Facultad de Ingeniería

Colegio de Ingeniería Industrial

“Análisis y procesamiento de series de tiempo de activos financieros por medio de inteligencia artificial”

Tesis de Licenciatura

Presenta:

Ana Karen Guevara Aguilar

Director:

Dr. Víctor Manuel Vázquez Báez

Codirector:

M.E.S. Gabriela Yáñez Pérez

Lectores

Dr. Jose Israel Rodriguez Mora

Dra. Dolores García Toral

Grado a obtener: Licenciada en Ingeniería Industrial

H. Puebla de Z. a 03 de Diciembre de 2024

Agradecimientos

Con un gran estima y reconocimiento, extiedno mi más sincera gratitud a mi director de tesis Dr. Victor Manuel Vazquez Baez y a la M.E.S. Gabriela Yañez Perez. Por la dedicación y el tiempo que se tomaron para poder apoyarme y guiarme siendo unos pilares fundamentales en la dirección y enriquecimiento de esta investigación.

Expreso tambien mis agradecimientos a los lectores el Dr. Jose Israel Rodriguez Mora y la Dra. Dolores Garcia Toral, cuyas observaciones y construcciones con sus comentarios han sido cruciales para lograr la consolidación de este trabajo.

Tambien quisiera agradecer a la Universidad Aautonoma de Puebla, por la excelencia academica que me ayudo a formar mi camino con sus bastos conocientos para mi desarrrollo de un espiritu crítico para el desarrollo de mi carrera ingenieria industrial.

A mi padre Jose Antonio Ladron de Guevara Alcaide por su ejemplo a seguir en i vida llena de fortaleza, convicción y nunca una rendición, tambien a mi madre Veronica Aguilar Silva, por apoyarme en los momentos dificiles que surgieron durante mi proceso, por siempre estar a mi lado y mostrarme la tenacidad para poder salir adelante.

A mis hermanas mis Ana Luisa Guevara Aguilar y Maria Fernanda Guevara Aguilar, por contar con ustdes para poder cumplir mis metas junto a ustedes.

A cada uno de ustedes, mi más profundo agradecimiento por su invaluable contribución a este viaje academico.

INDICE

INTRODUCCIÓN.....4

CAPÍTULO 1. Series de tiempo.....5

1.1 Componentes de la serie de tiempo.....6

1.2 Análisis de series de tiempo mediante herramientas convencionales......9

1.3 Predicciones a partir de series de tiempo......11

Capítulo 2. Redes Neuronales Artificiales.....14

2.1 Redes Neuronales Artificiales.....14

2.2 Tipos de redes neuronales.....15

2.3 Diseño de RNA para series de tiempo.....17

2.4 Funciones de activación adhoc para el estudio de series de tiempo.....18

CAPÍTULO 3. Análisis de series de tiempo de activos financieros.....20

3.1 Implementación de redes neuronales para el análisis de series de tiempo......20

3.2 Algoritmo de funcionamiento......21

3.3 Implementación de los códigos y calibración del modelo......22

3.4 Comparación con los métodos estándar......32

3.4.1 Modelo ARIMA.....33

3.4.2 REDES NEURONALES ARTIFICIALES (RNA).....34

Capítulo 4.- Conclusiones.....36

BIBLIOGRAFÍA.....38

INTRODUCCIÓN

Analizar cualquier sistema físico, a través de mediciones del mismo, siempre esta limitado por la capacidad de medición generando un conjunto discreto de datos de los cuales es necesario extraer información o predicciones; dado lo cual el análisis y procesamiento de series de tiempo es de vital importancia para poder adjudicar un grado de precisión y exactitud para poder confiar en el modelo matemático o en las predicciones provenientes de los datos. Esto se ha realizado, durante mucho tiempo, mediante los métodos más simples de interpolación, ajuste de datos y extrapolación.

Así mismo, de forma usual, los problemas con los que nos enfrentamos dentro del ámbito de las series de tiempo son dos: el “relleno” de datos faltantes entre una medición y otra, la interpolación, o la predicción del comportamiento del sistema en un rango de operación fuera de los datos que se han medido previamente, la extrapolación. En el área del análisis numérico se han dado respuesta, mediante diferentes métodos, a estas situaciones; sin embargo, no obstante, su eficacia y precisión, se vuelven inadecuadas o tecnológicamente inoperantes cuando se trata de analizar una gran cantidad de datos (mayor a 10^6).

Este último hecho, aunado a la gran capacidad de cómputo con que hoy se cuenta en cualquier computadora de escritorio hizo que de un tiempo a la fecha se hicieran ampliamente “famosos” los algoritmos computacionales de ciencia de datos, englobados en dos grandes vertientes la inteligencia artificial y el aprendizaje de máquinas. Hoy en día, no existe ninguna aplicación de dispositivos móviles, de motores de búsqueda en la web, de plataformas de streaming e incluso de navegación, tales como Waze, que no se sirvan de uno o más algoritmos de alguna o de las dos vertientes.

En ese contexto la interpolación o extrapolación de datos a partir de una serie de tiempo es totalmente susceptible de ser abordada en el contexto de la ciencia de datos, en este trabajo planteamos específicamente su implementación en el contexto de la inteligencia artificial, donde se utilizará un algoritmo que aprenda del pasado y pueda predecir datos futuros hablando de una serie de tiempo de valores de activos financieros.

Siendo el objetivo general el realizar un análisis y procesamiento de series de tiempo de valores de activos financieros mediante inteligencia artificial a fin de realizar predicciones de valores futuros, mediante el conocimiento, creación y diseño de sistemas inteligentes con los paquetes Scikit-Learn y TensorFlow del lenguaje Python, generando predicciones diarias a largo y mediano plazo para la gestión de un portafolio de inversiones.

Por lo consiguiente, en el presente trabajo se desarrollaran los conceptos e ideas más relevantes en cuestión de Series de tiempo y Redes Neuronales (Capítulo 1 y 2), una vez teniendo claros estos conceptos, los llevaremos a su aplicación especificamente para la prediccieon de activos financieros (Capítulo 3), posteriormente se presentan los resultados obtenidos de la implementación (Capítulo 4) y por último las conclusiones del arduo trabajo realizado.

CAPÍTULO 1. Series de tiempo

Dentro de las ciencias exactas, las ingenierías y aun en las áreas sociales las series de tiempo son de vital importancia para poder analizar la evolución temporal de algún fenómeno de interés, ya sea por medios estrictamente gráficos o mediante su análisis estadístico y de tendencias. Llamamos series de tiempo a todo conjunto de datos determinados o medidos en algún instante de tiempo y ordenados cronológica o secuencialmente, este conjunto de datos puede estar o no espaciado en intervalos iguales. (Chatfield, 2003).

La serie de tiempo es un conjunto de datos que son obtenidos mediante mediciones de un evento, ya sea casual o inducido, y que se agrupan en una misma variable, dichas mediciones se realizan con un único set de instrumentos, y de ser posible en las mismas condiciones, a lo largo de un periodo de tiempo que se distribuye en intervalos, generalmente por practicidad de la misma medida. La obtención de este conjunto de datos tiene como propósito construir un mecanismo, mediante el análisis matemático del mismo, para observar y estudiar el fenómeno al que corresponde la serie de tiempo y en base a esto esta r en capacidad de identificar tendencia, patrones o pronosticar valores de su comportamiento en un tiempo estimado a futuro, lo cual es pieza clave la ingeniería industrial para poder llevar a cabo una planeación y toma de decisiones en diversas áreas de esta disciplina.

El intervalo de tiempo que se utiliza varia ya que este podría ser anual, semestral o a cada minuto o segundo, dependiendo la duración del intervalo de medición del fenómeno en específico bajo estudio, por ejemplo si realizamos un conteo de manchas solares un intervalo de medición en la escala de segundos minutos e incluso horas no sería de gran utilidad por lo cual se utilizan periodos mensuales, para mayor facilidad en el análisis de la serie es recomendable mantener una frecuencia constante con la se realizan las observaciones (lo cual en muchos casos prácticos no es posible), ya que con estas observaciones se construirán gráficos donde se observan el comportamiento de los datos y contar con mediciones regularmente espaciadas en el tiempo facilita la interpretación de los mismos, pudiéndose extraer información y conclusiones incluso de forma visual.

Una gráfica de series de tiempo siempre tendrá dos dimensiones, en el eje horizontal se coloca la frecuencia de la medición o el periodo de tiempo mientras que en el eje vertical representamos la variable de interés, el grafico es muy importante, ya que la figura podría indicarnos algún tipo de patrón de comportamiento a simple vista, independientemente de que posteriormente se apliquen análisis por medio de otras técnicas.

Por ejemplo, la serie que se muestra en la Figura 1.1 correspondiente a la tasa logarítmica de variación del PIB de E.E.U.U., podemos ver que evoluciona alrededor de una franja acotada, entre menos dos y dos, tomando valores continuos dentro de dicho intervalo de manera oscilante, lo cual incluso nos da pie a pensar que en promedio la

variación podría ser cero o muy cercana a cero, puesto que las “subidas” se compensan con las “bajadas”.

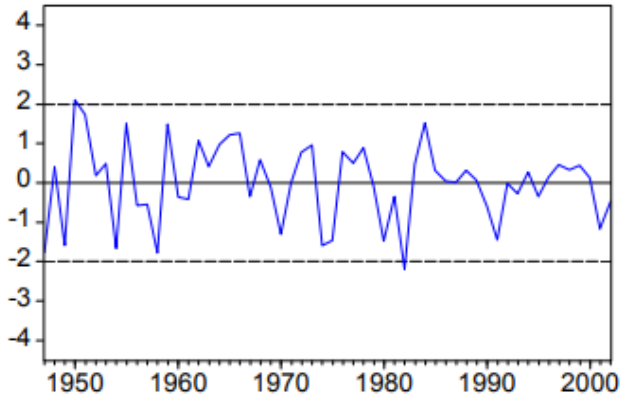

- El eje vertical mide la variable de interés
- El eje horizontal medida de los periodos de tiempo

Figura 1.1
Tasa logarítmica de variación anual del PIB real en E.E.U.U.
1947 – 2002
(consumption. Wf1)

Una serie de tiempo es importante porque nos ayuda a saber que debemos buscar y cómo podemos encontrarlo, regularmente en una serie de tiempo es posible que podamos identificar algún componente que nos permite sacar algunas conclusiones sobre el comportamiento de los datos y por ende del fenómeno que los mismos describen.

1.1 Componentes de la serie de tiempo

Con base a lo anterior se podemos argumentar que pueden existir cuatro componentes diferentes dentro de una misma serie de tiempo los cuales son:

- Componente de tendencia
- Componente Estacional
- Componente cíclico
- Componente Aleatorio

A continuación describimos brevemente en que consisten cada una de estas componentes:

Tendencia. -

Es el cambio a largo plazo que se produce por la relación al nivel medio, o al cambio a largo plazo de la media. La tendencia se identifica en la gráfica por un movimiento suave de la serie a largo plazo, esté podría ser creciente o decreciente y los datos podrían comportarse de forma lineal o no- lineal.

Estacional. –

Son los patrones del comportamiento de los datos que se repiten en intervalos de tiempo regulares, para observar si la estacionalidad existe es muy deseable considerar al menos un conjunto de datos que contenga como mínimo dos veces el número de estaciones, si el patrón de comportamiento tiende a repetirse es muy posible que los datos tengan un componente estacional pero, si el número de datos es muy pequeño y solo tenemos un dato de cada estación es imposible saber si los datos representan estacionalidad o si la variación que se observa proviene únicamente de la aleatoriedad.

Cíclico. -

Es muy parecido al componente estacional, pero la diferencia más grande es que en los ciclos el número de intervalo de tiempo pueden ser diferentes mientras que en el componente estacional, es fundamental que los patrones de comportamiento se repitan en intervalos de tiempo contantes, esto no ocurre en los ciclos, ya que regularmente la existencia de ciclos en las series de tiempo de la clase o tipo que le conciernen al presente trabajo está asociada a factores económicos como recesiones, depresión, crecimiento, entre otras.

Aleatorio. –

Este componente no refleja ningún patrón de comportamiento, sino que puede interpretarse como el resultado de factores que ocurren al azar, cuando una serie de tiempo únicamente contiene este componente, entonces la gráfica de la serie tiene un comportamiento horizontal o estacionario, lo cual genera que las necesidades, hablando de una serie de interés para la ingeniería industrial, se visualicen más notorias en las empresas un mayor y mejor control y pronóstico de la economía, existen diferentes áreas de diversas empresas en donde no sólo se pronostica el valor de la moneda sino también algunos cambios que se pueden generar a lo largo de un periodo y por tanto alcanzar un óptimo control de suministros minimizando los costos y maximizando ganancias, haciendo uso únicamente del tipo de cambio.

La presencia de estas componentes en un serie de tiempo puede tener lugar en singular, a pares por lo regular, siendo el caso extremo donde se encuentran las cuatro componentes el correspondiente al estudio de fenómenos extremadamente complejos como lo es actualmente el tipo de cambio del peso frente al dólar, lo cual da pie a utilizar herramientas como la que se presenta en este trabajo de tesis, mismo que se detallará más adelante.

Al momento de analizar y procesar una serie de tiempo, de cualquier área no solo de la ingeniería industrial, para realizar predicciones al futuro, se debe tener en cuenta que «el

objetivo de un pronóstico es posibilitar las decisiones sobre el futuro y proporcionar una estimación del riesgo involucrado en la decisión» (Erossa, 2004). Mencionamos esto puesto que incluso con la herramienta, método o técnica más sofisticada disponible, no contamos con la “bola de cristal” dado lo cual cualquier predicción va acompañada de su grado de incertidumbre y por tanto de un riesgo a la hora de tomar decisiones basados en tal predicción.

La importancia de un buen pronóstico se deriva de que existe un gran número de imprecisiones (o variables ocultas que en la práctica es imposible tomar en cuenta) que es complicado separar de la realidad, lo que genera que todas las organizaciones operen en un ambiente de cierto grado de inseguridad e incertidumbre. Por ello es preciso mencionar que para disminuir el riesgo en la toma de decisiones en la gerencia y/o de operación, es vital contar con un buen modelo del presente y así poder generar buenas predicciones a futuro, lo que conlleva a minimizar la incertidumbre en la toma de decisiones.

Para tal efecto de aminorar la incertidumbre es necesario un trabajo más preciso en lo que se refiere al control, la distribución y la utilidad en diferentes áreas, por mencionar algunos procesos, también es altamente deseable que además se obtengan datos anteriores de los procesos, porque la historia pesa, y estaremos en la mejor capacidad para obtener datos a futuros para evitar incidentes o cuestiones que no tenemos previstos hoy en día, con lo cual se evitarán errores que puedan ir creciendo a lo largo del tiempo y que vayan a ocasionar algún daño o pérdida económica dentro de nuestra organización. El análisis que aquí proponemos también es susceptible de ser aplicado no sólo a las finanzas sino a diferentes procesos generales con los que el ingeniero industrial se ve enfrentado que debe dar solución como los son: los cuellos de botellas, la reducción de costos, la optimización de tiempos, el aumento de la productividad, la disminución de riesgos, etc.

Aunado a lo anterior, consideramos que en la ingeniería industrial es de gran importancia utilizar las redes neuronales en cualquier área laboral tanto como lo puede ser en el ámbito de finanzas, al predecir el riesgo de inversiones y así poder determinar si vale la pena invertir en algún proyecto, empresa o rama, las redes neuronales también le permiten a la organización ahorrar en tiempos de trabajo, puesto que la terea de predicción se podrá realizar en un corto tiempo y con un largo tiempo de predicciones, conduciéndonos a una reducción de tiempos y eliminación de tiempos muertos.

Otro ejemplo es en el área de producción, si se generara el autoaprendizaje computacional de cómo funciona una planta industrial se podrán obtener los resultados propuestos para que exista un aumento o disminución en dicha área, lo que podrá ayudar para lograr los objetivos de mejor una manera y así evitar los cuellos de botella en la planta, esto generará tener una mejor administración desde la materia prima hasta la mano de obra, teniendo un mejor control de calidad. Minimizando de esta manera la sobreproducción o también de forma contraria.

Pero no solo es aplicable en plantas y en finanzas también se pude realizar en el área de ingeniería agrícola, porque obteniendo la base de datos de cómo se encuentra el clima en los lugares de cultivo, se podrá predecir el clima con un mínimo de error en la temporada que se sembrará o cultivará algún fruto o verdura. Esto genera un pronóstico de que tan bueno será el cultivo, también se aplica en la venta y el precio en que se pondrá la venta el producto ya cultivado. Por este medio, se obtendrá el costo del producto y las ganancias, haciendo que las perdidas sean mínimas y sin tanto riesgo. También con base a los datos programados se podrá establecer el número de personas que se pondrán a trabajar para la mano de obra con un salario más exacto a lo que se necesita en el campo de trabajo. Desde luego se obtendrán mejores resultados no solo de la mano de obra sino del cultivo, ya que generando una predicción casi exacta se evitarán las perdidas.

En esta tesis basaremos los conocimientos obtenidos durante la carrera en el área de inversiones y finanzas con la ingeniería industrial, aplicado a una serie de tiempo de datos del Banco de México con respecto al precio del peso mexicano y el dólar, desde el año 1950 hasta el 31 de abril de 2024, y así poder disminuir la perdida y saber el riesgo que se podrá llegar a tener o en su dado caso las ganancias que se obtendrán a largo plazo, gracias a la generación de predicciones de valores futuros con algoritmos de redes neuronales artificiales. De esta manera se basará en el aprendizaje computacional de alguna devaluación o alguna situación que ponga en peligro la inversión que se generó en el pasado ya que se programa la neurona a base de datos pasados, tomando en cuenta devaluaciones contra el dolar americano, o algún antecedente que pueda ocurrir en un tiempo indefinido. Generando un mejor panorama para cualquier empresa o persona que quisiera invertir sus ahorros en un banco sin riesgo de pérdida.

1.2 Análisis de series de tiempo mediante herramientas convencionales.

Existen diferentes tipos de análisis a los que se puede someter una serie de tiempo, siendo los más usados el descriptivo, que nos permitirá a entender las características de nuestra serie, el exhaustivo, que es el explicativo o también inferencial, donde se intenta explicar las razones que dieron origen al comportamiento que se llega a observar en la serie; y el predictivo, con el cuál se utiliza la información histórica de la serie para poder predecir el comportamiento en un futuro.

Para empezar a realizar el análisis de la serie, se debe tener experticia en el ámbito de la aplicación de la misma, porque necesariamente se debe saber interpretar el contenido del tipo de serie de tiempo, solo así se podrán realizar correctamente las diferentes fases del análisis y se podrá realizar la interpretación de los resultados obtenidos.

Después es necesario definir claramente los objetivos del análisis, para poder tener la ruta establecida para realizar el mismo. Posteriormente, se realizará la recolección de los datos que tengamos y así en base a los objetivos se podrá determinar la frecuencia temporal. El tiempo en que se deben adquirir los datos se podrá realizar en años, meses,

días, horas, minutos, entre otras. Y así también el tiempo de cobertura, estos dos elementos dependerán del objetivo de análisis.

Se puede realizar un mapa mental de los datos usando un análisis exploratorio, pero la herramienta más útil para una serie es a través de una gráfica de tiempo, como se había explicado anteriormente se pondrán en el eje vertical las observaciones y en el eje horizontal la variable temporal. De esta manera podremos entender el comportamiento de la señal o en dado caso si la escala de tiempo es la correcta o no, y así podremos detectar los problemas potenciales que en la generalidad de los casos podrían ser datos faltantes.

Otras de las herramientas que se implementan pueden ser sistemáticos como lo son el nivel, la tendencia y la estacionalidad o los no sistemáticos, como es el ruido que se puede encontrar bajo nuestro control ya que siempre está presente. Puede estar presente en mayor o menor grado esto depende del análisis que se realice, cuyos componentes pueden ser representados de manera aditiva esto quiere decir que la serie sea la suma de esos componentes o puede ser multiplicativa, que se multipliquen dichos componentes.

1. La estacionalidad y la función de auto correlación de la serie de tiempo

Existen diferentes métodos estadísticos para hacer el análisis de las series, pero requieren como primer paso verificar la estacionalidad de la señal. La función de la estacionalidad hace que las propiedades de las estadísticas de la serie se mantengan sin ningún cambio en el tiempo. Y así la función de autocorrelación será el resultado de comparar la señal consigo misma, esto es útil para verificar los patrones de estacionalidad o tendencia lineales

Esto le da paso al **Pre-procesamiento de la serie tiempo,** el procedimiento que se realiza en este momento es preparar la base de datos para realizar el análisis. En base a esto se analiza si hay datos faltantes o espacios vacíos en la serie de tiempo, si en dado caso existen faltantes, se puede utilizar diferentes alternativas, por ejemplo la imputación y la eliminación para el manejo de datos.

Después se analizará si los datos obtenidos son de diferentes fuentes y si fuera el caso se unificarán las resoluciones para así empezar a procesar la serie, se pude utilizar la interpolación para aumentar la resolución temporal, luego se usará el manejo de valores extremos, es decir, dependiendo de las características de la serie y el objetivo de la misma se eliminarán o preservarán dichos valores.

En el caso de que debamos realizar un análisis predictivo se debe preservar la correlación existente entre observaciones que son consecutivas dentro de la serie, lo que genera dos sub-series cuya función es:

1. El entrenamiento con las primeras observaciones
2. La otra realizará la validación de las observaciones restantes

El tamaño de la sub-serie depende de qué tipo de predicción se realizará.

Por último, después de haber realizado cada uno de los pasos anteriores correctamente, se procede con el **análisis de la serie tiempo,** y como anteriormente se menciono puede ser descriptivo, explicativo o predictivo.

Descriptivo: Se reúnen los resultados del análisis exploratorio, también de las pruebas de estacionalidad y de autocorrelación, se utilizan las gráficas de la serie de tiempo para visualizar los diferentes componentes.

Explicativo: También conocido como inferencial, se busca encontrar las relaciones de causa-efecto entre la serie de tiempo observada y la hipótesis que se quiere explicar.

Predictivo: Como menciona por sí mismo se trata de predecir valores futuros de la serie de tiempo a partir de su comportamiento histórico, cabe mencionar que existen dos enfoques principales:

- Los que se basan en modelos
- Los que se basan en datos

El análisis predictivo basado en modelos utiliza modelos matemáticos o estadísticos y generalmente se utiliza para explicar el comportamiento de la serie tiempo y a partir de esto generar las predicciones. Esto dependerá de la presencia o no de estacionalidad, periodicidad o tendencias. Existen diferentes tipos de modelos entre los que se encuentran, por mencionar algunos, los siguientes: Modelos de regresión lineal o polinómica, también los modelos Auto-regresivos (AR) y los de media móvil (MA), dentro de los usualmente utilizados hoy en día se tienen modelos como ARMA (Auto-Regressive Moving Average) y ARIMA (Auto-regressive Integrated Moving Average).

Por otra parte, el análisis predictivo que se basan los datos depende de métodos que aprenden a identificar los patrones a lo largo del tiempo dentro de la serie y que no se lleven a cabo independientemente de las condiciones estadísticas, por lo general tienen un enfoque de Machine Learning u otro tipo de método más completo como es el Deep Learning, que se utiliza para identificar los patrones en la serie de tiempo y así poder realizar las tareas de regresión o de clasificación.

1.3 Predicciones a partir de series de tiempo.

Casi todas las organizaciones grandes y pequeñas, privadas y públicas utilizan los pronósticos de manera explícita o implícita, puesto que deben planear para satisfacer necesidades o demandas en las condiciones del futuro sobre las que siempre se tiene un conocimiento imperfecto. Además, la necesidad de tener pronósticos está en todas las líneas funcionales, así como en todo tipo de organizaciones, aún en el día a día de nuestra vida personal. Dentro de una organización se requieren pronósticos en las áreas de finanzas, marketing, personal, producción, etc. (Hanke, 2006)

Esta necesidad de contar con predicciones en base a nuestra historia y nuestro presente favoreció el hecho de que el campo de los modelos estadísticos haya crecido

rápidamente, lo que lleva a tener, al día de hoy, una gran cantidad de modelos de pronósticos. Estos modelos van desde los sencillos que eran considerados inicialmente por medio de las estadísticas básicas, los tradicionales de regresión múltiple y otros modelos más complejos como las series temporales que fueron propuestos por Box y Jenkis. (Wilkinson, 1999)., cuyos modelos involucran las redes neuronales

Las técnicas en las que se basan las predicciones en series tiempo se agrupan en dos grandes bloques:

- Métodos cualitativos

Son utilizados habitualmente para predecir los cambios en los patrones de datos históricos, ya que valoran la experiencia y usan su opinión para poder establecer pronósticos que llegan a predecir en forma subjetiva los hechos a futuro. Una de las técnicas más representativas que se pueden encontrar en la literatura es el ajuste de curva que se basó en el "ciclo de vida de un producto" de acuerdo con Bowerman, O`Connell y Koehler (2007).

Se considera que el ciclo de vida tiene tres etapas, la primera etapa se basa en el crecimiento, la segunda se basa en la estabilidad y en la última aparece la declinación. Se requiere de gran experiencia y criterio para la construcción de las curvas ya que su proceso no se puede realizar manera sencilla, pero sobre todo al estar basado en la experiencia y criterio del ingeniero a cargo también conlleva una gran subjetividad.

Otro de los métodos es el Delphi, en este esquema se recurre a cuatro expertos que resuelven de manera aislada las actividades a pronosticar, luego se hace el resumen de las diferentes opiniones y después de varias rondas de cuestionamiento, se llega a un consenso que se utilizará para las predicciones.

Y por último se encuentra la técnica cualitativa que se basa en las comparaciones a lo largo del tiempo, las transformaciones en un área se predicen mediante el monitoreo de cambios que tienen lugar en un área distinta, pero que están relacionadas (Gerstenfeld, 1971).

- Métodos cuantitativos

Para implementar cualquiera de estos métodos, se requiere el estudio de información histórica para poder pronosticar los valores a futuro de cualesquiera de las variables de interés, se pueden agrupar en dos grupos:

  - Modelos univariados

Los cuales predicen el futuro de la serie con base en su propio comportamiento histórico, son de mayor utilidad si en dado caso el patrón detectado en el pasado se llega a mantener en el futuro, de lo contrario no es muy aconsejable el uso de este tipo de modelos.

  - Modelos Causales

Para implementar este tipo de modelos se requiere de otras variables, además de las canónicamente involucradas, para así relacionarlas de manera Causa-Efecto, con la variable que se quiere predecir. Una vez obtenidas las variables relacionadas, se construye un modelo estadístico que procura describir la relación entre las variables y la variable que se pronosticará, despreciando la presencia de variables ocultas. Uno de los modelos más conocidos en este grupo es el de regresión lineal simple y los modelos de regresión no lineales.

Cualquier serie de tiempo presentará variaciones, por ello es importante para la descripción y estudio de fenómenos que evolucionan con el tiempo, las variaciones que se encuentran en una serie de tiempo se clasifican como sistemáticas y aleatorias, donde las sistemáticas ocurren con una mayor regularidad, por lo cual son más susceptibles de ser modeladas, y las aleatorias que son causadas por situaciones aisladas y fuera del control del observador del fenómeno o sistema bajo estudio, por ejemplo, terremotos, huelgas, depresiones, crisis, surgimiento de empresas unicornio o la ocurrencia de pandemias (como recientemente vivimos y padecimos), entre otras. Es precisamente por este tipo de características que son difíciles de modelar.

Se han identificado, sin descartar la posible identificación de alguna otro, a lo largo del estudio de las series de tiempo, desde sus orígenes hasta nuestros días, tres diferentes tipos de variaciones que son:

- Tendencia secular.
    - Al estudiar la serie en periodos extremadamente largos, de acuerdo a la escala del sistema a la que dicha serie describe, el observador se da cuenta que existen ciclos en el comportamiento de la serie y, por tanto, del sistema bajo estudio; generalmente son debidas a factores económicos importantes (hablando sólo de la industria que es el ramo que nos compete en este trabajo) relacionados con ciclos recesivos o de crecimiento, aumento de la población, los avances tecnológicos (recordemos la ley de Moore) o el surgimiento de tecnologías emergentes; entre otras. Todos estos factores conllevan al sistema a desembocar en una clara tendencia cíclica de ascendentes, descendentes o en ninguna evolución (en promedio).
- Variación estacional
    - De acuerdo a la definición más ampliamente aceptada en la literatura (María del Mar Ballesteros Aguado,2021), la estacionalidad es una especie de secularidad que se da en intervalos de tiempo inferiores o iguales a un año; el ingeniero a cargo del monitoreo del sistema debe siempre estar pendiente de las variaciones que se reflejan en comportamientos que se repiten de la misma forma cada año.
- Variaciones cíclicas
    - Describe las fluctuaciones a largo plazo (mayor que la estacionalidad pero menores que la secularidad), que se repiten regularmente cada

cierto número de años en actividades económicas: en periodos de crisis, booms económicos, subida en las tasas de interés, etc.

Capítulo 2. Redes Neuronales Artificiales

2.1 Redes Neuronales Artificiales

Las redes neuronales artificiales (RNA), constituyen un sistema que se encuentra compuesto por nodos y conexiones computacionales entre los mismos, cuya red ya interconectada (a modo del ingeniero a cargo y encaminado a la tarea por cumplir), cuentan con una organización jerárquica, en las cuales se procesa la información de entrada dando como respuesta una salida.

La red neuronal artificial tiene como objetivo principal su propio autoaprendizaje a fin dar consecución a una tarea, se encuentra inspirado en el sistema nervioso de los organismos biológicos, el cual consiste en un conjunto de nodos que se activan o no dependiendo del estímulo que cada neurona reciba, así la red neuronal artificial recibe el conjunto de datos o diversos eventos de entrada, los procesa y aprende de ellos, con el objetivo final de producir una salida (respuesta), a través de su sistema de interconexión de neuronas artificiales,

Los algoritmos de inteligencia artificial, al día de hoy son innumerables, la idea de programar a una computadora para que aprenda, decida y actúe por sí misma no es nueva, (Sandra Navarro 2024); sin embargo, al día de hoy contamos al menos con diversas automatizaciones, encaminadas al aprendizaje de las computadoras (o del código con que están programadas en sí mismas) en diferentes aspectos o aplicaciones como lo son, a saber, por mencionar algunos los siguientes esquemas:

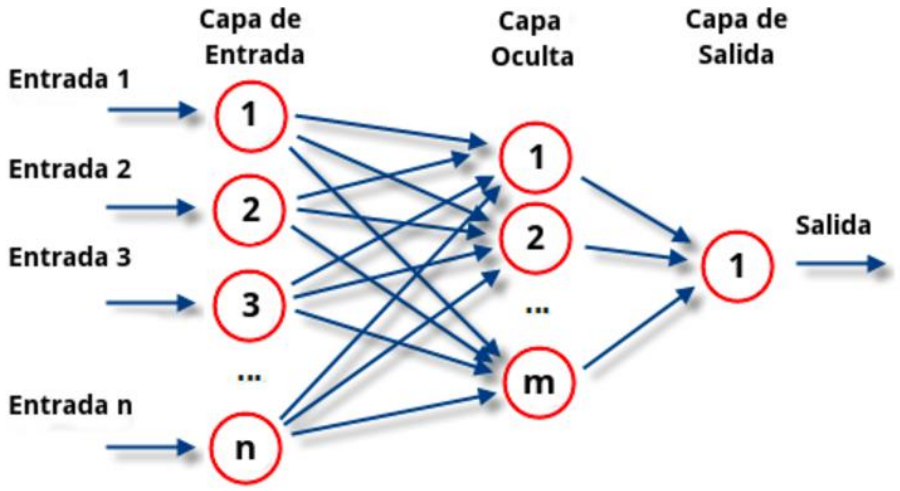

(Jorge Calvo, 2023)

A continuación describimos brevemente los componentes fundamentales de una red neuronal y los procesos que puede llevar a cabo:

Deep Learning

Es un tipo del área de Machine Learning que entrena a una computadora para la realización de tareas como lo realizamos los humanos por ejemplo, el reconociemiento de voz, identificación de imágenes o realizar predicciones, en el cual el deep learning configura parámetros básicos acerca de los datos y así entrenar la computadorea para que aprenda por cuenta propia mediante patrones y la utilización de capas en el procesamiento.

Neurona

Son las células de activación que define la salida de un nodo, dado un conjunto de entradas, cuya función es recibir, procesar y transmitir la información a través de estímulos generados por las células emisoras.

Red Neuronal artificial

Unidad de procesamiento de la información que se encuentra integrada por la interconexión de las neuronas artificiales.

Función de activación

Se define como la salida de un nodo dado un conjunto de entrada, la cual es la representación básica de cómo es el funcionamiento de una red neuronal artificial, esta función se puede describir como binaria, lo que quiere decir es que el resultado final puede ser de activación o no, ya que para producir esta función se utiliza la función escalón y sus derivados.

Arquitectura de una rede neuronal

Es la descripción de la forma en que se interconectan las entras y la salida de las neuronas artificiales de una red neuronal

Pasos o parámetros

La red neuronal es capaz de recibir varias entradas de información, los parámetros son las ponderaciones que se encuentran asociadas a cada una de las entradas con valores reales cuyos datos pueden ser positivos y/o negativos. Donde su función es multiplicar cada peso al valor de cada una y luego se realiza una sumatoria para que dé como resultado un solo valor.

2.2 Tipos de redes neuronales

Existe actualmente una gran variedad de arquitecturas para general una red neuronal artificial, dicha arquitectura varía dependiendo de la aplicación que se le quiera dar a la red, específicamente de la tarea que tiene que llevar a cabo y del resultado final que se

desea. A continuación damos una descripción de algunos de los tipos de redes que más usualmente se implementan, así como la aplicación de las mismas.

Perceptrón

Es la red neuronal más sencilla, ya que esta fue la primera red desarrollada en 1943 por Warren McCullonch y Walter Pitts, la cual consiste en un conjunto de entradas cuyos valores son multiplicados para cada uno de los enlaces y cada uno de los valores aleatoriamente, en el cual da un resultado final que debe ser comparado con un patrón preliminar y si el resultado es correcto la salida debe ser 1 si no debe ser 0. Este sistema solo se basa en una neurona y da una sola salida cuya función de activación es binaria.

Perceptrón multicapa

Su arquitectura se encuentra conformada por una serie de capas de neuronas artificiales, cada capa ella consiste en varias neuronas que se encuentran en paralelo donde todas reciben los mismos valores de entrada, pero teniendo cada una parámetros independientes de los demás. En la salida de cada neurona de una capa se encuentran conectadas como entradas a cada una de las neuronas de la siguiente capa, entre más capas tiene una neurona puede aprender información más compleja.

ADELINE

Cuyas siglas quiere decir ADAptive LInear NEuron (Neurona lineal adaptiva). La principal importancia fue su funcionamiento, ya que en fue la inspiración para la creación de otro tipo de redes neuronales. Esta red puede resolver los mismos problemas que la anterior (Perceptrón), pero la diferencia entre las dos es que ADELINE, es de transferencia tipo lineal.

Backpropagation

Es una red de aprendizaje supervisado, tiene una implementación de dos fases, de adaptación-propagación donde el objetivo es imitar el funcionamiento del cerebro humano, su utilizaci[on es lenguaje de promación es más comun al programar esté tipo de entrenamiento en Phyton, de esta manera, se utilizó para superar la limitante de la resolución de los problemas que son linealmente separables que las redes de una sola capa tenían. Se encuentra como una de las redes más actuales y más popularmente implementadas.

Aprendizaje asociativo

Este tipo de redes son capaces de auto organizarse, ya que son capaces de cambiar automáticamente los pesos en sus neuronas. En este tipo de red no es tan necesario indicar alguna respuesta correcta o incorrecta. Esto se debe a que las redes no reciben la información de que es lo correcto, sino a que el aprendizaje

que utiliza es identificando categorías, errores, irregularidades, etc. de entre las de base de datos que le son ingresadas.

Redes competitivas

En este tipo de redes se generan grupos de neuronas que compiten y se ayudan entre sí, esto se debe a que por ella misma sabrá cuales neuronas de la subred son las que quedarán activas y cuales estarán desactivadas, este proceso se va a generar en cada una de las capas. El objetivo es que la neurona por ella misma se categorice dependiendo de lo que va aprendiendo, esto se debe a que es una red no supervisada.

Redes recurrentes

Dentro de esta categoría tenemos tres tipos:

- Redes Hopfield, su funcionamiento es por medio de un control geométrico que se basa en la geometría diferencial. Su estructura es binaria donde sus valores pueden ser 1 y 0, o también 1 y -1. Su objetivo es alcanzar valores mínimos, y así poder evitar un comportamiento confuso.
- Red multicapa, tiene un valor de salida que no varía en el tiempo, al hacer esta función adquiere un comportamiento dinámico al cambiar los valores que se encontraba en entrada, poniendo un valor estacionario que converge.
- Red Elman, Consiste en utilizar dos capas de Backpropagation con la diferencia que la capa que se encuentra oculta tendrá una salida que alimenta la misma capa oculta, esto permitirá reconocer los patrones temporales o con variables en el tiempo.

Redes Feedfoward

Consiste en un conjunto de capas, las cuales no están conectadas entre sí, lo que genera es que la capa recibe y envía la información que se obtuvo a la siguiente capa. Su función es reaccionar a los cambios que se susciten en su entorno, así mantendrá un estado preciso del sistema. Su resultado final es binario y será verdadero o falso.

2.3 Diseño de RNA para series de tiempo

Una red neuronal se encuentra compuesta de neuronas, donde estas se agrupan en capas que se encuentran conectadas con las neuronas de una capa anterior. Para poder crear una red neuronal artificial, tendremos que tomar en cuenta tres puntos importantes que son:

- Numero de capas que tendrá la red
- Número de neuronas en cada una de sus capas

- La función de activación que se usará en cada capa

En cada una de las capas se realizan operaciones haciendo que nuestra red neuronal aprenda por si sola, a base de repeticiones. Para implementar una red neuronal se debe conocer cómo se realiza su funcionamiento. Este se basa en cuatro procesos los cuales son:

1. La primera capa es la que recibe los valores, conocidos también como inputs.
   - Cuyos valores fueron definidos por los datos de entrada, que por consiguiente la siguiente capa recibirá los resultados de la capa anterior.
2. Luego se realiza la suma de todos los valores de entrada
   - Para realizar este punto se necesita una matriz de pesos, que tiene la misma cantidad de filas como de neuronas en cada una de las capas.
3. Al obtener el resultado de la suma anterior se le suma otro parámetro también conocido como bias.
   - Por lo tanto, cada una de las neuronas tiene sus propias bias, en donde las dimensiones del vector bias, será en forma de columna, por lo que cada una de las filas como neuronas contiene cada capa.
4. Por último, se obtendrá el resultado de la función que por consiguiente es el resultado de la neurona.
   - Aquí tendremos la función de activación que es la clave para las redes neuronales, donde se utilizará la función de activación para evitar que nuestra red neuronal sea solo una simple regresión lineal.

Como se menciona anteriormente las redes neuronales artificiales (RNA), son modelos computacionales que procesan la información imitando el funcionamiento de las neuronas de manera biológica.

Al finalizar la estructura de nuestra red neuronal se aplica la función de activación, es la herramienta principal ya que en dado caso de no tener la función mencionada solo se realizaría una transformación lineal de los datos, lo cual se puede realizar por medio de los métodos convencionales.

2.4 Funciones de activación adhoc para el estudio de series de tiempo

La función de activación transmite la información que se generó en una capa por medio de la relación de lineal de los pesos y las entradas, es la manera de transmitir la información por medio de las conexiones de salida. Es un punto muy importante para lograr el objetivo de la red neuronal, ya que así podrá resolver problemas más complejos.

Las funciones de activación que son más utilizadas en la actualidad son:

- Función Escalón (Función de escalón unitario)
  - Es una de las herramientas más utilizadas en control. Se puede decir que es un interruptor en el cual los valores que se pueden utilizar es 0 y 1.

- Función Sigmoidal
    - Cuya función es recibir los valores y después devolverlo entre el valor 0 y 1. Lo que genera que sea una función útil para modelar probabilidades y así poder realizar clasificaciones binarias.

- Función Rectificadora (ReLU)
    - Se utiliza para valores negativos y la función devuelve los datos en cero, pero en funciones con valores positivos regresa el mismo valor. Es una de las herramientas más utilizadas en la actualidad ya que evita el Grandient vanish (Desvanecimiento de gradiente) que se refie a una disminución exponencial de los gradientes durante la programación del error lo que puede generar una dificultad en los pesos de las capaz en nuestra red neuronal.

- Función Tangente Hperbólica
    - Su principal objetivo es poder mapear entre un rango de –1 a 1. Donde se define como una relación entre el seno y coseno hiperbólica. Lo que quiere decir es que es una función simétrica. Cabe mencionar que es una función no lineal, lo que genera que se pueda trabajar con relaciones no lineales entre los datos.

- Función de Base Radial
    - Es una función con uno de los mejores desempeños ya que trabaja con un mayor número de datos para el entrenamiento, para su construcción se requiere una mayor cantidad de neuronas en los nodos. Generalmente se utilizan realizar patrones de entrenamiento con un gran volumen de datos. Esta función también es conocida como una red con alta eficiencia en la base de entrenamiento.

CAPÍTULO 3. Análisis de series de tiempo de activos financieros

En el presente capítulo se desarrollará un análisis y procesamiento de la serie de tiempo de valores de activos financieros mediante inteligencia artificial a fin de realizar predicciones de valores futuros. Como se menciona anteriormente nos ayudará a disminuir el riesgo de inversión a lo largo del tiempo, pero también a eliminar pérdida de tiempo o de recursos durante el periodo que se genera una inversión, para tener un mejor desempeño, por otra parte, tomando en cuenta los datos que se obtuvieron con anterioridad para implementar su análisis mediante redes neuronales se podrán lograr objetivos de manera más precisa.

3.1 Implementación de redes neuronales para el análisis de series de tiempo.

Analizar cualquier sistema físico, a través de mediciones de este, siempre está limitado por la capacidad de medición generando un conjunto discreto de datos de los cuales es necesario extraer información o predicciones. Esto se ha realizado, durante mucho tiempo, mediante los métodos más simples de interpolación, ajuste de datos y extrapolación, en el presente trabajo realizaremos dicha tarea mediante la implementación de técnicas de inteligencia artificial para predecir valores futuros del precio del peso mexicano frente el dólar, considerando una serie de tiempo, obtenida del Banco de México (JA Martínez-Escobar · 2020), desde el año 1950 hasta el 31 de abril de 2023.

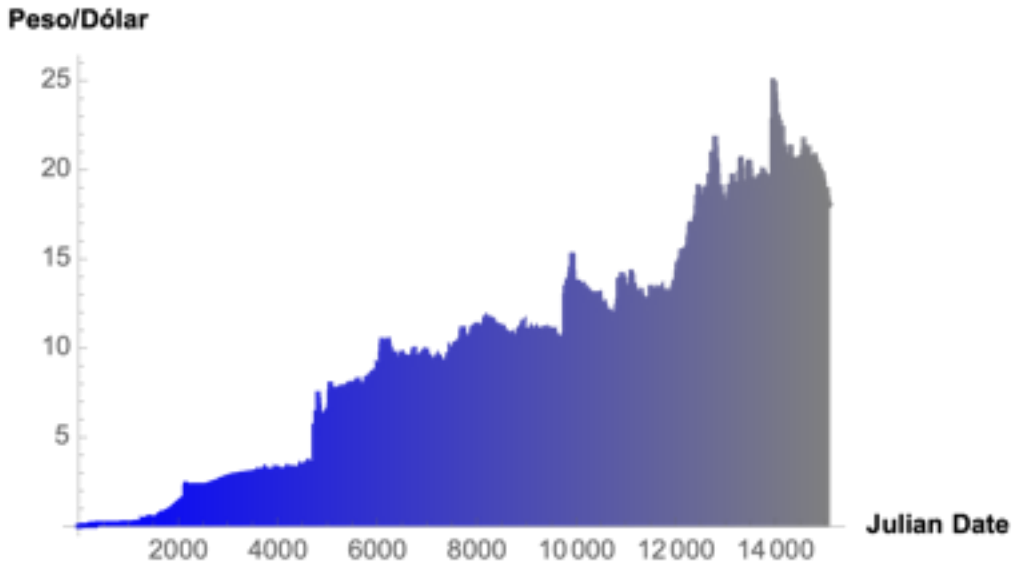

Figura 2. Gráfica de tiempo, Tipo de cambio peso dólar 1982-2023.

El tipo de análisis de la serie de tiempo es de tipo predictivo basado en las técnicas de Deep Learning, ya que se utiliza la información histórica de la serie para poder predecir el comportamiento en un futuro; siendo la variable de interés el valor del precio del dólar como se puede apreciar en la gráfica de tiempo (Ver Figura 2.). Siendo la técnica del Método cuantitativo en el grupo univarido con variaciones cíclicas.

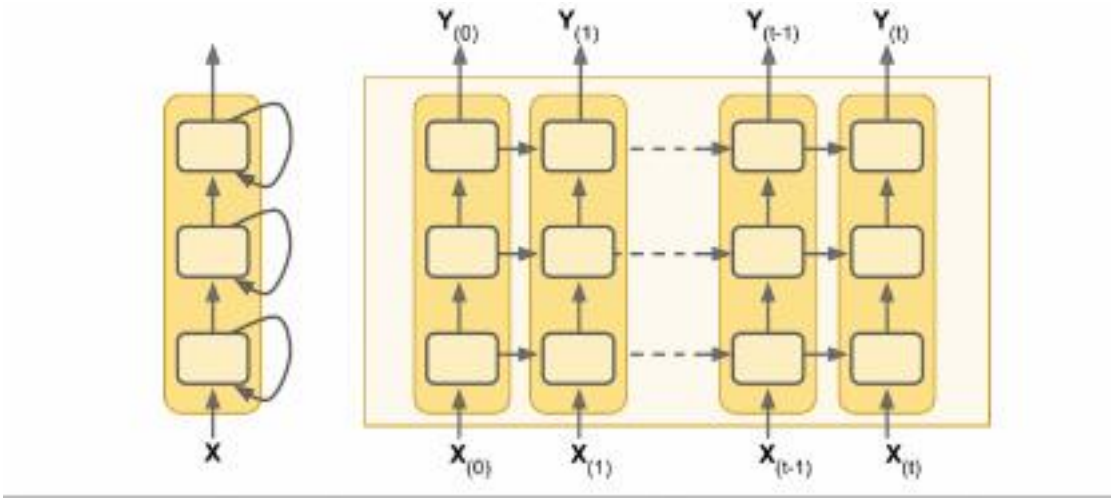

Figura 3. Modelo Red Neuronal Perceptrón Multicapa.

El modelo de Red Neuronal a utilizar es perceptrón multicapa (MPL), el cual proporciona resultados satisfactorios al resolver problemas financieros; se compone de una capa de entrada (de paso), una o más capas de TLU (unidad lógica de umbral), llamadas capas ocultas, y una capa final llamada capa de salida (Ver Figura 3). CAMBIAR POR EL MODELO DE RED NEURONAL RECURRENTE (RNN)

La estrategia de preparación de evaluación del modelo consiste en separar las observaciones en un conjunto de entrenamiento, un conjunto de validación (o validación cruzada) y un conjunto de prueba. Es muy importante asegurar que ninguna información del conjunto de test participa en el proceso de entrenamiento del modelo; siendo entonces entrenamiento 80%- test 20%, el reparto se realizó de forma aleatoria.

3.2 Algoritmo de funcionamiento.

El proceso para realizar el análisis y posterior predicción de valores en una serie de tiempo se realiza de la siguiente manera:

- Se maneja un mini lote a la vez (por ejemplo, que contiene 32 instancias o datos cada uno), y pasa por el conjunto de entrenamiento completo varias veces. Cada pase se llama época.

- Cada mini-lote se pasa a la capa de entrada de la red, que lo envía a la primera capa oculta. Luego, el algoritmo calcula la salida de todas las neuronas en esta capa (para cada instancia en el mini-lote). El resultado se pasa a la siguiente capa, su salida se calcula y se pasa a la siguiente capa, y así sucesivamente hasta obtener la salida de la última capa, la capa de salida. Este es el pase hacia adelante: es exactamente como hacer predicciones, excepto que todos los resultados intermedios se conservan ya que son necesarios para el pase hacia atrás.
- A continuación, el algoritmo mide el error de salida de la red (es decir, utiliza una función de pérdida que compara la salida deseada y la salida real de la red, y devuelve alguna medida del error).
- Luego calcula cuánto contribuyó cada conexión de salida al error. Esto se hace analíticamente aplicando la regla de la cadena (quizás la más fundamental regla de cálculo), lo que hace que este paso sea rápido y preciso.
- Posteriormente, el código mide cuánto de estas contribuciones de error provienen de cada conexión en la capa de abajo, nuevamente usando la regla de la cadena, trabajando hacia atrás hasta que el algoritmo llega a la capa de entrada. Como se explicó anteriormente, este paso inverso mide eficientemente el gradiente de error a través de todos los pesos de conexión en la red propagando el gradiente de error hacia atrás a través de la red.
- Finalmente, el algoritmo realiza un paso de descenso de gradiente para ajustar toda la conexión de pesos en la red, utilizando los gradientes de error que acaba de calcular.

Resumiendo, el algoritmo: para cada entrenamiento primero hace una predicción (paso hacia adelante) y mide el error, luego pasa por cada capa a la inversa para medir la contribución del error de cada conexión (paso inverso), y finalmente ajusta la conexión pesos para reducir el error (paso de descenso de gradiente).

3.3 Implementación de los códigos y calibración del modelo.

Siendo el objetivo de la presente tesis el realizar un análisis y procesamiento de series de tiempo de valores de activos financieros mediante inteligencia artificial a fin de realizar predicciones de valores futuros, mediante el conocimiento, creación y diseño de sistemas inteligentes con los paquetes Scikit-Learn y TensorFlow del lenguaje Python, generando predicciones diarias a largo y mediano plazo para la gestión de un portafolio de inversiones, se llevo a cabo la creación del código siguiendo la metodología que acontinuación se presenta:

1.- Recopilación de base de datos.- Para desarrollar la RNN, divididos en 80% conjunto de entrenamiento y 20% conjunto de prueba, de forma aleatoria.

2.- Estructuración de la RNN, este paso es mejor conocido como el diseño de la arquitectura de la RNN.

3.-Entrenamiento de la red neuronal.- Ajuste de los factores de peso (proceso interno) para la conexión y así minimizar los errores en la salida (resultado de la predicción).

4.-Validación.- Se verifica si los resultados son precisos utilizando el conjunto de prueba.

5.- Implementación.- Se podrá implementar la RNN en diferentes áreas.

A continuación, se visualizan las gráficas que se han obtenido en el proceso de calibración de la RNN, donde la validación de los datos, las perdidas y los resultados de la predicción, como se mencionó anteriormente los datos que teníamos se dividieron en 80% para entrenar y 20% para poder verificar que nuestra predicción es correcta. Aquí se mostrará si nuestra RNN es factible para nuestra investigación. También cabe señalar que se actualizaron los datos donde se trabajaba ya que no fue necesario tomar los datos desde 1954, sino que se tomaron desde el 2010, hasta el año en curso. Lo anterior debido a que en el transcurso de las corridas de prueba, donde se experimentó con los diversos factores involucrados en la arquitectura de la red, de donde se didentificó una arquitectura que provee resultados óptimos con un conjunto relativamente pequeño de datos, como se mostrará más adelante.

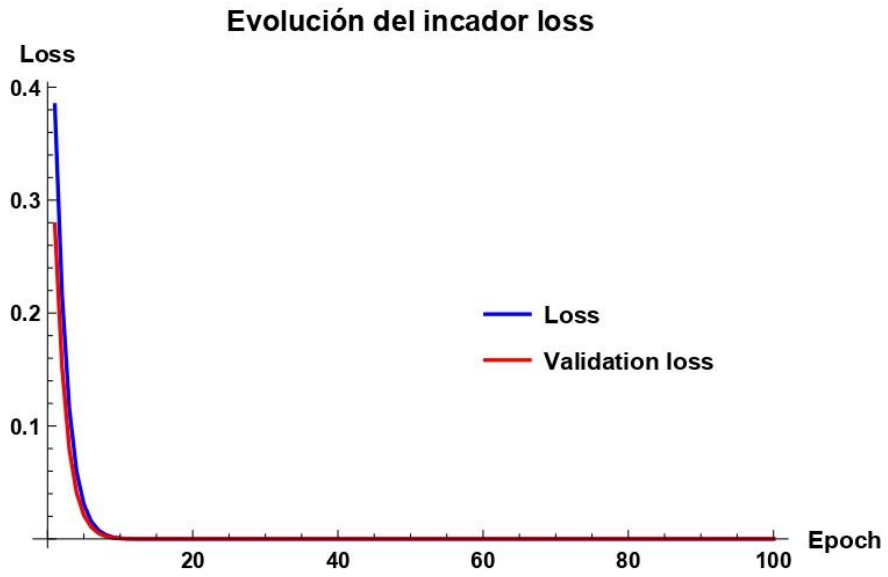

La gráfica anterior es del año 2010 a la fecha, en la cual se muestran los resultados del desempeño de nuestra red neuronal, donde la curva azul muestra el valor de la pérdida durante el entrenamiento y la curva roja es la pérdida durante la validación. Se puede mostrar que se genera la misma curva y llegar al mismo resultado de los datos anteriores como con los datos que se generaron. La pérdida, o Loss, es una función que evalúa la desviación entre las predicciones realizadas por la red neuronal y los valores reales de las observaciones utilizadas durante el aprendizaje, en fracción porcentual. Cuanto menor es el resultado de esta función, más eficiente es la red neuronal.

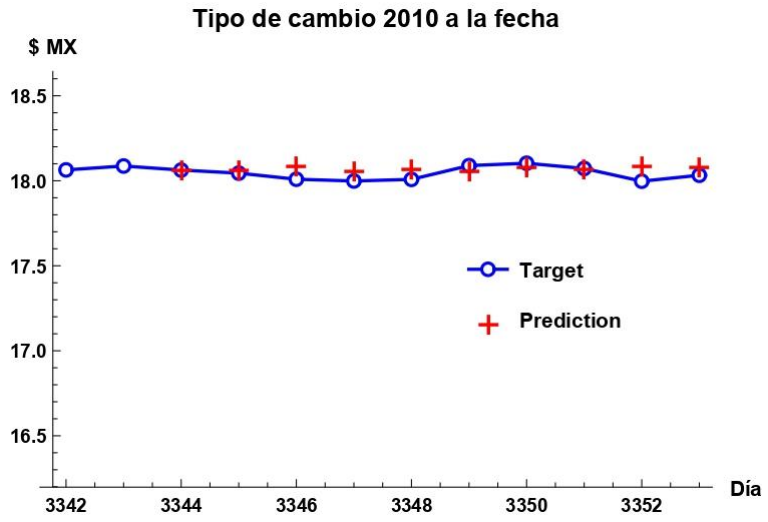

En esta gráfica correspondiente también a datos del 2010 a la fecha, donde visualizamos el objetivo de nuestra predicción con círculos azules y lo que se encuentra marcado con una “+” es la predicción, si los dos se encuentran es porque la predicción es más exacta o son iguales. En el cual empezamos con los datos 3.95E-01 y se concluyó con los datos 6.78E-11.

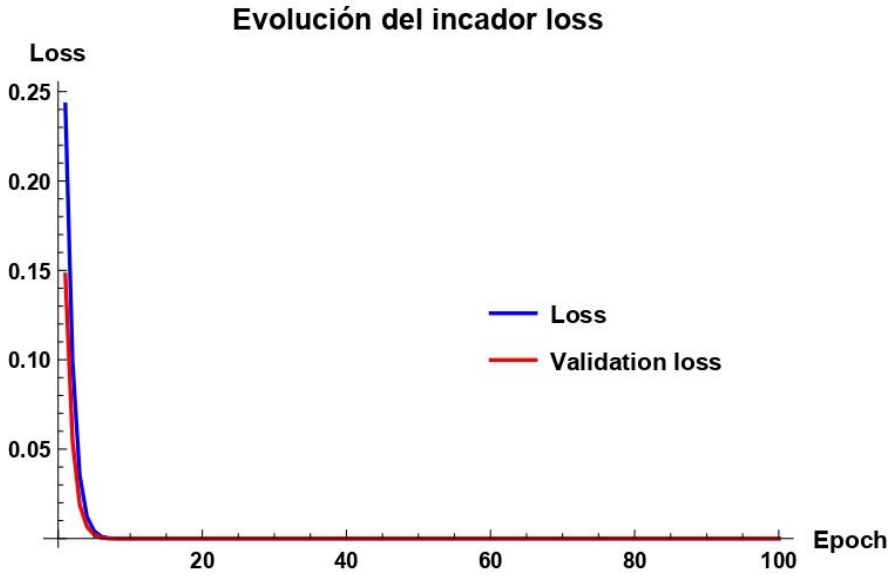

En esta gráfica se muestran observaciones del año 2018, donde se aprecia que la perdida de validación vuelve a coincidir en un punto después y después es continua entre las dos líneas del estudio se mantiene así a lo largo de las epocas (iteraciones), los valores son menores que en la gráfica con datos del 2010, por lo cual es más eficiente la red neuronal, dada su arquitectura en correspondencia con el conjunto de datos que se le proporcionan a la red.

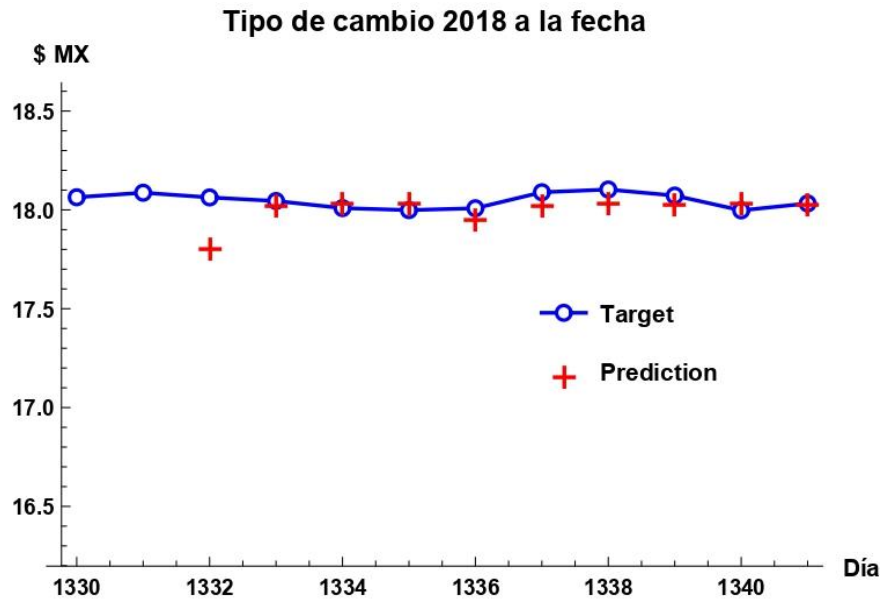

Podemos comentar que en la gráfica anterior, tienen más puntos de encuentros donde corroboramos que nuestro predicción funciona de manera más eficiente y se han tomado datos desde el 2018 a la fecha, lo que genera un resultado eficiente para poder avanzar más con nuestra RNN. Donde empezamos con los datos de 1.04E-01 y terminamos con 7.65E-11.

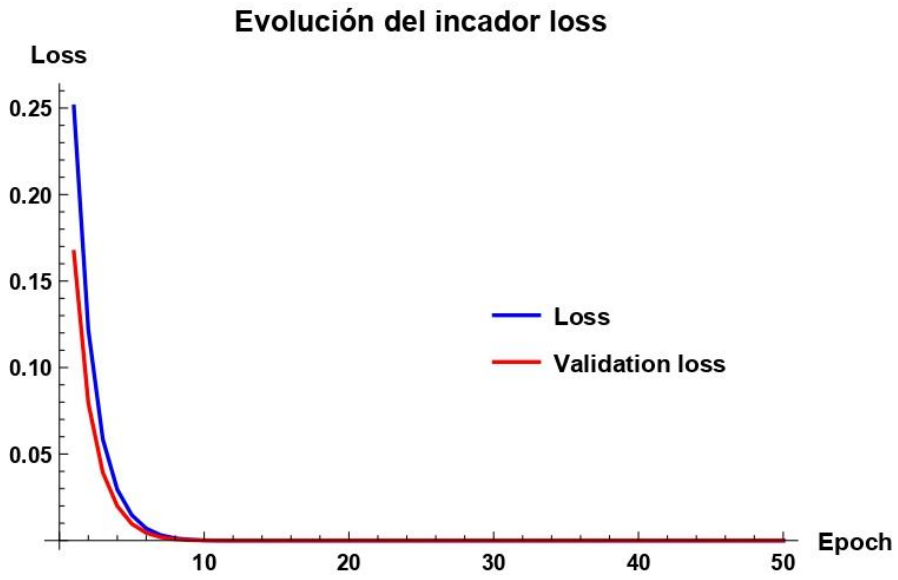

En la anterior gráfica se muestran los resultados generados a partir del 2020 a la fecha, donde las curvas de Loss se puede apreciar que tardan un poco más de épocas en coincidir las curvas de Loss y Validation Loss, pero si reacciona de manera positiva a la predicción, así mismo, se disminuyo en un 50% el número de epocas sin afectar los valores de la pérdida.

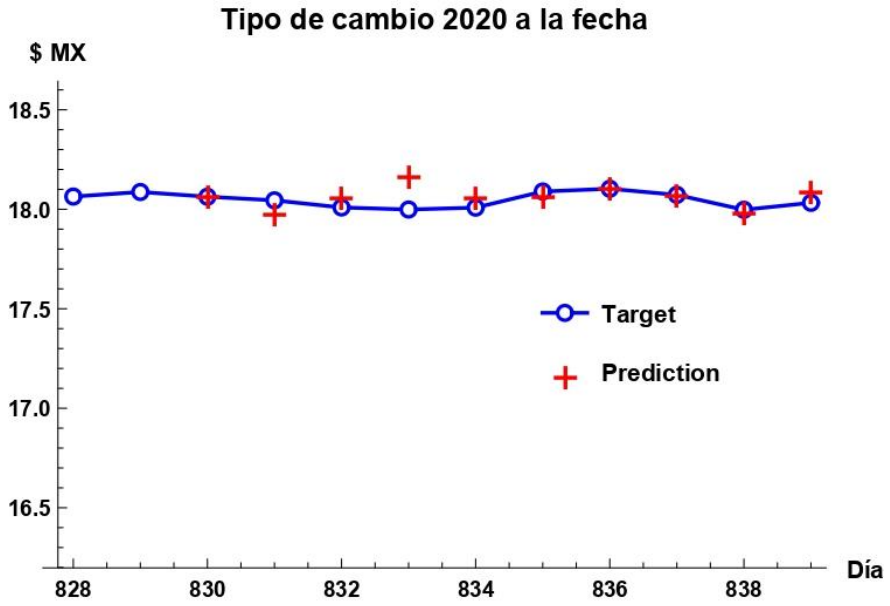

En este estudio se muestra que se tomó los datos desde el 2020 a la fecha, donde se sigue haciendo el análisis de la programación lo que nos continúa dando buenos resultados y cotejando los datos obtenidos, la mayoría de los resultados ya son casi iguales de los que se obtuvieron en el proceso, lo que nos demuestra que nuestra neurona funciona prediciendo en esta caso 10 datos.

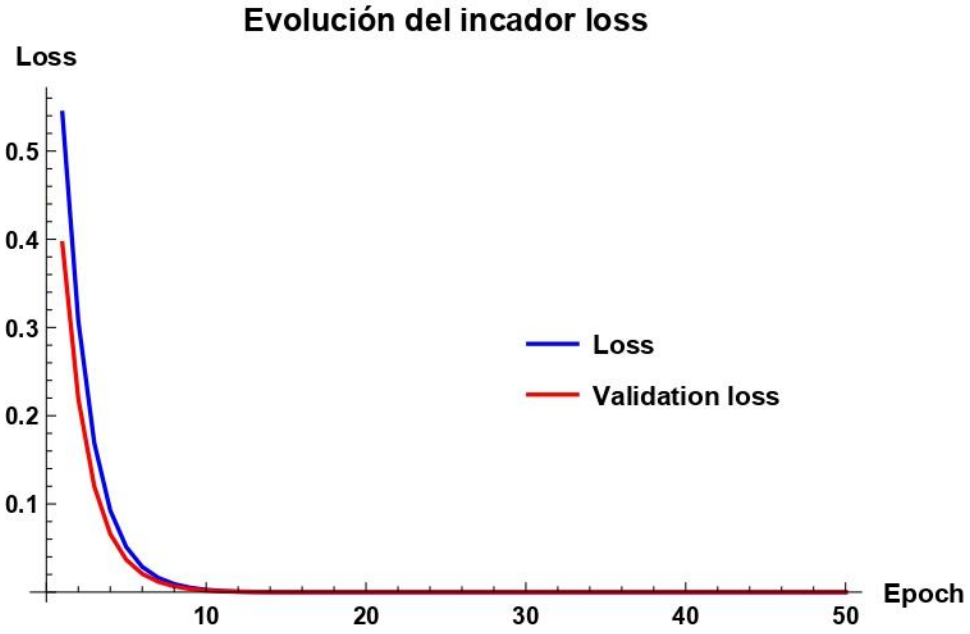

En la nueva gráfica muestra el desempeño de la red utilizando datos del 2021 a la fecha, se puede visualizar que es casi igual a la gráfica anterior del año 2020, pero se obtienen mejores resultados como se muestra en la gráfica que sigue a continuación.

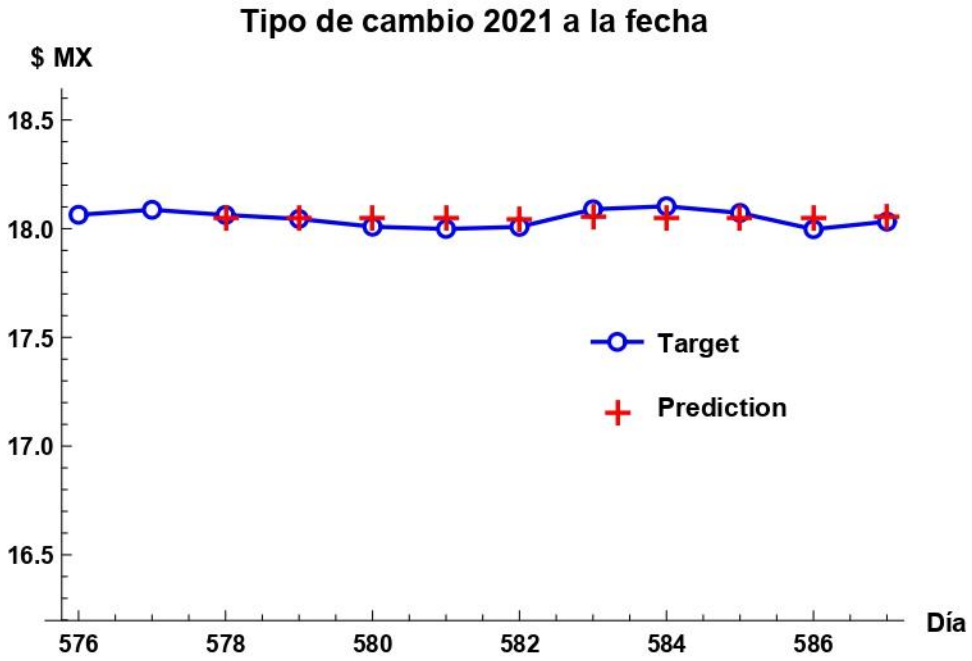

Se observa que tiene un excelente resultado ya que la predicción se vuelve cada vez más exacta, de esta manera se puede continuar la programación como se ha realizado hasta ahora.

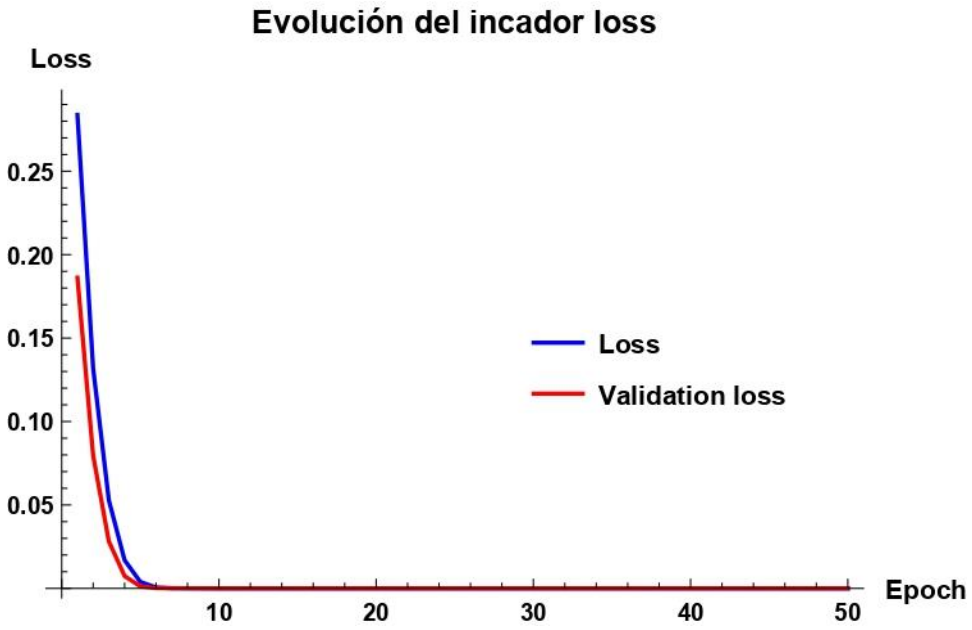

Se demuestra que al principio tienda a varias irregulares en la línea de Validacion loss, haciendo que el resultado de Loss, reprograme y aprenda por si misma para obtener los resultados deseados a lo largo del proceso.

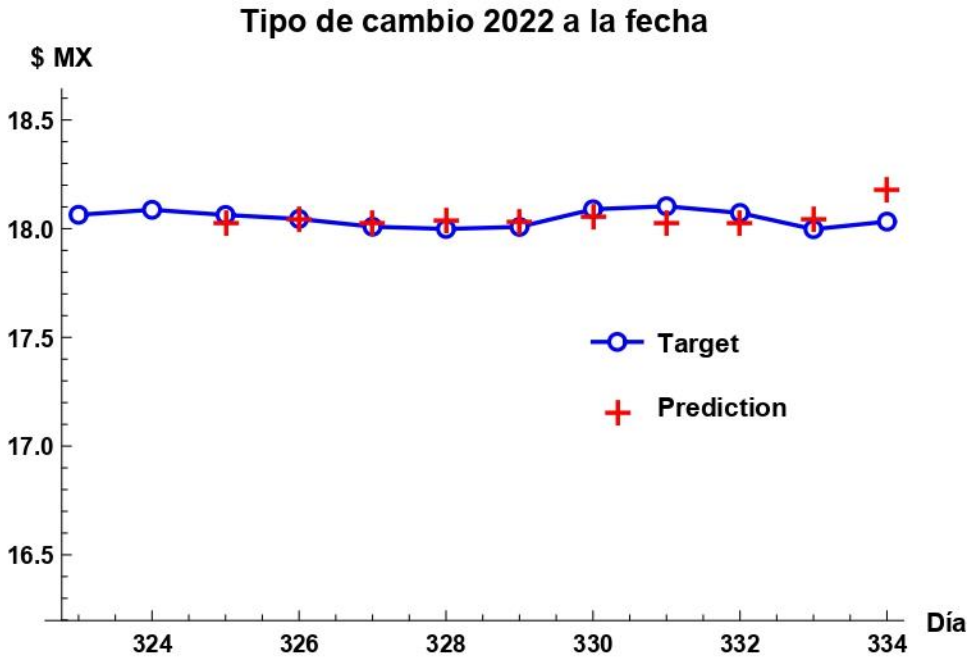

Se muestra en la tabla que con el aprendizaje de la neurona se sigue haciendo la predicción de manera exitosa, aunque no es el resultado exacto su variación es mínima lo que continúa haciendo que nuestro proceso nos muestre que la red neuronal aprende por si sola y nos demuestra los datos cotejando que continua sobre la misma predicción.

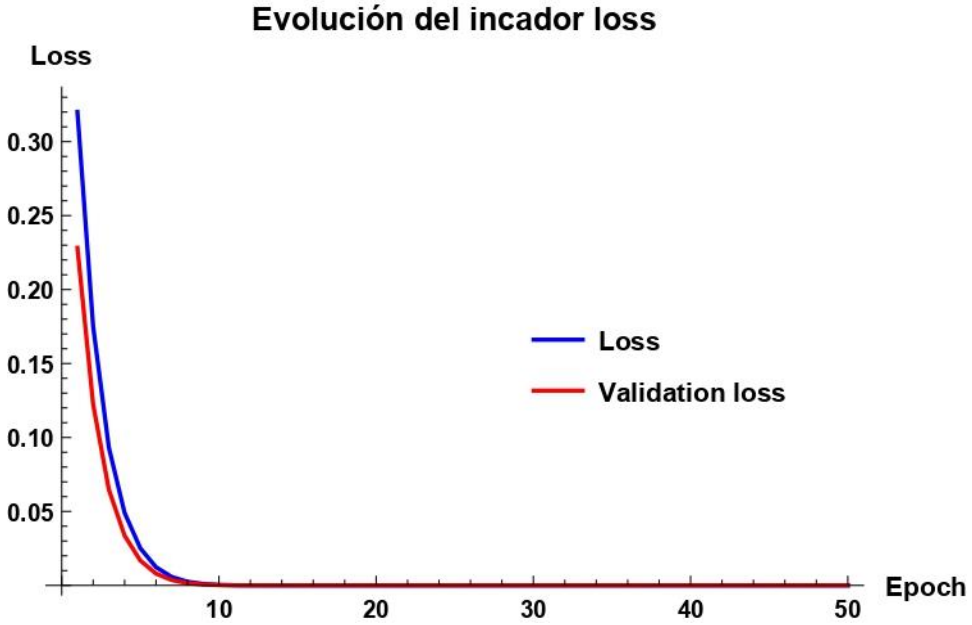

En la evolución del indicador loss, son los datos del año 2010 hasta abril del 2023, sigue mostrando que su procesamiento es correcto y si necesita un ajuste es de manera mínima.

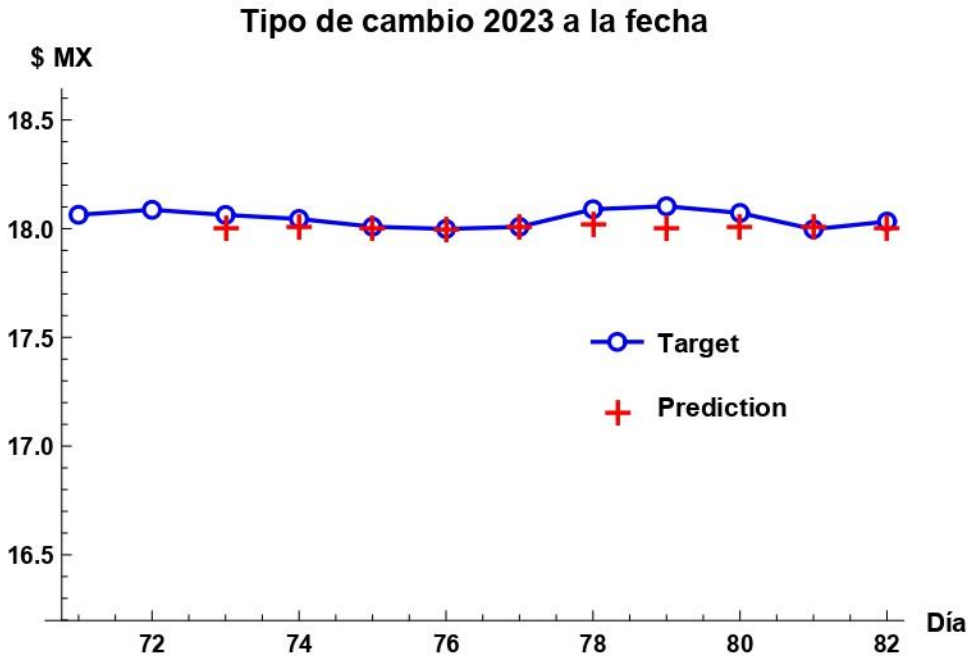

En la gráfica de tipo de cambio hasta el año 2023, muestra las mejoras que se han realizado, y los resultados positivos que obtenemos en las predicciones.

Tabla de Resultados de calibración de la RNA

Modelo de RNN	Series	Epocas	Porcentaje máximo de ruido	Neuronas primera capa	Neuronas segunda capa	Loss	Predicción	Desviación Estándar	Tiempo Total [s]	Datos sin normalizar	Función de activación
ST_RNRe2cVr_v2.py											
1982-2023	1000	20	5.00E-02	20	20	0.2308	18.01246	0.1654	4320		relu,relu
	5000	20	5.00E-02	20	20	9.95E-04	18.00731	0.4278	22480		relu,relu
ST_RNRe2cVr_v2.py											
1982-2023	5000	20	1.00E-02	20	20	0.0097	18.033445	0.0395	25200		relu,relu
	10000	20	1.00E-02	20	20	0.0067	18.070196	0.0437	32560		relu,relu
ST_RNRe2cVr_v2_2023_10pred.py	10000	20	5.00E-02	50	50	5.91E-07	17.998716	1.32E-04			relu,relu
ST_RNRe2cVr_v2_2023.py											
2023	1000	20	5.00E-02	20	20	0.1315	18.016777	0.1782	20		relu,relu
	7500	20	5.00E-02	20	20	0.0212	18.040203	0.2824	100		relu,relu
ST_RNRe2cVr_v2_2023.py											
	500	20	1.00E-02	20	20	0.0087	18.035137	0.0354	0		relu,relu
	5000	20	1.00E-02	20	20	0.0014	18.031847	0.0611	60		relu,relu
	7500	20	1.00E-02	20	20	0.0094	18.013973	0.0305	100		relu,relu

	10000	20	1.00E-02	20	20	0.0037	18.001854	0.0393	140		relu,relu
ST_RNRe2cVr_v2_2022.py											
2022-2023	250	20	5.00E-02	20	20	0.0483	18.039818	0.3576	20		relu,relu
	1000	20	5.00E-02	20	20	0.0702	18.011656	0.2622	40		relu,relu
ST_RNRe2cVr_v2_2022.py											
2022-2023	5000	20	1.00E-02	20	20	0.0103	18.038897	0.0458	180		relu,relu
ST_RNRe2cVr_v2_2021.py											
2021-2023	10000	20	5.00E-02	20	20	0.0008	18.020163	0.4288	720		relu,relu
ST_RNRe2cVr_v2_2021.py											
2021-2023	2500	20	1.00E-02	20	20	0.0078	18.011726	0.0396	180		relu,relu
ST_RNRe2cVr_v2_2020.py											
2020-2023	500	20	5.00E-02	20	20	0.1332	18.020483	0.2987	120		relu,relu
ST_RNRe2cVr_v2_2019.py											
2019-2023	10000	20	1.00E-02	20	20	0.0041	18.019163	0.0461	2200		relu,relu
ST_RNRe2cVr_v2_2018.py											
2018-2023	250	20	5.00E-02	20	20	0.1422	18.025340	0.2409	1260		relu,relu
ST_RNRe2cVr_v2_2018.py											

2018-2023	10000	20	1.00E-02	20	20	0.0064	18.039812	0.0325	3200		relu,relu
	100	50	1.00E-02	100	100	0.0132	18.067333	0.0168	50		
ST_RNRe2cVr_v2_2013.py											
2013-2023	5000	20	5.00E-02	20	20	0.0214	18.0401	0.3040	0		relu,relu
ST_RNRe2cVr_v2_2013.py											
2013-2023	250	20	1.00E-02	20	20	0.0105	18.013725	0.0502	1260		relu,relu
	2500	20	1.00E-02	20	20	0.0137	18.018108	0.0520	1280		relu,relu

En la anterior tabla se visualizan los resultados con la mejor predicción en cada uno de los ciclos de programación, se utilizaron periodos de diferentes años, 20 épocas, 2 capas ocultas, continiendo por capa 20 neuronas, obteniendo en cada calibración la pérdida, desviación estándar, así mismo el tiempo estimado de cada calibración, esto permitió obtener la mejor predicción con el valor mínimo de pérdida.

3.4 Comparación con los métodos estándar.

Figura 4. Modelo ARIMA y Redes Neuronales Artificiales

Existen varios métodos para la creación de una inteligencia artificial, pero con diferentes características y procesamiento, se realizó una investigación con anterioridad para escoger la herramienta que mejor se adecuaba a nuestro trabajo de tesis, en el cual se mencionarán a continuación para mostrar mejor los argumentos para una conclusión más exacta:

Las herramientas más utilizadas para pronosticar una serie de tiempo son Redes Neuronales y Arima. Se busco obtener una predicción que nos permitiera un resultado con mayor precisión en base a los datos que se utilizaron para programar la red neuronal para analizar la serie de tiempo. Existen varios tipos de análisis de series temporales que se han utilizado con diferentes metodologías que se encuentran agrupadas en:

- Métodos estadísticos y econométricos
- Redes neuronales
- Modelos híbridos

3.4.1 Modelo ARIMA

Se conoce como un modelo móvil integrado autorregresivo en estadística y econometría con el cual resulte ideal para la generación de los modelos que se ajustan a series temporales, se pueden determinar manualmente los valores para componentes que pueden llevar mucho tiempo y una cantidad considerable de ejercicios de prueba y error. Pero se tiene que tomar en cuenta que no acepta la cantidad de datos que se necesitan para poder realizar la funcionalidad de dicho proyecto, lo que afectará en la pronosticación ARIMA.

Ventajas

- Son buenos para la predicción en el corto plazo, debido a su capacidad de aprender los cambios en la dinámica de la serie
- Sirve como punto de referencia
- Son baratos y rápidos de construir
- Se ajustan a una serie en particular
- Los conceptos se derivan de sólidas teorías de la probabilidad clásica y de la estadística matemática
- Produce óptimas predicciones (a corto plazo, un par de predicciones confiables)
- Considera efectivamente la correlación lineal entre observaciones
- Permite escoger los ordenadores de los modelos, por medio del estudio de los correlogramas simple, parcial y sus respectivas funciones (FAS) y (FAP).
- El desarrollo de este modelo es rápido presentando errores bajos
- No necesita un conjunto de datos históricos grande, pues solo toma un valor que indique su orden para realizar la predicción

Desventajas

- Son pobres para predecir en momentos de cambios estructurales y puntos de giro.
- Son de memoria corta.
- Menos eficiente en el uso de la información.
- Sigue siendo una labor manual, esto quiere decir que cualquier ajuste a los parámetros internos debe ser ejecutado por el analista.
- Requiere de una serie temporal estacionaria.
- La precisión requiere de la experiencia del pronosticador (lo cual, además lo vuelve hasta cierto punto un análisis subjetivo).
- No logra captar los cambios inesperados de los patrones del comportamiento de la serie debido a su linealidad.
- No existen una técnica establecida para encontrar los parámetros de cada modelo, por esto se hallan mediante el ensayo y error.
- La adecuación del modelo se hace con el tanteo de los parámetros de la ecuación de cada modelo hasta encontrar un error mínimo.
- Se debe realizar un modelo para cada paso de tiempo en el cual se quiera predecir un valor, convirtiendo la predicción en un tedioso y complicado trabajo.

Entre otros puntos que destacar sobre las desventajas del modelo ARIMA, su pronóstico es a corto plazo y también presente datos no exactos, ya que su rango de error es mucho más grande, en el libro de “Python for Data Analysis” escrito por Wes McKinney que nos habla sobre la utilización y el análisis en Python y nos habla de diferentes series temporales, comprando la utilidad de ellas y cual es la más adecuada a la programación para obtener los resultados requeridos, por ello se tiene que destacar que no todos los modelos que fueron propuestos pueden llegar a proporcionar un ajuste adecuado, esto es debido a que los datos mínimos que se requieren son 30 pero los datos máximos son 100, por lo tanto, no es viable para aplicar este modelo en una programación sobre economía, puesto que se requieren la mayor cantidad de datos disponibles posible (esto es una limitante del método en sí mismo, ni siquiera de infraestructura de cómputo) por lo tanto no es razonable su implementación para llevar a cabo un paralelo a nuestra investigación, sobre todo por los alcances que se pretendían y obtuvieron.

3.4.2 REDES NEURONALES ARTIFICIALES (RNA)

Es un tipo de proceso conocido como Machine Learning, llamado también como aprendizaje profundo, en el cual como se menciona anteriormente se utilizan nodos (neuronas interconectadas), que se encuentran interconectados en una estructura de capas que tiende a funcionar como el cerebro humano. Las Redes Neuronales Artificiales es una herramienta que hoy en día es utiliada por muchos tecologías como son, Facebook, Envidia y Microsoft, entre otras. También se desarrolla el modelo de las redes neuronales al utilizar el celular al conectarse con el internet ya que esto se debe a la utilidad de la nube de donde se conectan.

Con base a este método la RNA aprende por si sola mediante sus errores y así mejorar continuamente de manera autónoma, obteniendo una mayor precisión en el resultado.

Ventajas

- Tiene la habilidad de aprender mediante una etapa que se llama etapa de aprendizaje. Esto quiere decir que los datos ingresados de entrada a su vez indica cual es la salida (respuesta) esperada.
- Auto organización. Crea su propia representación de la información en su interior, descargando al usuario de esto.
- Puede manejar cambios no importantes en la información de entrada, como señales con ruido u otros cambios en la entrada.
- La estructura es paralela, por lo cual, si esto no es implementado con computadoras o en dispositivos electrónicos especiales, se pueden obtener respuestas en tiempo real.
- Son modelos de vanguardia que capturan de una forma óptima y efectiva características complejas, obteniendo resultados con una alta precisión
- Los pesos son ajustados basándose en la experiencia, lo que significa que se le tiene que enseñar a la red lo que necesita saber antes de ponerla en funcionamiento.
- Las neuronas pueden reconocer patrones que no han sido aprendidos, solo deben tener cierto parecido con el conocimiento previo que tenía la red. (Hilera 1995, Freeman 1993)

Aunado a lo anterior, es capaz de comprender datos no estructurados y poder realizar observaciones generales sin un entrenamiento explícito, esto se logra por su estructura que se basa en el sistema nervioso. Es una técnica que se otorga a las computadoras el acceso al conjunto de datos muy grandes por lo cual se les enseña aprender de dichos datos, en los cuales encuentran patrones y los aplica de esta manera se podrá hacer la toma de decisiones más exacta con mínimo de riesgo en el área que se utilicen las redes neuronales.

Por lo antes expuesto se optó por esta tecnología que nos proporciona un mejor pronostico con un mínimo de error en el resultado, también se toma en cuenta que para lograr un mejor resultado se introdujo una base mucho mayor a la que nos permite ARIMA, cabe destacar que los resultados que nos proporciona se realizarán en meses hasta años. Se tiene que tomar en cuenta que las estructuras de nuestros datos irán aumentando de manera considerablemente en base a ciertos parámetros que se haya programado para realizar el modelo de las redes neuronales, de igual manera la cantidad de observaciones de cada una de las muestras que se lleguen a realizar, de tal forma que se tiene que tomar en cuenta la cantidad de datos que se están utilizando durante los ciclos del procesamiento.

Estos son los puntos más destacados del porqué escogimos las redes neuronales sobre otros modelos de predicción, cabe señalar que con ningún otro sistema se obtendrían los resultados que se obtienen mediante las Redes Neuronales Artificiales.

Capítulo 4.- Conclusiones

En este trabajo de tesis se han utilizado las redes neuronales artificiales, especificamente RNN para la predicción de series de tiempo del precio del peso frente al dólar, se ha evaluado la capacidad que tienen las RNN en la predicción de series de tiempo, resultando efectiva en esta tarea y demostrando que es una herramienta útil en la predicción de series de tiempo.

Uno de los inconvenientes es la utilización de redes neuronales es la elección de cada elemento de la arquitectura de red, obteniéndose en muchos casos por ensayo y error dentro de un conjunto de posibles valores.

La investigación que se desarrollo permite realizar predicciones de infinidad de fenómenos de diversas áreas, lo cual conlleva a una amplia gama de temas a estudiar; ya que a través de algoritmos avanzados y machine learning se pueden analizar gran cantidad de datos de manera rápida y precisa, pudiendo identificar patrones y predecir tendencias.

En cuanto a la capacidad de procesamiento y análisis de datos no existio restricción alguna, ya que se cuentaba con el hardware y software necesario para la ejecución de dicha tarea; quizas la única limitante a considerar es el acceso a los datos confidenciales o no abiertos de ciertos activos o fondos; sin embargo, existen fuentes de datos abiertas y confiables, en específicio para nuestro caso la del Instituto Nacional de Estadística y Geografía y Banco de México.

La IA es una herramienta de cómputo muy poderosa, misma que puede ser implementada en un amplio espectro como la reducción de riesgos, la minimización de tiempos, mejorar la calidad de trabajo, aumentar ganancias, implementar mejoras continuas, etc. ; sin embargo es de relevancia evaluar que procesos se puede beneficiar de esta tecnología y cuáles no.

En base a los resultados que se obtuvieron, podemos afirmar que constituyen una propuesta viable para el análisis de series de tiempo, perfeccionando la modelización y los resultados de la misma, dando un margen mucho más amplio de confianza en las predicciones, toda vez que no siguen una tendencia sino que aprenden de la historia.

Para el área de Ingeniería Industrial la IA es vital y un aliado, si queremos tomar decisiones acertadas, informadas y precisas, con velocidad de respuesta, que sean estas lo más apegadas a la realidad y no basadas en vivencias u anécdotas con errores humanos con los cuales pedemos sesgar las decisiones: permitiendo la automatización

de decisiones, reduciendo el trabajo humano intensivo y las tareas tediosas, todo ello para potencializar la competitividad y el éxito de las organizaciones; sin embargo debe de usarse como una herramienta de apoyo supervisada por personal capacitado.

Se recomienda que si la IA es usada en las diversas organizaciones, se capacite al personal para garantizar que los empleados trabajen con esta potente herramienta y se adapten al cambio, así mismo se mantienen a la vanguardia sobre lo último en tecnología y tendencias para garantizar que la organización es competitva y tomar decisiomes de forma inteligente.

BIBLIOGRAFÍA

Aurelien Geron. *Hands-on Machine Learning with Scikit-Learn, Keras and TensorFlow : Concepts, Tools, and Techniques to Build Intelligent Systems*. Beijing, O'reilly, 2019.

Beu, Titus A. *Introduction to Numerical Programming : A Practical Guide for Scientists and Engineers Using Python and C/C++*. Boca Raton, Crc Press, Taylor & Francis Group, 2015.

Bosco, Joish, and Fateh Khan. *Stock Market Prediction and Efficiency Analysis Using Recurrent Neural Network*. GRIN Verlag, 18 Sept. 2018.

Bose, Nirmal K, and Ping Liang. *Neural Network Fundamentals with Graphs, Algorithms, and Applications*. McGraw-Hill Companies, 1996.

Botero Botero, Sergio, and Jovan Alfonso Cano Cano. "ANÁLISIS de SERIES de TIEMPO PARA LA PREDICCIÓN de LOS PRECIOS de LA ENERGÍA EN LA BOLSA de COLOMBIA." *Cuadernos de Economía*, vol. 27, no. 48, 1 June 2008, pp. 173–208, www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-47722008000100007.

Carlos, Profesores, et al. *Cátedra: Informática Aplicada a La Ingeniería de Procesos - Orientación I Redes Neuronales: Conceptos Básicos Y Aplicaciones. 0 Contenidos*

Contenidos..... *2*. Mar. 2001.

Ezequiel Uriel Jiménez, and PeiróAmado. *Introducción al Análisis de Series Temporales*. Madrid Thomson-Paraninfo, 2005.

Fausett, Laurene V. *Fundamentals of Neural Networks : Architectures, Algorithms, and Applications*. Upper Saddle River, Nj, Prentice Hall, 1994.

Francisco, Eduardo, and LópezAlfonso. *Una Aproximación Práctica a Las Redes Neuronales Artificiales*. Programa Editorial Universidad Del Valle, 2009.

G Peter Zhang. *Neural Networks in Business Forecasting*. Hershey, Pa., Idea Group, 2004.

Giardina, Daniel. *Proyecto Final de La Carrera Ingeniería Electrónica, Facultad de Ciencias Exactas, Ingeniería Y Agrimensura* . 1995, p. 56.

Hyndman, Rob J, and George Athanasopoulos. *Forecasting : Principles and Practice*. 2nd ed., Heathmont, Vic., Otexts, 2018.

javier. "La Función Sigmoide: Una Herramienta Clave En Redes Neuronales." *Jacar*, 24 Mar. 2023, jacar.es/la-funcion-sigmoide-una-herramienta-clave-en-redes-neuronales/. Accessed 12 Mar. 2024.

javier . "La Tangente Hiperbólica: Función de Activación Potente." *Jacar*, 24 Mar. 2023, jacar.es/la-tangente-hiperbolica-funcion-de-activacion-potente/. Accessed 12 Mar. 2024.

José Ramón Hilera González, and JoséVictor. *Redes Neuronales Artificiales : Fundamentos, Modelos Y Aplicaciones*. Madrid, Ra-Ma, 1995.

Kong, Qingkai, et al. *Python Programming and Numerical Methods*. Academic Press, 27 Nov. 2020.

Lasse Rouhiainen. *Inteligencia Artificial*. Alienta Editorial, 20 Nov. 2018.

Palacios Burgos, Francisco Jose . "Redes de Funcion de Base Radial (RBF)." *Www.ibiblio.org*, 2003,

www.ibiblio.org/pub/linux/docs/LuCaS/Presentaciones/200304curso-glisa/redes_neuronales/curso-glisa-redes_neuronales-html/x185.html. Accessed 12 Mar. 2024.

Parra, Francisco. *8 Series Temporales | Estadística Y Machine Learning Con R*. *Bookdown.org*, 25 Jan. 2019, bookdown.org/content/2274/series-temporales.html.

Raquel Flórez López, and José M Fernández Fernández. *Las Redes Neuronales Artificiales : Fundamentos Teóricos Y Aplicaciones Prácticas*. Oleiros, La Coruña Netbiblo, 2008.

---. *Las Redes Neuronales Artificiales : Fundamentos Teóricos Y Aplicaciones Prácticas*. Oleiros, La Coruña Netbiblo, 2008.

redacTor. "Conceptos Básicos Sobre Redes Neuronales." *ElConspirador.com*, 18 Oct. 2014, www.elconspirador.com/2014/10/18/conceptos-basicos-sobre-redes-neuronales/. Accessed 12 Mar. 2024.

Román Mínguez Salido, and del Carmen. *Modelos de Series Temporales Aplicados a Rendimientos Financieros*. La Plata, 1 Dec. 2010.

Santosh Kumar Das, et al. *Machine Learning Algorithms for Industrial Applications*. Springer Nature, 18 July 2020.

Thampi, Sabu M, et al. *Machine Learning and Metaheuristics Algorithms, and Applications : Second Symposium, SoMMA 2020, Chennai, India, October 14{U2013}17, 2020, Revised Selected Papers*. Singapore, Springer Singapore, 2021.

Witold Pedrycz, and Shyi-Ming Chen. *Deep Learning : Algorithms and Applications*. Cham, Springer International Publishing, 2020.