídas se presentan cuando el periodismo y las noticias no logran dar claras explicaciones sobre las caídas de precios, por ende, existe mayor incertidumbre económica, lo cual implícitamente indica que efectivamente los mercados y sus accionistas se dejan influenciar por noticias, políticas y coyunturas económicas que causan un efecto volátil inexplicable dentro del precio de las acciones.

La volatilidad, la incertidumbre y las fuertes caídas durante periodos de crisis causan comportamiento “bullish” o “bearish” en donde la psicología de los mercados pasa por periodos de pesimismo, miedo, codicia, esperanza e incluso confianza en los inversionistas. Durante períodos de alza, la confianza aumenta junto con el optimismo hasta el máximo valor que alcanza el precio. Sin embargo, las observaciones comportamentales han demostrado que la controversia existe a la baja de precios por miedo a perder, también. (Pring, 1985) Si bien existen inversionistas informados o expertos que siguen las tendencias de precios durante momentos de fluctuaciones, y

su posición con respecto a la aversión a pérdida es madura y con análisis respectivos al riesgo de pérdida, las investigaciones demuestran que ante el público general el mercado funciona de las maneras más inesperadas. Es por eso que el comportamiento histórico de precios ha sido utilizado como referencia de investigación para crear índices sentimentales que muestren el comportamiento de los accionistas, tanto “bullish” como “bearish” durante momentos de incertidumbre. (Galiana,2017)

Al utilizar tres o cuatro índices que miden los sentimientos de los accionistas, implícitamente se garantiza que está teniendo una perspectiva más acertada y útil para crear consensos que determinen la tendencia del mercado (Pring, 1985). Sin embargo, dado que los índices sentimentales son susceptibles a la subjetividad y cambios institucionales, es fundamental considerarlo como un grupo especulativo que soporte el comportamiento, mas no como un factor directo dentro del comportamiento del mercado en perspectiva de subvaloración o sobrevaloración de precios. (Pring, 1985). Como parte de la terminología del mercado financiero, se ha demostrado que las acciones optimistas al alza se llaman “bullish” y pesimistas a la baja, “bearish”. Por lo tanto, la tradicional frase de “*compre barato y venda caro*” es una actitud común de “bullish”, contrariamente cuando quieren vender caro por precios bajos se conoce como actitud “bearish”. (Galiana,2017)

Estos términos no sólo son técnicos al momento de describir actitudes referentes a la compra y venta de acciones, sino que también investigadores y el Association of Individual Investors (AII) las han utilizado para crear índices que describen el comportamiento de los inversionistas. Estas están atadas a estrategias de inversión en donde los inversionistas “bullish” encuentran el éxito de tomar posiciones que resulten en ganancias si el pronóstico es correcto. Por el contrario, los inversores “bearish” son aquellos pesimistas que estiman que de acuerdo a la

situación pronosticada los precios irán a la baja. Para ambos comportamientos no existen fórmulas matemáticas que diferencien una acción de la otra; es por esto que lo anterior se basa meramente en la percepción propia del mercado, ya sea alza o baja, y así tomar decisiones respectivas de compra y venta. (Galiana, 2017).

Por otro lado, en la teoría empírica, se evidencia cómo los incentivos de inversión suelen tener vacíos a la hora de explicar el comportamiento de las inversiones en el mercado de capitales. Es por esto que los autores Malmendier & Tate (2005), proponen incluir características personales como una variable fundamental y medible a la hora de tomar decisiones. Evidencias históricas han demostrado que la confianza de los CEOs respecto al precio de mercado y el valor de una empresa, está relacionada claramente con el desempeño y niveles de flujo de caja; no obstante, ante su propia percepción siempre serán superiores con respecto a su competencia.

Efectivamente el flujo de caja aumenta las posibilidades de inversión, pero son las decisiones basadas en “Better Than Average” las que incentivan a tomar mayores riesgos, dejando a un lado temas como política de la empresa y los riesgos de franquicia y mercado (Malmendier & Tate, 2005). Por ende, es fundamental tener presente comportamientos de rebaño, aversión a pérdida, sobre confianza como variables explicativas de comportamientos “bullish” o “bearish” como complemento al desarrollo de pronósticos y tendencias de precios del mercado de acciones.

6. Marco teórico

La toma de decisiones en el Mercado de Valores ha sido estudiada por múltiples académicos y teorías, con el fin de encontrar modelos óptimos y estrategias de inversión que permitan anticiparse a las tendencias del mercado y obtener beneficios o rendimientos adicionales.

La Teoría del Portafolio moderno (Markowitz, 1952) es considerada la base de los modelos clásicos más reconocidos de valoración de activos. Markowitz investigó cómo los inversionistas pueden desarrollar carteras de activos financieros eficientes, basados en el riesgo y la utilidad esperada. La Teoría del Portafolio Moderno propone una “Frontera Eficiente” con la que se crea un portafolio dado un nivel de riesgo determinado como límite o frontera, el cual debe generar un nivel óptimo de utilidad. Según esta teoría al realizarse un análisis en conjunto con estadísticas como la correlación y la varianza, se puede crear un portafolio con diversos tipos de acciones que, en su conjunto, cumplen o llegan a la frontera esperada de riesgo, y que pueden favorecerlo con una mayor utilidad, que cuando se evalúan las acciones individualmente. La Teoría del Portafolio Moderno asume que los agentes como entes racionales, tomarán sus decisiones de inversión basados en la información y principalmente en el riesgo que desean asumir en un momento u otro.

En décadas posteriores, varios autores han complementado esta teoría incluyendo otras variables que pueden afectar la decisión de inversión: “han abordado problemas inter temporales de los portafolios, para incorporar características realistas como los multipremiados de inversión, los costos de transacción o la imposibilidad de transar en tiempo real” (Jacquier, 2013). Sin embargo, varios autores ignoran las variables existentes por la irracionalidad de los agentes participantes en los mercados.

Una de las teorías más discutidas sobre el comportamiento de los mercados es: “La hipótesis de los Mercados Eficientes” (Fama,1970) Según esta el precio de un activo es el reflejo de toda la información histórica, pública y privada del mismo. Esto implica que ningún inversor pueda obtener un beneficio superior al de la media del mercado y que ningún activo estará mal valorado en el mercado de valores pues a un cambio en la información el precio se ajustará casi automáticamente.

Según la teoría hay 3 factores que afectan el valor del activo:

- **Número de participantes:** A mayor número de participantes, mayor eficiencia del mercado.
- **Costos de transacción o información:** A mayores costos, menor eficiencia del mercado pues en caso de que los costos superen el beneficio, se desincentiva la participación en el mercado y a menor número de participantes menor es la eficiencia.
- **Información disponible:** A mayor información disponible, mayor eficiencia pues se reduce la asimetría en la información.

Adicionalmente, según la información que haya intrínseca en el precio del activo se dividen los tipos de eficiencia:

- **Eficiencia Débil:** Según esta el precio del activo refleja la información histórica del mismo y el inversor solo podría superar el beneficio del mercado si tiene información pública o privada. En este caso un análisis técnico de la acción no permitiría obtener una utilidad adicional a la de los otros participantes del mercado.

- **Eficiencia Semi fuerte:** Esta eficiencia se da por que el valor del activo está dado por la información histórica y también la pública disponible. En este caso el inversor sólo podría obtener un mayor beneficio si cuenta con información privada, es decir privilegiada de la empresa.
- **Eficiencia Fuerte:** La eficiencia del mercado es fuerte cuando el valor del activo refleja toda la información existente y si existiera algún tipo de información privilegiada el precio se ajustaría rápidamente y no le permitiría beneficiarse a ningún actor.

La HME según Fama (1970) y Ludlow (1997) está dada por los siguientes supuestos:

- **Libertad de precios:** Los precios se dan de manera automática por la interacción de oferta y demanda, y no existen ningún tipo de restricciones de precios.
- **Libre entrada y salida del mercado:** Los inversionistas pueden comprar o vender acciones en cualquier momento.
- **Información sin costo:** Todos los inversionistas poseen la misma información sin costo.

Sin embargo, esta hipótesis ha sido debatida por autores como Grossman y Stiglitz (1980) quienes demuestran que la información es costosa y si el mercado tuviera una eficiencia fuerte ningún inversionista incurriría en costos de información pues se supone que está ya se encuentra implícita en el precio del activo financiero. No obstante, ellos apoyan el tipo de eficiencia débil y semi fuerte, en las cuales los actores con acceso a información privilegiada serían los únicos con rendimientos adicionales. Otros autores han intentado demostrar cómo sí se pueden obtener rendimientos superiores a los del mercado, por la naturaleza irracional de los actores del mismo;

Kaminsky y Schmukler (1999) evidenciaron que los agentes toman decisiones de inversión por efectos psicológicos como el efecto manada o rebaño, y esto causa que se alteren los precios de su valor intrínseco.

Bajo un mercado eficiente el cambio en el precio de la acción sería el reflejo del comportamiento de su utilidad o dividendos. Sin embargo Shiller (1981) encontró que la variabilidad del precio era mucho más alta que la variabilidad de los dividendos; es decir, que esta variable cuantitativa no era 100% explicativa de las tendencias del mercado. Para Shiller hay momentos en que las acciones están “caras” o “baratas”, esto se calcularía de la siguiente forma: Valor de acciones en el mercado/ Dividendos de las acciones mencionadas. Las acciones están baratas en el momento en que esta ratio sea bajo y viceversa. Lo anterior permitiría un beneficio adicional al del mercado al inversor que compra cuando están baratas y vende cuando están caras y demostraría que el precio del activo no refleja siempre toda la información existente. Hansen (1982) estudió los cambios de actitudes frente al riesgo de los inversores y analizó cómo la “expectativa” de importantes utilidades a futuro permite que los agentes mantengan activos que consideran riesgosos aun cuando están en un periodo de supuesta aversión al riesgo.

Los anteriores autores demostraron cómo la tendencia del mercado bursátil no siempre está dada por variables cuantitativas como lo postulan las teorías clásicas y adicionalmente evidencian las asimetrías de la información que no permiten que se cumpla siempre la HME. Shiller (2003) representa el paso a las finanzas conductuales en cuanto los estudios de tendencias de mercados empezaron a incluir variables irracionales de la psicología humana.

Según Kahneman (2011) existen dos sistemas que determinan el proceso de toma de decisiones: el primero es el cerebro automático que no necesita esfuerzo, es por el que toda la

información pasa inicialmente y funciona por similitud o asociación. El segundo sistema es el cerebro que añade lógica a la información y necesita de un proceso adicional deductivo; según el autor el segundo sistema se fue desarrollando a medida que el ser humano tuvo que adaptarse a ambientes más complejos y resolver más problemas. Es de aclarar que el primer sistema es el que se usa en la mayoría de las situaciones de los individuos, pero utilizar el segundo evitará caer en errores o sesgos en el momento de la inversión.

La predicción de precios siempre ha sido de las tareas más complejas para investigadores del sector financiero. Las series de tiempo se caracterizan por observaciones consecutivas, dentro de un periodo de tiempo específico (Box, 2012). Los datos no necesitan características específicas; estos son valores cuantitativos que no requieren una forma definida, aleatoria o incluso variaciones estacionales, con el objetivo de actuar como agentes predictivos utilizando valores pasados para proyecciones futuras. Esto le ha facilitado a los investigadores y organizaciones predecir variables futuras a partir de comportamientos variables del pasado (Rios, 2008). Dentro de esta metodología se encuentra el enfoque Box-Jenkins en donde cualquier serie de tiempo, estacional o no estacional, por medio de un modelo computacional crean un grupo de modelos de series de tiempo que luego determinan cuál se ajusta mejor a la serie determinada. La clase general de modelos de la metodología Box-Jenkins es la familia de modelos Autoregressive Moving Average (ARMA) en donde elementos determinísticos como la tendencia y estacionalidad de la serie de tiempo logran identificar tendencias de comportamiento al igual que proyecciones futuras. Durante mucho tiempo se utilizaron métodos econométricos tradicionales tales como el ARMA, para realizar proyecciones de series de tiempo. Es evidente que las tendencias del precio de las acciones son volátiles por lo que metodologías de Promedios Móviles intentan suavizar las fluctuaciones del precio de las acciones hacia una leve tendencia para disminuir las distorsiones de la data (Pring,

1985). Técnicos han identificado que para el propósito de identificar tendencias, los mejores resultados se obtienen graficando los resultados de Promedios Móviles, sin embargo, para el caso específico de precios, al cruzar el mismo con el promedio móvil se identifican cuando los precios se encuentran por debajo del promedio móvil y así elevar una alerta con respecto al comportamiento de los mismos. Por otro lado, esta metodología ayuda a que se elimine la subjetividad asociada a la construcción de líneas de tendencias al actuar como soporte del área de resistencia cuando el precio supera o desciende debajo del promedio móvil (Pring, 1985).

7. Desarrollo de la Metodología

Por medio de las siguientes cinco etapas de investigación se presentarán los pasos para el desarrollo de este trabajo, entre ellos: revisión bibliográfica, definición de variables y criterios, selección de datos, creación de algoritmos, simulación de datos y consolidación de resultados.

7.1 Etapa 1 Metodología: Revisión y definición de variables explicativas de estudio con base en el precio histórico de precios de acciones

La etapa preliminar consiste en evaluar detalladamente la bibliografía de estudio para identificar artículos, autores y fuentes de datos que sirvan de guía para la selección de sector industrial, periodo de tiempo y comportamientos conductuales a estudiar.

Dado que se evaluará la tendencia y volatilidad de los precios de las acciones en momentos de incertidumbre económica y financiera, se pretende escoger acciones que sean realmente representativas en el mercado de valores. Se escogió el mercado de Estados Unidos, pues NYSE (New York Stock Exchange) es considerada la bolsa de valores más grande del mundo, asimismo se escogió el índice de S&P para escoger las acciones que por su capitalización bursátil están en el Top del mismo. Se considera que la amplia experiencia de los inversionistas en el mercado de Estados Unidos es óptima para encontrar tendencias y comportamientos específicos que afectan la tendencia de los precios de los activos financieros.

Según el modelo escogido *LSTM*, se debe ingresar información histórica para identificar secuencias que permiten hacer pronósticos de tendencias. Por lo tanto las variables iniciales de

entrada que se escogieron fueron: precio al momento de apertura de mercado, valor máximo durante el día, valor mínimo durante el día y valor de cierre. Adicionalmente las teorías de *Behavioral Finance* incluyen en sus análisis variables comportamentales tales como, comportamiento de rebaño, sobre confianza, ignorancia, búsqueda de riesgo y aversión a pérdida. Por lo anterior se investigó sobre índices ya existentes que puedan reflejar este tipo de sesgos e ingresarlos como variable al modelo *LSTM*. Se encontró el *Sentiment Index*, el cual se basa en información sobre el flujo de transacciones del mercado bursátil para así determinar un comportamiento relacionado con factores exógenos que pueden afectar la toma de decisiones. Si bien la teoría indica que el mercado de acciones tiene patrones aleatorios de comportamiento, estudios como el de Kaminski (2014) indican que existe una correlación positiva entre los comentarios de inversionistas “bullish” o “bearish” y cómo el precio de cierre de las acciones se ve afectado por las siguientes variables comportamentales. Las variables explicativas que se incluirán dentro de la evaluación del modelo conductual utilizarán la base de datos de American Association of Individual Investors (AAII) la cual por medio de una encuesta determina de manera semanal, el porcentaje de inversores individuales que son alcistas o bajistas en el mercado de valores.

Asimismo, se integró una variable indicativa propia del presente estudio. El tipo de variable que se escogió fue una *dummy*, la cual se utiliza en modelos de regresión como indicativas o explicativas de una variable Y. Esta variable dummy toma por lo general valores entre 0 y 1 sobre rangos de variables cualitativas. En este caso, se incluyó esta variable a un índice cualitativo ya existente: el índice VIX (CBOE Volatility Index), que analiza la incertidumbre del mercado pues mide las expectativas de los inversionistas y por tanto como su nombre lo indica permite captar la volatilidad del mercado. Sin embargo esta se considera una variable proxy del comportamiento del

mercado toda vez que esta basado en el “sentir” de las opciones que hay sobre el S&P, el precio de estas opciones varia dependiendo el vencimiento y el nivel donde alcanzan su valor, sin embargo el índice no incluye situaciones particulares de los derivados relacionadas al vencimiento de futuros u otros elementos propios de los contratos de derivados.

Se evaluó la variación diaria del índice VIX para crear la variable *dummy* y se definió que para días con variación diaria mayor al 20% la dummy tomaría un valor de -1 y para variación diaria menor al -20% tomaría un valor de 1, todos los demás días tendrán la dummy en 0. Lo anterior nos permite ver los momentos de mayor incertidumbre en el periodo escogido.

7.2 Etapa 2 Metodología: Recopilar datos históricos del precio de las acciones más relevantes del índice S&P500

En esta etapa se pretende identificar la tendencia de precios de cierre durante momentos específicos de incertidumbre. La visión de referencia en economía y las finanzas sostiene que los cambios en el precio de las acciones reflejan respuestas racionales a noticias sobre tasas de descuento y ganancias corporativas (Baker, Bloom 2021). El rango de data a evaluar será desde 1 de abril de 2016 hasta el 30 de junio de 2021. Durante este periodo se presentaron dos momentos específicos de alta volatilidad en el índice de S&P 500:

Durante el último trimestre del 2018 el índice tuvo su mayor pérdida mensual desde febrero de 2009, se lograron identificar 3 situaciones por las que se dio la incertidumbre en ese momento: Preocupación de los inversionistas por la tensión entre la relación de China y EE.UU., incremento de 4 veces en el año de las tasas de interés por parte de la FED, y una desaceleración económica

importante por la cual los inversionistas retiraron importantes cantidades de las acciones que componen el S&P 500. En el año 2020 se presentó alta volatilidad y caídas históricas del mercado bursátil de más de un 34% durante febrero y marzo como consecuencia de la pandemia de COVID-19. Se puede considerar que las caídas de las mismas están relacionadas con momentos de incertidumbre por factores tales como:

- Los inversionistas reaccionan de manera excesiva a nueva información.
- Cómo se comportan los inversionistas ante información esperada sobre el mercado de acciones.
- Qué tanto suelen repetirse los mismos errores.
- Los inversionistas son especulativos, es decir, tienen expectativas individuales por las cuales se emocionan o interesan más en un tipo específico de acción.

Se comparó el rendimiento de las 5 de las principales acciones del índice S&P500 para determinar si las mismas son relevantes en la identificación de momentos de incertidumbre en el mercado. El valor del rendimiento diario se obtiene al sacar la fórmula de pendiente entre el rendimiento de las acciones respecto al índice S&P500. El comportamiento de las mismas se refleja en las siguientes gráficas, en donde se identifica que en particular la tendencia de la acción de AMZN va de la mano a la tendencia del comportamiento del índice. En ambos casos el momento de mayor volatilidad de las acciones estuvo entre 1 de enero de 2016 a junio 2021 interpretándose como periodo de mayor incertidumbre en el mercado y precio de acciones. Por el lado del

comportamiento de TSLA vemos grandes variaciones en la volatilidad de precio de acciones con respecto al índice. Lo anterior puede sugerir que el comportamiento de la acción tuvo variaciones significativas las cuales se evaluarán dentro de la construcción del modelo de predicción de tendencias de precios por medio de un algoritmo neuronal de memoria corta en las siguientes etapas.


No obstante, las figuras señaladas en seguida muestran cómo el rendimiento de las acciones tienen gran peso en el rendimiento del índice S&P500; durante momentos de alta volatilidad y variación del rendimiento las mismas tienen una tendencia similar, AZMN y TSLA siendo mucho más extrema versus MSFT y APPL con un comportamiento más estable y similar al del índice S&P500.

Figura 4: Rendimiento AMZN vs. S&P500




Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 5: Rendimiento TSLA vs. S&P500



Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 6: Rendimiento MSFT vs. S&P500




Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 7: Rendimiento APPL vs. S&P500



Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 8: Rendimiento FB vs. S&P500



Nota: Elaboración propia con datos de Yahoo Finance (2021)

7.3 Etapa 3 Metodología Realizar una proyección de precios de la data histórica por medio de promedios móviles ponderados a 5, 10 y 30 días

Como parte de la metodología, el comportamiento conductual se basaría en modelos predictivos. Para esto se utilizarán como fundamentos el Modelo ARMA, un modelo de promedio móvil que usa errores de pronóstico basados en un modelo similar a una regresión (Hyndman & Athanasopoulos, 2018). El análisis de promedio móvil facilitará la precisión del modelo de manera que permita pronosticar variables futuras utilizando comportamiento del pasado. Todos estos enfoques se centran principalmente en la propia serie de tiempo, ignorando otros factores que

influyen, como la información del contexto, así como su estabilidad a lo largo del tiempo. Las ventanas se determinarán al crear secuencias de movimiento para la variación de precio de las acciones seleccionadas durante un alcance de tiempo determinado. En este caso, como se ha mencionado anteriormente, se evaluaron durante enero del 2016 hasta el 30 de junio del 2021. La muestra de la variabilidad de los precios T será la información relevante para analizar el comportamiento que tienen nuestras variables comportamentales a la hora de tomar decisiones. (Salinas, 2017).

Para el análisis de las acciones se realizan tres escenarios de promedios móviles y se crea un pronóstico de tendencia que ayude al inversor a definir qué posición debe tomar, ya sea comprar, vender o mantener su posición actual. Los promedios móviles ayudarán a suavizar la volatilidad de los precios para justificar su posición y fortalecer su convicción a la hora de tomar decisiones. Para este escenario se tomaron periodos móviles de 5, 10 y 30 días y se crea un comparativo con respecto al cierre real de las acciones.

En este escenario se comparará los resultados obtenidos mediante el pronóstico del modelo de promedios móviles con respecto al desarrollo del algoritmo de red neuronal versus el precio real de la acción. Por medio de este ejercicio se evaluará e intentará determinar si las variables explicativas sentimentales influyen el comportamiento de los inversionistas, suponiendo que el mercado eficiente no existe y la incertidumbre y los riesgos que están por fuera del alcance intelectual y matemático de los inversionistas tienen mayor relevancia en la toma de decisiones en cuanto a predicción de precios y definición de tendencia.

La teoría de mercados eficientes indica que no se puede predecir precios futuros en base a los valores anteriores, debido a que la valoración es aleatoria (Johnston, 1997). La práctica

demuestra que los inversores participantes están atentos a cualquier cambio de información que les parezca atractivo, con el objetivo de generar rentabilidad. Delfiner (2002) dice que “entre más eficientes sean los mercados más aleatorios son los precios.” Precisamente por esto es que se utilizan modelos estadísticos de mercados eficientes, para definir de manera estricta una ecuación matemática, que mediante un análisis compara el comportamiento de precios bajo dos escenarios posibles.

Ecuación 1: Calcular rendimiento diario de las acciones por medio de promedios móviles

Paso 1: Calcular el valor del precio utilizando el promedio los 5, 10 o 30 últimos valores.

Paso 2: Calcular la diferencia de rentabilidad diaria de los valores pronosticados.

Paso 3: Calcular el valor absoluto de la diferencia entre el valor pronosticado y el valor real.

Paso 4: Calcular el valor promedio de los valores absolutos.

Las métricas de desempeño que se utilizarán para definir cuál de las predicciones del modelo se ajusta de mejor manera a los valores reales son las siguientes. Estas medidas nos permitirán comparar los resultados de los pronósticos. Se calcularán las siguientes dos funciones:

Paso 5: Calcular el Error Cuadrático Medio (MSE) y (RMSE)

Ecuación 1: MSE

$$MSE \equiv \frac{1}{K} \sum_{i=0}^k (S_i - S)^2$$

Ecuación 2: RMSE

$$RSME = \sqrt{MSE} = \sqrt{\frac{1}{K} \sum_{i=0}^k (S_i - S)^2}$$

Paso 6: Calcular el Error Porcentual Absoluto Medio (MAPE) al dividir el valor absoluto sobre el valor de cierre del precio de la acción

Ecuación 3:MAPE

$$MAPE = \frac{\sum_{i=0}^k |S_i - S|}{S_i} \times 100$$

Para cada muestra se estimó la predicción de precios futuros y determinó el error de cada uno de ellos, utilizando el comparativo de la data actual a partir de enero de 2016. El objetivo es evaluar cómo el valor de los precios influencia la toma de decisiones, definiendo un patrón de

comportamiento. Se graficará el comportamiento del precio de cada acción escogida durante el último año y medio para identificar momentos de alta volatilidad e incertidumbre.

7.4: Etapa 4 Metodología: Construcción de algoritmo LSTM de análisis de datos, con y sin variables conductuales

Se correrá el código inicialmente sólo con la data histórica del precio de la acción en el periodo escogido, de esta manera se pretende analizar si la red neuronal encuentra secuencias en el comportamiento pasado de las acciones que permitan hacer pronósticos. Luego se correrá una segunda vez el código para cada acción, pero esta vez incluyendo las variables cualitativas para poder concluir que tan explicativos son los sesgos psicológicos en el mercado bursátil versus un análisis de variables cuantitativas.

La base de datos se descargó de la siguiente forma:

- Se descargó información de las siguientes acciones

Periodo de 1 enero de 2016 – 30 de julio de 2021:

- Amazon, Inc - AMZN
- Tesla, Inc - TSLA
- Microsoft Corporation - MSFT
- Apple, Inc - APPL

- Facebook Inc - FB

El periodo escogido para el modelo se da por los dos momentos de crisis que se identificaron como lo fueron el último trimestre de 2018 y el segundo trimestre de 2020. De acuerdo con lo anterior existieron fuertes caídas y volatilidad en la tendencia de precios y se encontraron comportamientos atípicos a los modelos de maximización de utilidad racionales. Por ejemplo, Tesla fue una de las acciones con mayor volatilidad y crecimiento durante el año 2020, por encima de compañías con mejores indicadores financieros y del mismo sector.

El algoritmo evaluará dos escenarios principales: en el primero se aplica la hipótesis del mercado eficiente en donde todos sus inversionistas son racionales usando únicamente información pública de variables cuantitativas; el segundo incluirá variables e índices sentimentales, representando un escenario en donde los inversionistas no son seres racionales sino emocionales. De esta manera se identificará una muestra significativa de dos posibles escenarios para así comparar la diferencia de los pronósticos de precios de las acciones.

Desarrollo red neuronal LSTM:

Los modelos neuronales simulan el comportamiento biológico del cerebro por medio de los algoritmos de inteligencia artificial. En este caso, se utilizarán los fundamentos de una red neuronal para simular cómo es el comportamiento de la compra y venta de acciones. Dentro de los modelos neuronales, la unidad se conoce como la neurona y está formada por conexiones ponderadas. “El patrón de estas conexiones define la arquitectura de la red neuronal e influye en la funcionalidad

para la que la red neuronal es más adecuada (reconocimiento de patrones, clasificación, etc.). Las redes neuronales pueden "aprender" ajustando la fuerza de estas conexiones hasta que puedan aproximarse a una función que calcule la salida adecuada para un patrón de entrada dado." (Microsoft Build, 2021). La estructura neuronal tendrá tres capas: capa de entrada, una capa oculta y una capa de salida. Los valores de entrada multiplicados por la matriz de ponderaciones pasarán por la capa oculta realizando todas las posibles combinaciones de resultados. La capa oculta aumenta el número de interconexiones ponderadas y finalmente por medio de una función de activación, la suma de todas las entradas ponderadas de las neuronas calculará el valor de salida de las neuronas. Por medio de este modelo, los sesgos mencionados anteriormente, se incluyen como fundamentos del riesgo real y se evaluará la forma relativa de toma de decisiones.

Los LSTM son un tipo de red neuronal que como su nombre lo dice, por medio de su memoria de corto plazo logra aprender las dependencias y utilizarlas a largo plazo. Normalmente se utiliza este tipo de modelos neuronales para predicciones de series de tiempo.

La capa inicial de las variables de entrada son los precios que tenemos a la fecha junto con los índices relacionados. Esto se basa en datos históricos del mercado y forman una matriz o arreglo, correspondiente al rango de tiempo y variables explicativas.

La capa interna del modelo neuronal tendrá la función para que la información de la matriz de entrada se combine de todas las maneras posibles y crear una secuencia de datos que reflejen el comportamiento final de precios. El propósito de la misma es clasificar el aprendizaje del algoritmo dentro de aquellos que mejor asimila el comportamiento real. Finalmente, la distribución de los pesos lo implementa el algoritmo dentro del módulo de aprendizaje por medio de funciones internas de la librerías importadas.

Etapa 4.1: Creación del algoritmo de red neuronal de memoria de corto plazo LSTM - PYTHON

Para el desarrollo del programa se utilizó la herramienta Jupyter Notebooks como ambiente de programación en el lenguaje Python. Python es un lenguaje popular para realizar algoritmos de análisis de datos e inteligencia artificial; y existen librerías ya desarrolladas de funciones y herramientas para el desarrollo de modelos de redes neuronales, en particular para una LSTM.

1. Importar librerías

El set de datos está compuesto por el comportamiento histórico de la serie de datos desde enero del 2016 hasta junio del 2021. Como paso inicial estaremos importando las librerías keras y tensor flow las cuales habilitan el modelo de machine learning de LSTM. Adicionalmente importamos las librerías numpy y pandas. Pandas (pd) es la librería que permite convertir cualquier tipo de data en formato excel mediante columnas y filas, mientras numpy (np) es la que logra realizar funciones aritméticas. Para cada registro diario de datos se cuenta con la

información de precio de apertura, valor máximo, valor mínimo y precio de cierre para cada acción respectiva.

Figura 9: Importar Librerías

```
In [2]: pip install keras

Collecting keras
  Downloading keras-2.6.0-py2.py3-none-any.whl (1.3 MB)
    |██████████████████████████████| 1.3 MB 2.6 MB/s eta 0:00:01
Installing collected packages: keras
Successfully installed keras-2.6.0
Note: you may need to restart the kernel to use updated packages.

In [3]: pip install tensorflow

Collecting tensorflow
  Downloading tensorflow-2.6.0-cp38-cp38-macosx_10_11_x86_64.whl (199.0 MB)
    |██████████████████████████████| 199.0 MB 10.5 MB/s eta 0:00:01 |██████████████████████████████| 117.2 MB
  B 5.2 MB/s eta 0:00:16
Requirement already satisfied: six~=1.15.0 in ./opt/anaconda3/lib/python3.8/site-packages (from tensorflow) (1.15.0)
Requirement already satisfied: wrapt~=1.12.1 in ./opt/anaconda3/lib/python3.8/site-packages (from tensorflow) (1.12.1)
Collecting clang==5.0
  Downloading clang-5.0.tar.gz (30 kB)
Collecting astunparse==1.6.3
  Downloading astunparse-1.6.3-py2.py3-none-any.whl (12 kB)
Requirement already satisfied: wheel=0.35 in ./opt/anaconda3/lib/python3.8/site-packages (from tensorflow) (0.36.2)
Collecting h5py==3.1.0
  Downloading h5py-3.1.0-cp38-cp38-macosx_10_9_x86_64.whl (2.9 MB)
    |██████████████████████████████| 2.9 MB 20.7 MB/s eta 0:00:01
Collecting keras-preprocessing==1.1.2
  Downloading Keras_Preprocessing-1.1.2-py2.py3-none-any.whl (42 kB)
    |██████████████████████████████| 42 kB 2.4 MB/s eta 0:00:01
Collecting tensorboard==2.6
```

Nota: Elaborado en Jupyter Notebooks

Figura 10: Importar Librerías

```
In [43]: #importar librerias

import os

import numpy as np

import pandas as pd

import matplotlib.pyplot as plt
import math
from sklearn.metrics import mean_squared_error
%matplotlib inline

from keras.models import Sequential

from keras.layers import Dense

from keras.layers import LSTM

from keras.layers import Dropout
```

Nota: Elaborado en Jupyter Notebooks

Este modelo estará basado en arreglos en 3 dimensiones, donde la primera dimensión identifica el número de filas del arreglo o número de registros disponibles para realizar la predicción. La segunda dimensión será el número de series de tiempo, es decir el periodo de predicción se basará en los últimos sesenta registros. Por último, la tercera dimensión serán las variables de entrada, en este caso los precios de apertura, máximo, mínimo y cierre de la data descargada.

2. Entrenamiento de los datos

Para el entrenamiento de datos primero se creará la variable de entrenamiento la cual estará compuesta de un arreglo con el primer 70% de los registros de la data de cada acción. Esta se llamó training set, en donde únicamente tomará las variables de la columna 1 a 4 dado que el modelo no logra identificar el formato de fecha como parte de la serie de tiempo durante el proceso de predicción de precios. Por lo siguiente el orden de las columnas para cada lectura de datos es como muestra la imagen en seguida.

Tabla 1: Referencia columna de datos a importar a modelo LSTM

Date	Open X1	High X2	Low X3	Close X4
-------------	----------------	----------------	---------------	-----------------

Nota: Elaboración propia

Durante el entrenamiento de la red neuronal, buscaremos con este subgrupo de datos que la red LSTM logre aprender a predecir los valores de precios de apertura basado en el comportamiento del primer 70% de datos para así predecir tendencia y valores futuros de la data restante del 30%.

Figura 11: Entrenamiento de datos

```
dataset_train = pd.read_excel(r'///Users/cristinabarrero/OneDrive/Documents/Semestre IV/Trabajo grado final/Datos LSTM')
training_set = Dataset_train.iloc[:, 1:5].values

#Dataset_train.head()
training_set
```

Nota: Elaborado en Jupyter Notebooks

3. Normalización de data

Dado que los valores de entrada son valores cuantitativos de dinero se realizará una transformación de la data para que la variabilidad de los precios entre un día y otro sea comparable y proporcional al cambio de los valores de las variables x. Esta normalización de la data facilitará que el modelo logre entender las subidas y bajadas de precios. Esto se realizará mediante la opción MinMaxScaler para que todos los valores de la data se encuentren dentro de un rango de 0 a 1.

Figura 12: Normalización de datos

```
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)
print(training_set_scaled)

[[0.10823023 0.09852921 0.09983757 0.09741625]
 [0.09229536 0.09395631 0.09506822 0.09668431]
 [0.09216716 0.08766859 0.08525667 0.08081852]
 ...
 [0.90073714 0.89929348 0.89928525 0.887116 ]
 [0.88197551 0.88086063 0.89043535 0.88173537]
 [0.89014165 0.8924791 0.90202727 0.89135379]]
```

Nota: Elaborado en Jupyter Notebooks

4. Ajustes del modelo

Tomaremos la data de entrenamiento y realizaremos un ciclo *for* para que dentro del arreglo de entrenamiento sea segmentado en 60 registros para predecir el t+1 basado en la predicción de los 60 registros anteriores. El *for* continúa ciclo por ciclo de 60 días hasta llegar al final de entrenamiento la cual se acabará hasta llegar al registro 866. Cabe aclarar que se pueden realizar diferentes escenarios en donde se cambia el número de registros a valores diferentes a 60 días pero para el análisis del ejercicio mantuvimos este valor.

Figura 13: Fase de entrenamiento LSTM

```
In [44]: x_train = []
y_train = []
for i in range(60,866):
    x_train.append(training_set_scaled[i-60:i, 0:training_set.shape[1]])
    y_train.append(training_set_scaled[i, 0])

    #print(x_train)

x_train, y_train = np.array(x_train), np.array(y_train)
#x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))
print(x_train.shape)
x_train
```

Nota: Elaborado en Jupyter Notebooks

A continuación, se corre el código donde se traerán: el modelo, las capas internas de lectura, el LSTM y las capas dropout.

Estas son las librerías que se utilizan en el modelo:

- Sequential es la red neuronal
- Dense agrega las conexiones de los nodos a las capas de la red
- LSTM es para hacer la capa long short term memory layer
- Dropout capa de salida y resultado del pronóstico

Las capas dropout son fundamentales , estas se usan como medida para mitigar el *overfitting*.

El overfitting o sobreajuste del modelo se da cuando se usan demasiados datos para el

entrenamiento del modelo y no se comporta tan bien con los datos del test pues están tan alineados con los de entrenamiento que no reconocerá patrones generales para aplicarlos a una nueva data que no sea con la que se entrenó. La función lo que hace es que se remuevan aleatoriamente unidades de las capas internas. Lo anterior hará que no se ajuste en sobremedida a los resultados históricos de entrenamiento.

Figura 14: Inputs Modelo LSTM

```
regressor = Sequential()

regressor.add(LSTM(units = 50, return_sequences = True, input_shape = (x_train.shape[1],x_train.shape[2])))
regressor.add(Dropout(0.2))

regressor.add(LSTM(units = 50, return_sequences = True))
regressor.add(Dropout(0.2))

regressor.add(LSTM(units = 50, return_sequences = True))
regressor.add(Dropout(0.2))

regressor.add(LSTM(units = 50))
regressor.add(Dropout(0.2))

regressor.add(Dense(units = 1))

regressor.compile(optimizer = 'adam', loss = 'mean_squared_error')
```

Nota: Elaborado en Jupyter Notebooks

Por último, se realizaron simulaciones repetitivas mediante los epochs. En este caso utilizamos 100 epochs para evaluar diferentes escenarios y seleccionar el mejor.

Figura 15: Cálculo Epochs

```
regressor.fit(x_train, y_train, epochs = 100, batch_size = 32)
26/26 [=====] - 3s 125ms/step - loss: 0.0021
Epoch 93/100
26/26 [=====] - 3s 116ms/step - loss: 0.0020
Epoch 94/100
26/26 [=====] - 3s 109ms/step - loss: 0.0018
Epoch 95/100
26/26 [=====] - 3s 107ms/step - loss: 0.0019
Epoch 96/100
26/26 [=====] - 3s 128ms/step - loss: 0.0019
Epoch 97/100
26/26 [=====] - 3s 103ms/step - loss: 0.0019
Epoch 98/100
26/26 [=====] - 3s 110ms/step - loss: 0.0019
Epoch 99/100
26/26 [=====] - 3s 105ms/step - loss: 0.0019
Epoch 100/100
26/26 [=====] - 3s 119ms/step - loss: 0.0019
Out[44]: <keras.callbacks.History at 0x7fc0893cc8b0>
```

Nota: Elaborado en Jupyter Notebooks

Finalmente el regresor nos entregará el modelo entrenado que se utilizará en la etapa de testeo del modelo de la predicción de valores de cierre.

5. Testeo del modelo de datos a predecir

Como inputs se incluirán el set de datos de testeo junto con la data completa para el periodo de cinco años.

Se realizará el test igual al entrenamiento de datos en donde tomaremos la data restante de testeo y realizaremos un ciclo *for* para que dentro del arreglo de testeo sea segmentado en 60 registros para predecir el t+1 basado en la predicción de los 60 registros anteriores. El *for* continúa ciclo por ciclo de 60 días hasta llegar al final del testeo la cual se acabará hasta llegar al final de la

data lo cual corresponde a los restantes 515 registro que no fueron parte de la fase de entrenamiento.

Figura 16: Fase de testeo LSTM

```
In [49]: dataset_test = pd.read_excel(r'//Users/cristinabarrero/OneDrive/Documents/Semestre IV/Trabajo grado final/Datos LSTM P
dataset_total = pd.read_excel(r'//Users/cristinabarrero/OneDrive/Documents/Semestre IV/Trabajo grado final/Datos LSTM
real_stock_price = dataset_test.iloc[59:515, 1:2].values

inputs = dataset_test.iloc[:, 1:5].values
#inputs = inputs.reshape(-1,1)
inputs = sc.fit_transform(inputs)
X_test = []
for i in range(60, 516):
    X_test.append(inputs[i-60:i, 0:4])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1],X_test.shape[2]))
```

Nota: Elaborado en Jupyter Notebooks

6. Predicción de valores

La predicción de valores utilizará el resultado del regressor, es decir del modelo LSTM, el cual utilizará el entrenamiento para predecir el precio de la acción. Finalmente, esta predicción de precios se representará en un arreglo con data normalizada o transformado para lo que debemos escalar nuevamente para que los valores sean convertidos a su valor real. Esto se realiza con la opción `sc.inverse_transform`.

Figura 17: Predicción del modelo LSTM

```
predicted_stock_price = regressor.predict(X_test)
trainPredict_extended = np.zeros((len(predicted_stock_price),4))
trainPredict_extended[:,2] = predicted_stock_price[:,0]
predicted_stock_price = sc.inverse_transform(trainPredict_extended)[:,2]
print(X_test)
```

Nota: Elaborado en Jupyter Notebooks

7. Cálculo del error

Una vez tenemos la predicción de los precios pronosticados realizaremos el cálculo de RMSE por medio de python. Este utilizará los datos del set de testeo y mediante la opción `math.sqrt(mean_square_error)` obtener el resultado del pronóstico versus los valores reales.

Figura 18: Cálculo RMSE

```
In [19]: # calculate root mean squared error
testy = dataset_test.iloc[59:515, 1].values
testScore = math.sqrt(mean_squared_error(testy, predicted_stock_price))
print('Train Score: %.2f RMSE' % (testScore))

Train Score: 6.80 RMSE
```


Nota: Elaborado en Jupyter Notebooks

8. Graficar precios actuales de acciones a evaluar

Por último para graficar la tendencia de precios reales y precios pronosticados utilizaremos la librería que se importó al principio del código mediante `matplotlib.pyplot`. Se definirán los colores

correspondientes de cada tendencia y los nombres de cada eje. Finalmente, se le solicitará al programa que muestre la gráfica tal cual como se muestra a continuación.

Figura 19: Grafica modelo LSTM y predicción



Nota: Elaborado en Jupyter Notebooks

7.5 Etapa 5 Metodología: Comparar las redes neuronales LSTM (con y sin variable conductual) vs modelos de promedios ponderados

Se definió que la forma de comparar los resultados de los modelos de pronóstico sería por medio de los RMSE. Se pretende identificar el modelo que presente el menor RMSE versus los precios reales del mercado.

Se harán las siguientes comparaciones:

- Pronóstico de precios de acción por medio de promedios ponderados.
- Pronóstico de precios de acción por medio de LSTM usando información histórica del precio.
- Pronósticos de precios de acciones por medio de LSTM añadiendo el histórico de tasas de la FED para reflejar el impacto de la alta liquidez en el mercado por parte de los bancos centrales.
- Pronóstico de precios de acción por medio de LSTM añadiendo índices de comportamiento.

Los resultados de la ventana móvil serán el primer comparativo del modelo por medio del RMSE obtenido con respecto a los valores resultado del algoritmo LSTM. Cabe aclarar que debido a que los nodos de entradas contienen únicamente datos pasados, el análisis será netamente técnico, es decir, para validar la hipótesis del trabajo y no para utilizarlo como referencia en inversión de acciones. No consideramos el volumen de acciones para que todos los valores de la data fueran comparables.

En esta etapa se busca definir la relevancia que tienen las variables conductuales en el precio de las acciones y cómo esto afecta la toma de decisiones de inversión. También se pretende evaluar si el algoritmo de red neuronal logra predecir el valor de los precios mejor que el modelo tradicional de promedios ponderados y si efectivamente el comportamiento de sobre confianza y

del rebaño, pueden dar precisión sobre el valor esperado de los precios de las acciones de tecnología. Por último, se espera establecer cuáles son los principales factores que influyen sobre la rentabilidad en inversión de la acción y si éstas efectivamente pueden adaptarse en el mercado local.

El análisis de cada acción en los 3 modelos nos permitirá tener resultados concluyentes sobre la expectativa frente a diferentes tipos de acciones e industrias, así como identificar si cada uno de los modelos responde mejor a un tipo de acción específica.

8. Resultados

Esta sección está enfocada en resumir los resultados obtenidos durante el desarrollo del modelo de predicción de precios tanto por metodologías ARMA como algoritmos de memoria de corto plazo LSTM. El objetivo es determinar si efectivamente esta segunda metodología de inteligencia artificial logra pronosticar las tendencias de precios en momentos de incertidumbre financiera.

Resultados modelo ARMA:

Para los modelos de pronósticos de promedios móviles se realizó el análisis para cada una de las ventanas o series de tiempo: 5, 10 y 30 días. Lo que buscamos es definir cuál medida de ventanas móviles tiene una mejor medición al igual que comparar los resultados de las diferentes acciones evaluadas.

Con el MSE se identificó el error cuadrado promedio de nuestras predicciones. Este suele ser mayor a cálculos del MAE dado que los valores están siendo elevados al cuadrado, lo que implica que cualquier error se penaliza con un mayor impacto. Por lo tanto aquellos valores más cercanos a cero definen de mejor manera la eficiencia de nuestro modelo de pronósticos. En general se identifica que siempre que la ventana móvil sea menor tiene un error cuadrático promedio menor, es decir que el valor de los pronósticos son más acertados con el valor real de los precios. Acciones como AMZN y TSLA, que tienen alta volatilidad en su precio, tienen un

MSE mucho más alto que MSFT y APPL. Lo cual indica que la volatilidad dificulta el modelo de predicción siempre que la ventana móvil se hace mayor.

En el caso del MAPE como indicador de desempeño del pronóstico, mediremos el tamaño del error en términos porcentuales, lo cual facilita su interpretación. Para las cuatro acciones evaluadas se reconoce que el MAPE siempre es menor para aquellas ventanas móviles de 5 días. Nuevamente acciones como MSFT y APPL tienen errores constantes a su proporción de ventanas móviles, siempre obteniendo valores de pronósticos menores al 5%. En el caso particular de TSLA se identifica que al aumentar el rango de la ventana el error MAPE aumenta significativamente. Como lo menciona la figura a continuación, durante el último año, esta acción tuvo una fuerte valoración en su precio, lo cual cualquier promedio basado en resultados anteriores puede ser altamente alterado por los constantes incrementos.

En conclusión aquellas acciones con mayor estabilidad de precio mantienen mejores errores de pronósticos y definen que nuestro análisis de la tendencia de precios sea más acertado. Casos atípicos como la valoración de TSLA durante el último año y medio al igual que los altos precios de AMZN tienen errores aceptables para pronósticos de ventanas móviles cortas. Su reciente valoración en el mercado durante el periodo de tiempo de 2016-2021 nos recomienda que cualquier pronóstico sea realizado con ventanas de corto plazo para así tener aproximaciones más certeras.

Tabla 2: Errores modelo promedios móviles AMZN

AMZN 5 días			AMZN 10 días			AMZN 30 días		
MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
2914,591	53,987	2,00%	11020,883	104,980	2,92%	11161,475	105,648	4,20%

Nota: Elaboración propia con datos de Yahoo Finance (2021)

Tabla 3: Errores modelo promedios móviles TSLA

TSLA 5 días			TSLA 10 días			TSLA 30 días		
MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
264,178	16,254	4,00%	1465,627	38,284	7,64%	1341,986	36,633	9,03%

Nota: Elaboración propia con datos de Yahoo Finance (2021)

Tabla 4: Errores modelo promedios móviles MSFT

MSFT 5 días			MSTF 10 días			MSFT 30 días		
MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
11,042	3,323	1,65%	16,103	4,013	1,99%	39,777	6,307	3,20%

Nota: Elaboración propia con datos de Yahoo Finance (2021)

Tabla 5: Errores modelo promedios móviles APPL

APPL 5 días			APPL 10 días			APPL 30 días		
MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
4,136	2,034	1,95%	6,385	2,527	2,61%	19,125	4,373	4,98%

Nota: Elaboración propia con datos de Yahoo Finance (2021)

Tabla 6: Errores modelo promedios móviles FB

5 días			10 días			30 días		
MSE	RMSE	MAPE	MSE	RMSE	MAPE	MSE	RMSE	MAPE
34,048	5,835	2,08%	50,570	7,111	2,67%	128,406	11,332	4,41%

Nota: Elaboración propia con datos de Yahoo Finance (2021)

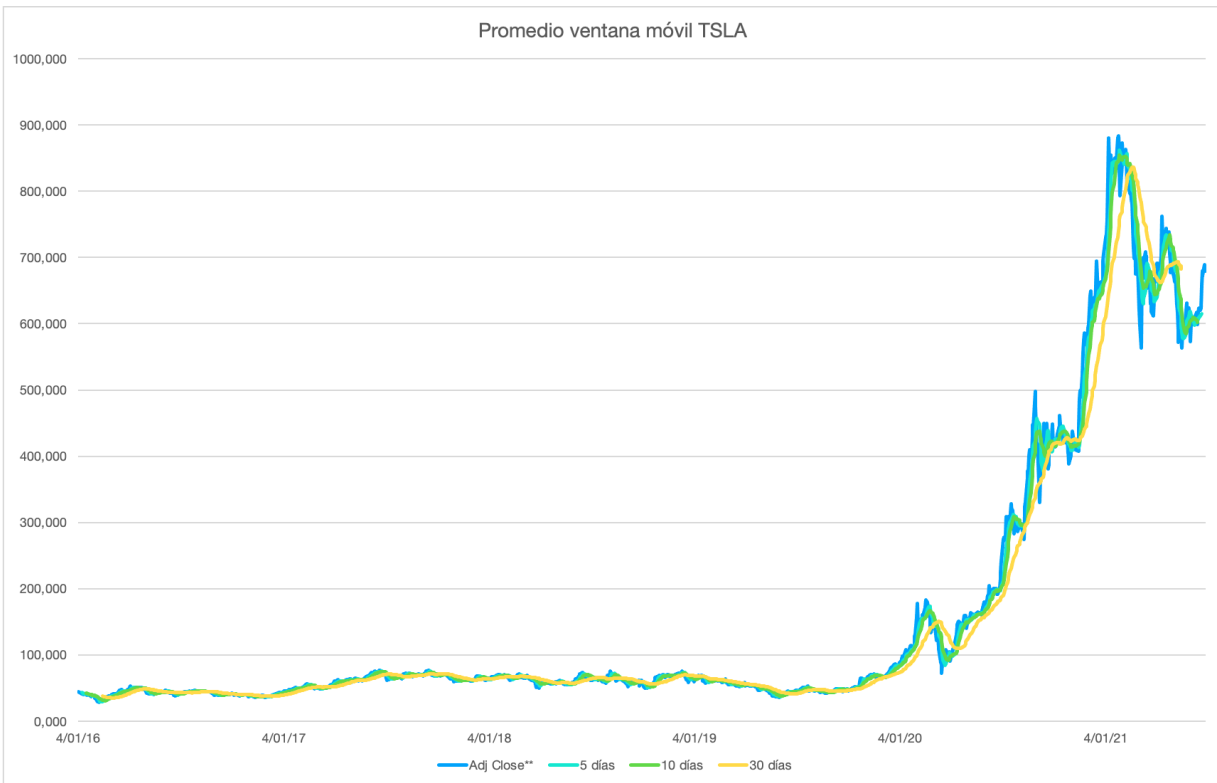
Por último, en las figuras a continuación podemos detallar como los pronósticos realizados con los tres rangos de ventanas móviles suavizan la tendencia de precios. Los pronósticos de ventanas móviles de 30 días tienen una línea más suave, sin tanta variación lo que explica su aumento en el error de los pronósticos. Si bien son metodologías aceptadas para realizar pronósticos en el caso de precio de acciones, en momento de incertidumbre se ve mayor volatilidad, un pronóstico de ventanas de mayor tiempo no logra definir un valor más acertado al valor real del mercado.

Figura 20: Promedio ventana móvil AMZN




Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 21: Promedio ventana móvil TSLA




Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 22: Promedio ventana móvil MSFT




Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 23: Promedio ventana móvil APPL



Nota: Elaboración propia con datos de Yahoo Finance (2021)

Figura 24: Promedio ventana móvil FB



Nota: Elaboración propia con datos de Yahoo Finance (2021)

Resultados modelo LSTM:

En el desarrollo del modelo de inteligencia artificial por medio de una red neuronal LSTM se logra predecir la tendencia de precios basados en entrenamiento de los datos pasados. A continuación, vemos el RMSE para cada una de las acciones y modelos:


Tabla 7: Resultados RMSE modelo LSTM

Acción	LSTM	LSTM FED Rates	LSTM- Bullish	LSTM- Bearish	LSTM- VIX Dummy
Amazon, Inc AMZN	99,2	100,53	84,86	103,35	110,48
Tesla, Inc TSLA	29,36	29,87	42,4	29,99	24,6
Microsoft Corporation - MSFT	6,8	7,98	7,84	5,87	7,45
Apple, Inc - APPL	2,35	4,86	2,49	3,83	2,74
Facebook Inc - FB	6,86	7,87	9,07	9,27	9,2


Nota: Elaboración propia

Figura 25: Predicciones LSTM AMZN

Resultado LSTM AMZN




Resultado LSTM FED Rates AMZN




Resultado LSTM AMZN Bullish



Resultado LSTM AMZN Bearish



Resultado LSTM AMZN VIX - Dummy




Nota: Elaborado en Jupyter Notebooks

Figura 26: Predicciones LSTM TSLA


Resultado LSTM TSLA




Resultado LSTM FED Rates TSLA




Resultado LSTM TSLA Bullish



Resultado LSTM TSLA Bearish




Resultado LSTM TSLA VIX - Dummy




Nota: Elaborado en Jupyter Notebooks

Figura 27: Predicciones LSTM MSFT


Resultado LSTM MSFT




Resultado LSTM FED Rates MSFT




Resultado LSTM MSFT Bullish



Resultado LSTM MSFT Bearish




Resultado LSTM MSFT VIX - Dummy




Nota: Elaborado en Jupyter Notebooks

Figura 28: Predicciones LSTM APPL

Resultado LSTM APPL



Resultado LSTM FED Rates APPL



Resultado LSTM APPL Bullish



Resultado LSTM APPL Bearish




Resultado LSTM APPL VIX - Dummy




Nota: Elaborado en Jupyter Notebooks

Figura 29: Predicciones LSTM FB


Resultado LSTM FB




Resultado LSTM FED Rates FB




Resultado LSTM FB Bullish



Resultado LSTM FB Bearish



Resultado LSTM FB VIX - Dummy



Nota: Elaborado en Jupyter Notebooks

Si bien el modelo únicamente muestra el valor futuro $t+1$. Al utilizar variables no conductuales los resultados de los LSTM, para las 5 acciones son mejores que los resultados obtenidos en el modelo de promedio de ventana móvil de 5 días. De la misma forma, el modelo LSTM con variables cualitativas acierta más que el LSTM con información histórica cuantitativa. Adicionalmente, se tuvo en cuenta que la dimensión de la serie de tiempo es mayor en los modelos LSTM y aun así logra predecir con mejor exactitud.

También evidenciamos que en el modelo LSTM las variables de Dropout logran evitar el overfitting de los datos. Si bien la tendencia pronosticada es muy clara y refleja similitudes de forma con respecto a los precios reales, no alcanza todos los picos de volatilidad que sucedieron realmente en el periodo pronosticado.

Para el caso de la adición de variables de liquidez, utilizando las tasas históricas de la FED vemos que el comportamiento de la predicción de precios logra definir la tendencia, sin embargo dado que el periodo de entrenamiento cubre un periodo en donde las tasas se encontraban mucho más altas con respecto a la fuerte caída durante el 2020, el modelo no logra definir una tendencia tan acertada dado que nadie se esperaba la fuerte inclusión de masa monetaria. Adicionalmente consideramos que este comportamiento puede ser más acertado al evaluar índices que tengan mayor visibilidad del mercado, dado que las acciones evaluadas en este trabajo por si mismas tienen una alta capitalización. No obstante es muy importante la liquidez de una acción, ya que una alta liquidez asegura bajos costos de negociación.

Para el caso de la adición de las variables conductuales como parte del LSTM presentamos varios escenarios. En el caso del índice sentimental Bullish, en donde el inversionista está positivo con respecto al mercado, el RMSE de AMZN es aún menor al resultado del modelo sin variables

conductuales. Por lo contrario, con el índice sentimental Bearish, el RMSE es mayor al primer pronóstico, lo que nos hace entender que es más fácil predecir un comportamiento Bullish que Bearish en la toma de decisiones de los inversionistas, es decir que por lo general en momentos Bullish existen más factores conductuales que se asemejan al comportamiento y tendencia de precios de la acción.

Nuevamente acciones como AMZN y TSLA, que tienen alta volatilidad en su precio, tienen un RMSE mucho más alto que MSFT, APPL y FB. Lo cual indica que la volatilidad dificulta el modelo de predicción siempre que la serie de tiempo se hace mayor. En el caso de los LSTM de MSFT y APPL vemos errores bastantes bajos lo que demuestra que por más que existan momentos de incertidumbre el modelo logra predecir la tendencia de precios con mejor precisión. Definitivamente valores de alta volatilidad, crecimientos espontáneos como el fuerte incremento de las acciones de TSLA son poco difíciles de prevenir y muestran una gran relación con variables conductuales VIX dentro de los fundamentos de toma de decisiones en el mercado bursátil. El VIX tiene efectos colaterales diferentes, consideramos que es un proxy porque tiene una explicación del comportamiento del mercado mas no es una medición exacta.

Dado que las empresas evaluadas en este modelo contienen capitalizaciones de mercados fuertes y de mayor peso en el S&P500, interpretamos que la tendencia pronosticada es bastante acertada dado a su fuerte relación. Por el hecho que la capitalización de acciones determina la situación real del mercado mediante el índice S&P500, estas 5 acciones presentan pequeños RMSE, pero en un trabajo futuro podría evaluarse otras acciones de menor capitalización para comprobar si su pronostico es igual de acertado, tanto en momento de incertidumbre junto con variables comportamentales por medio del algoritmo LSTM propuesto.

9. Conclusiones

Para evaluar la tendencia y volatilidad de los precios de las acciones en momentos de incertidumbre económica y financiera, se escogieron acciones representativas en el mercado de valores. Se escogió el mercado de Estados Unidos, pues NYSE (New York Stock Exchange) es considerada la bolsa de valores más grande del mundo; asimismo se escogió el índice de S&P para escoger 5 acciones que por su capitalización bursátil están en el top del mismo. Se considera que la amplia experiencia de los inversionistas en el mercado de Estados Unidos es óptima para encontrar tendencias y comportamientos específicos en la tendencia de precios de activos financieros. El análisis de estos comportamientos permitieron identificar los periodos de alta incertidumbre financiera. Como variables explicativas se definen: la data histórica del precio de cierre de las acciones a evaluar y asimismo 3 variables conductuales: Bullish, Bearish y VIX. Estas variables explicativas, también conocidas como variables independientes, logran explicar la variable de salida, la cual en este caso es el valor de cierre ajustado. Factores como la demanda y valor de mercado actual definen el comportamiento siguiendo la teoría de mercados eficientes, sin embargo, la interacción entre oferta y demanda no demuestra ser el único determinante del precio de una acción como lo define la HME.

La red LSTM desarrollada con los precios históricos de abril de 2016 a junio de 2021 como variable de entrada, es capaz de identificar y aprender las secuencias de los precios de las acciones para replicarlas a futuro como lo demuestra el RMSE de las 5 acciones. Cuando comparamos los precios reales con los pronosticados por la red neuronal, encontramos que la red es capaz de identificar secuencias en periodos donde el mercado se encuentra “estable” y asimismo en momentos de incertidumbre. Durante el periodo escogido se presentaron situaciones como lo son:

pandemia, inclusión de masa monetaria por parte de las reservas federales, elecciones y otras que generaron momentos de incertidumbre financiera.

Se identificó que los dos momentos de mayor volatilidad del S&P 500 fueron los siguientes:

- Cuarto trimestre del 2018, durante el último mes de este año el índice tuvo su mayor pérdida mensual desde febrero de 2009, se lograron identificar 3 situaciones por las que se dio la incertidumbre en ese momento: Preocupación de los inversionistas por la tensión entre la relación de China y USA, incremento de 4 veces en el año de las tasas de interés por parte de la FED, y una desaceleración económica importante por la cual los inversionistas retiraron importantes cantidades de las acciones que componen el S&P 500. Aquí podemos evidenciar como la “expectativa” de los inversionistas juega un papel más allá de las decisiones racionales.
- Segundo trimestre del 2020, en medio de la desaceleración de la economía a causa del Covid-19, el S&P sorprendió por su comportamiento después de la fuerte caída de finales de febrero pues en el segundo trimestre el precio de sus acciones empezó a recuperarse rápidamente y sin explicación aparente. Con esto podemos concluir que se cumple la teoría de Hansen (1982) quien destacó que la “expectativa” de importantes utilidades a futuro permite que los agentes mantengan activos que consideran riesgosos aun cuando están en un periodo de supuesta aversión al riesgo.

A pesar de que el MSE del LSTM inicial demuestra que la tendencia es pronosticable con valores históricos, este estudio expone cómo la inclusión de variables conductuales es en algunos casos indicativas del comportamiento de los precios de las acciones. Para la segunda corrida del

código LSTM se incluyeron las variables de expectativa: Tasas históricas de las FED, Bullish y Bearish, así como una variable dummy indicativa de los momentos de incertidumbre acompañados de un escenario de política monetaria expansionista reactiva a la coyuntura vista durante el 2020 la cual mantuvo proporcionalmente la volatilidad esperada del mercado. Al incluir variables conductuales el RMSE disminuyó en las acciones más volátiles como TSLA y AMZN, lo que nos indica que las variables conductuales afectan aquellas acciones con mayor nivel de expectativa por factores como: noticias, redes sociales y codicia, que fortalecen la incertidumbre de los inversionistas y por ende afectan el precio. Los resultados muestran que la tendencia pronosticada por el modelo se acerca más a la tendencia real del mercado durante los dos periodos de incertidumbre expuestos previamente cuando se incluyen las variables cualitativas.

El modelo de inteligencia artificial de corto plazo, LSTM permite demostrar que la teoría de mercados eficientes no se cumple ya que, se pueden predecir los precios futuros de activos financieros con base en valores históricos. Adicionalmente el modelo LSTM con variables de entrada cualitativas, permite un mayor asertividad en la predicción, demostrando la irracionalidad de los agentes, especialmente en momentos de incertidumbre financiera, donde los inversores no siempre se guían por el riesgo y utilidad como lo proponen los modelos clásicos de valoración, sino que están expuestos a un entorno donde el conjunto de las expectativas y la psicología de los jugadores afectan la tendencia de los precios.

Bibliografía

American Association of Individual Investor. (2021). Retrieved September 29, 2021, from https://www.aaii.com/sentimentsurvey/sent_resultsMa.

Baba, N., & Kozaki, M. (1992, June). An intelligent forecasting system of stock price using neural networks. In [Proceedings 1992] IJCNN International Joint Conference on Neural Networks (Vol. 1, pp. 371-377). IEEE.

Baker, M., & Wurgler, J. (2013). Behavioral corporate finance: An updated survey. In *Handbook of the Economics of Finance* (Vol. 2, pp. 357-424).

Baker, S. R., Bloom, N., Davis, S. J., & Sammon, M. C. (2021). What triggers stock market jumps? (No. w28687). National Bureau of Economic Research.

BBC News Mundo. (2020). Las 14 recesiones de los últimos 150 años (y por qué la del coronavirus sería la cuarta peor). *BBC*.

Brown, J. R., Ivković, Z., Smith, P. A., & Weisbenner, S. (2008). Neighbors matter: Causal community effects and stock market participation. *The Journal of Finance*, 63(3), 1509-1531.

Behavioral Finance. (2020). Retrieved from Breaking Down Finance:

<https://breakingdownfinance.com/finance-topics/behavioral-finance/>

Borovkova, S., & Tsiamas, I. (2019). An ensemble of LSTM neural networks for high-frequency stock market classification. *Journal of Forecasting*, 38(6), 600-619.

Correa, J. S. (2015). *Escritura e investigación académica: una guía para el trabajo de grado*. Bogotá D.C.: Editorial CESA.

Diario La República . (31 de 12 de 2018). *La república*. Recuperado el 5 de 10 de 2021, de En 2018 las acciones de EE.UU registraron su peor momento tras una década <https://www.larepublica.co/globoeconomia/en-2018-las-acciones-de-eeuu-registraron-su-peor-momento-luego-de-una-decada-2810722>

Ding, G., & Qin, L. (2020). Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, 11(6), 1307-1317.

Escuela de inversión. (2020). Teoría de los Mercados Eficientes. Retrieved from Centro de Educación Bursátil: <http://www.escueladeinversion.cl/teoria-de-los-mercados-eficientes/>

Espasa, A. (1980). La predicción económica. Servicios de Estudios. Banco de España.

Fischer, T., & Christopher, K. (2017). Deep learning with long short-term memory networks for financial market predictions. *Leibniz Information Centre for Economics*, 1–34.

Galiana, P. (2017). ¿Qué es Bullish y Bearish en finanzas? IEBS.

<https://www.iebschool.com/blog/que-es-bullish-bearish-finanzas/>

Gao, P., Zhang, R., & Yang, X. (2020). The application of stock index price prediction with

- neural network. *Mathematical and Computational Applications*, 25(3), 53.
- Holmstrom, B., & Milgrom, P. (1994). The firm as an incentive system. *The American Economic Review*, 972-991.
- Jacquier, E. (2013). *Portfolio Theory and Management*. H. Kent Baker, Greg Filbeck.
- Jensen, M.C. (2001), Value Maximization, Stakeholder Theory, and the Corporate Objective Function. *Journal of Applied Corporate Finance*, 14: 8-21.
- Jin, Z., Yang, Y., & Liu, Y. (2020). Stock closing price prediction based on sentiment analysis and LSTM. *Neural Computing and Applications*, 32(13), 9713-9729.
- Juste, C. A. (2020). *Economipedia*. Obtenido de <https://economipedia.com/definiciones/modelo-valoracion-activos-financieros-capm.html>
- Kaminski J, Gloor PA (2014) Nowcasting the bitcoin market with twitter signals. Accessed 9 May 2016
- KDnuggets Using a Keras Long Short-Term Memory (LSTM) Model to Predict Stock Prices. (2018). Retrieved October 2, 2021, from <https://www.kdnuggets.com/2018/11/keras-long-short-term-memory-lstm-model-predict-stock-prices.html>.
- Kothari, S. P., Lewellen, J., & Warner, J. B. (2006). Stock returns, aggregate earnings surprises, and behavioral finance. *Journal of Financial Economics*, 79(3), 537-568.

- Levitt, S. D., & Syverson, C. (2008). Market Distortions when agents are better informed: The value of information in real estate transactions. *The Review of Economics and Statistics*, 90(4), 599-611.
- Lopez, J. & Sales, O. (2020). Implementación hardware de una red neuronal Long Short-Term Memory. Universidad Complutense, Facultad de Informática. https://eprints.ucm.es/id/eprint/63059/1/LOPEZ_MELCHORVersion_final_4398578_15_5578317_modificado.pdf
- Massa, M., & Simonov, A. (2005). Behavioral biases and investment. *Review of Finance*, 9(4), 483-507
- Malmendier, U., & Tate, G. (2005). CEO Overconfidence and Corporate Investment. *The Journal of Finance*, 2661-2700.
- Malmendier, U., & Tate, G. (2015). Behavioral CEOs: The Role of Managerial Overconfidence. *Journal of Economic Perspective*, 37–60.
- Myers, S. C., & Majluf, N. S. (1984). Corporate financing and investment decisions when firms have information that investors do not have. *Journal of financial economics*, 13(2), 187-221. Recuperado el 09 de Junio de 2018
- Olsen, R. A. (1998). Behavioral finance and its implications for stock-price volatility. *Financial analysts journal*, 54(2), 10-18.
- Owen, S. (2002). *Behavioural finance and the decision to invest in high tech stocks*. School

of Finance and Economics, University of Technology, Sydney.

Revista Dinero. (3 de 2 de 2020). *Revista dinero*. Recuperado el 15 de 3 de 2020, de La inversión extranjera salvó patria: creció 25% en 2019: <https://www.dinero.com/economia/articulo/cuanto-crecio-la-inversion-extranjera-en-colombia-en-el-2019/282249>

Ríos, G., & Hurtado, C. (2008). Series de tiempo. Universidad de Chile. Facultad de Ciencias Físicas y Matemáticas, 52.

Schrand, C. M., & Zechman, S. L. (2012). Executive overconfidence and the slippery slope to financial misreporting. *Journal of Accounting and Economics*, 311-329.

Shiller, R. J. (2014). Speculative asset prices. *American Economic Review*, 104(6), 1486-1517. Recuperado el 09 de Junio de 2018

Shiller, R. J. (2020). Entendiendo el mercado bursátil de la pandemia. *El Economista*, 1.

Shiller, R. J. (2003). From efficient markets theory to behavioral finance. *Journal of economic perspectives*, 17(1), 83-104.

Shiller, R. J., & Case, K. E. (1990). Forecasting Prices And Excess Returns In The Housing Market. *Real Estate Economics*, 18(3), 253-273.

Stracca, L. (2004). Behavioral finance and asset prices: Where do we stand?. *Journal of economic psychology*, 25(3), 373-405.

Strine, L. E., & Smith, K. M. (2020, 06 15). *Companies Need to Share More of Their*

Riches With Workers. Retrieved from Bloomberg Opinion:

<https://www.bloomberg.com/opinion/articles/2020-06-15/corporations-need-to-reward-all-workers-not-just-top-managers>

Pring, Martin.J. (1985). *Technical Analysis Explained: The Successful Investor's Guide to Spotting Investment Trends and Turning Points*. McGraw-Hill.

Thushan Ganegedara . (2020). *Datacamp: Stock Market Predictions with LSTM in Python*.

Retrieved October 2, 2021, from <https://www.datacamp.com/community/tutorials/lstm-python-stock-market>.

Value School. (2019). *Origen y presente del comportamiento financiero. Value School- Inversión Consciente*

Woolridge, J. R., & Snow, C. C. (1990). Stock market reaction to strategic investment decisions. *Strategic management journal*, 11(5), 353-363.

Yahoo Finance. (2021). *S&P 500 (^GSPC)*

<https://finance.yahoo.com/quote/%5EGSPC/history?p=%5EGSPC>

Yoon, Y., Swales Jr, G., & Margavio, T. M. (1993). A comparison of discriminant

analysis versus artificial neural networks. *Journal of the Operational Research*

Society, 44(1), 51-60.