



Vigilada Mineducación

**Desarrollo de un Modelo de Predicción Usando Redes Neuronales Artificiales de  
los Precios de los Futuros del Dólar para la Industria Colombiana**

Por

**Alejandro Montoya Herrera**

Trabajo de grado presentado como requisito parcial para optar al título de Magíster  
en Administración Financiera

Asesora

María Patricia Durango, PhD.

UNIVERSIDAD EAFIT

Pereira, 2023

## Resumen

El presente estudio ofrece una exploración de los modelos de predicción de los precios del dólar-peso, calculados mediante el uso de redes neuronales artificiales e indicadores bursátiles, para que constituya una herramienta para la toma de decisión de inversión. Se presenta un panorama general del uso de los indicadores bursátiles más usados en el mercado, como los osciladores y medias móviles, al igual que el análisis de mercados por la teoría de ciclos, donde finalmente se usan los indicadores de FLDS. Se realizan varios tipos de configuración de entrenamiento de las redes neuronales, explorando los posibles resultados de los modelos.

**Palabras claves:** *Red neuronal artificial (RNA), USD/COP, Osciladores, RSI, MACD, FLDS, Modelo de predicción.*

## Abstract

The present study presents an exploration of the dollar peso price prediction models, calculated through the use of artificial neural networks and stock market indicators, to constitute a tool for investment decision making. A general overview of the use of the most used stock market indicators in the market such as oscillators and moving averages is presented, as well as market analysis based on cycle theory, where finally the FLDS indicators are used. Various types of neural network training configuration are performed exploring the possible results of the models.

**Key words:** *Artificial neural network, USD/COP, Oscillators, RSI, MACD, FLDS, Prediction models.*

## Contenido

1. Introducción .....	8
2. Marco Teórico.....	9
2.1 Teoría de Ciclos .....	9
2.1.1 Filosofía .....	9
2.1.2 Ciclos .....	12
2.1.3 Patrones chartistas y su relación con la teoría de ciclos.....	15
2.1.4 Canales envolventes .....	22
2.1.5 Como conservar el dinero ganado.....	29
2.2 Osciladores .....	37
2.2.1 MACD (Moving average convergence divergence).....	37
2.2.2 RSI (Índice de fuerza relativa).....	40
2.3 Mercados de futuros.....	44
2.4 Redes neuronales artificiales.....	47
3. Metodología .....	52
3.1 Datos.....	52
3.2 Indicadores.....	54
3.2.1 Exponential móvil simple (EMA) .....	55
3.2.2 MACD.....	56
3.2.3 RSI .....	58
3.2.4 FLD.....	59
3.3 Implementación de redes neuronales artificiales .....	61
4. Resultados.....	63
4.1 Red neuronal con precio cierre (Close) .....	63
4.2 Red neuronal con precio cierre (Close) + RSI.....	64
4.3 Red neuronal con precio cierre (Close) + MACD.....	66

4.4 Red neuronal con precio cierre (Close) + FLDS .....	67
4.5 Modelo final .....	68
5. Conclusiones .....	71
Referencias bibliográficas .....	72
Anexos .....	74

## Lista de figuras

Figura 1. Parámetros de influencia en el precio de los activos.....	10
Figura 2. Futuros de la Soya, inversión con ciclo mayor .....	11
Figura 3. Futuros de la Soya, inversión con ciclos de diversos marcos de tiempo .....	12
Figura 4. Representación de los ciclos en los precios de un activo.....	13
Figura 5. Proporción de los ciclos según su duración .....	15
Figura 6. Canal envolvente en tendencia alcista.....	16
Figura 7. Formación de patrón hombro cabeza hombro.....	17
Figura 8. Composición resultante de la sumatoria de componentes en un precio .....	17
Figura 9. Cambio en la fase del ciclo .....	18
Figura 10. Formación doble cabeza.....	18
Figura 11. Formaciones triangulares.....	19
Figura 12. Agotamiento de tendencia confirmada por formación triangular .....	20
Figura 13. Formación envolvente de los ciclos.....	23
Figura 14. Bandas de sobres porcentuales.....	24
Figura 15. Bandas de Bollinger .....	25
Figura 16. Línea de tendencia alcista .....	26
Figura 17. Línea de tendencia bajista .....	26
Figura 18. Zona de proyección del precio .....	27
Figura 19. Zona de proyección del precio .....	28
Figura 20. Proyección por no real time envelops .....	30
Figura 21. Toma de utilidades por no real time envelops .....	31
Figura 22. Representación de medias móviles.....	32
Figura 23. Proyección de amplitud de la onda .....	32
Figura 24. Gráficas matemática de los ciclos del precio.....	33
Figura 25. Formación de señal compuesta por componentes de ciclos .....	34

Figura 26. Representación de líneas FLD en precio de USD/COP .....	35
Figura 27. FLDS como indicador de resistencias y cambio de tendencia .....	35
Figura 28. FLDS como proyección de precio alcista.....	36
Figura 29. FLDS como proyección de precio bajista .....	37
Figura 30. MACD indicando tendencia bajista.....	38
Figura 31. MACD indicando tendencia alcista .....	39
Figura 32. MACD indicando agotamiento de tendencia alcista.....	40
Figura 33. MACD indicando agotamiento de tendencia bajista.....	40
Figura 34. RSI indicando agotamiento de tendencia bajista .....	42
Figura 35. RSI indicando agotamiento de tendencia alcista.....	42
Figura 36. RSI indicando falso agotamiento alcista (sin divergencia) .....	43
Figura 37. RSI indicando falso agotamiento bajista (sin divergencia) .....	44
Figura 38. Funcionamiento de mercados regulados .....	45
Figura 39. Tipos contratos USD/COP en BVC .....	45
Figura 40. Funcionamiento de garantía en mercado de futuros .....	46
Figura 41. Ejemplo mercado de futuros .....	47
Figura 42. Estructura de red neuronal artificial de 1 capa oculta con 5 neuronas.....	48
Figura 43. Funcionamiento algorítmico de la neurona.....	49
Figura 44. Gráfica función sigmoide.....	50
Figura 45. Gráfica función Tanh.....	50
Figura 46. Gráfica función Relu .....	51
Figura 47. Metodología de aprendizaje supervisado (backpropagation).....	52
Figura 48. Muestra de datos de estudio, USD/COP 2019-2023 .....	53
Figura 49. Lenguaje de programación Python.....	54
Figura 50. Datos resultantes del indicador EMA.....	55
Figura 51. Gráfica de precio vs EMAS.....	56
Figura 52. Datos resultantes del indicador MACD.....	57

Figura 53. Gráfica de precio y MACD .....	57
Figura 54. Datos resultantes del indicador RSI .....	58
Figura 55. Gráfica de precio vs RSI .....	59
Figura 56. Datos resultantes del indicador FLD.....	60
Figura 57. Gráfica de precio vs FLD.....	61
Figura 58. RNA entrenada por ventanas de tiempo .....	63
Figura 59. Predicción de RNA con precio cierre .....	64
Figura 60. Predicción de RNA con precio cierre + RSI .....	65
Figura 61. Predicción de RNA con precio cierre + MACD .....	66
Figura 62. Predicción de RNA con precio cierre + FLD .....	67
Figura 63. Predicción de RNA modelo final de USD/COP 2019-2023.....	69
Figura 64. Predicción de RNA modelo final de USD/COP oct – nov 2023.....	69
Figura 65. Comportamiento de pérdida (loss) en cada entrenamiento .....	70
Figura 66. Predicción de RNA modelo final vs precio real .....	70

### **Lista de tablas**

Tabla 1. Valores nominales de los ciclos .....	14
Tabla 2. Exploración de modelos con entrada precio de cierre .....	64
Tabla 3. Exploración de modelos con entrada precio de cierre + RSI .....	65
Tabla 4. Exploración de modelos con entrada precio de cierre + MACD .....	66
Tabla 5. Exploración de modelos con entrada precio de cierre + FLD.....	67
Tabla 6. Modelo con mejores resultados.....	68

## 1. Introducción

En la actualidad, el comercio internacional se ha venido desarrollando a gran velocidad, gracias a la conectividad y al desarrollo de la tecnología, permitiendo que países como Colombia puedan acceder a los mercados globales, tanto para comercializar productos y/o servicios como para acceder a los mercados financieros. Al permitirse un fácil acceso a la información, muchos actores se han estado involucrando con el riesgo de la tasa cambiaria, pues cada día más personas y empresas tienen operaciones internacionales, pero no se cuenta con herramientas de fácil acceso ni comprensión para disminuir dicho riesgo.

Hay casos donde se cuenta con el conocimiento, como las empresas que toman coberturas para respaldar las operaciones que se hacen en otro tipo de monedas, operaciones necesarias para el desarrollo de su actividad, o para asegurar los precios de venta de sus productos o compra de insumos. Dichas coberturas las hacen con base a la experiencia de Instituciones y/o Traders, influyendo en sus decisiones factores arbitrarios como la psicología, técnicas y metodologías de cada ente, brindando precios no estandarizados. Por ende, al desarrollar un modelo de predicción por medio de redes neuronales, se brindarán resultados objetivos en la toma de decisiones de los interesados.

Así, con el desarrollo de este modelo, se busca tener una base de predicción para el futuro del dólar-peso, activo de principal interés para el país, convirtiéndose en una herramienta para el uso de coberturas, fines especulativos o para fines de comercio internacional (exportación o importación).

## 2. Marco Teórico

### 2.1 Teoría de Ciclos

#### 2.1.1 Filosofía

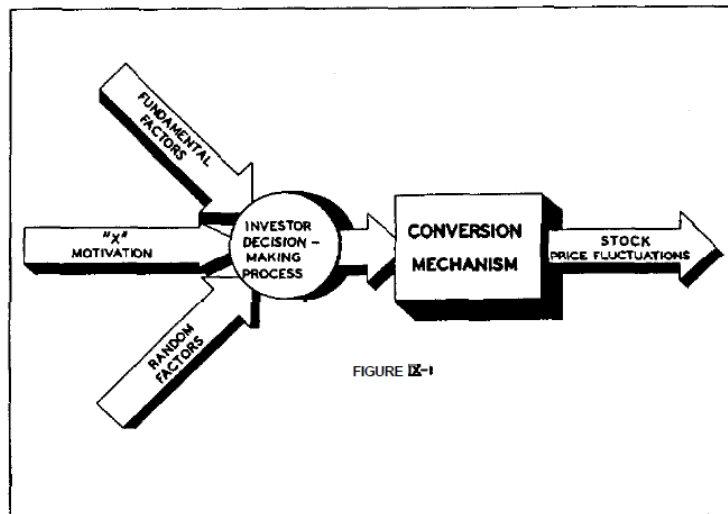
El físico e ingeniero aeroespacial J. M. Hurst, junto con un pequeño grupo de ricos inversores y una computadora potente para la época, investigaron alrededor del año 1970 el comportamiento del mercado y su similitud con el fenómeno físico de las ondas. Teorías que fueron plasmadas en su obra *The profit magic of stock transation timing*. En dicha época su publicación no tuvo gran renombre, debido a que el mercado sufría una tendencia bajista, y la mayoría de los inversionistas no tenían gran interés por la obra, ni por la inversión en los mercados.

Todavía no se cuenta con mucho reconocimiento de sus técnicas de negociación dentro del ámbito de la comunidad de inversionistas, debido a que se requiere amplios conocimientos matemáticos, físicos y de mercados, para poder ser comprendida. En una primera inmersión en sus técnicas puede parecer que son análisis arbitrarios y subjetivos, pero al profundizar en los análisis y dedicar buen tiempo al comportamiento de todos los marcos de tiempo, se llega a predecir los movimientos del mercado con cierto % de precisión. Cabe mencionar que hay ciertos eventos que generan volatilidad y no tienen relación con la teoría de ciclos, como son:

- Factores fundamentales: como los resultados financieros de una compañía, las noticias sobre un sector específico, hechos políticos, guerras, noticias, etc.
- Factores aleatorios: como la psicología de los inversores.
- La motivación "X": llamada así por el autor al referirse a los movimientos cíclicos del mercado, explicado en su teoría.

Figura 1

*Parámetros de influencia en el precio de los activos*



Fuente: Hurst, 1975.

Al comprender que la teoría de ciclos no funciona en un 100% de los tiempos, se justifica una filosofía de trabajo con esta técnica:

1. Trade, no invertir: se debe cambiar la filosofía de invertir en activos que se seleccionan debido a sus dividendos, a los buenos resultados financieros que han tenido, a la solidez de la compañía, al futuro del mercado en el que se encuentran, entre otros factores fundamentales. Se debe simplificar simplemente al hecho de aprovechar los movimientos del precio a los que se pueda sacar valor, sin ni siquiera importar su nombre.
2. Maximizar el porcentaje anual de rendimiento en cada trade: no solo se busca tener rendimientos con los trades, sino también que estos se produzcan en menores tiempos. No es lo mismo ganar 100 en 10 años que en 1 año.
3. Buscar que el capital esté invertido en lo posible en un 100% del tiempo: debe de buscarse la mayor cantidad de posibilidades de inversión para el capital, aprovechando tanto las subidas como bajadas de los precios, estando

presente con la inversión en la mayor parte de los movimientos de los ciclos. Se optimiza de esta manera el rendimiento anual por trade.

En la Figura 2 se presenta la posibilidad de inversión, aprovechando un ciclo mayor de tiempo, donde se compra en A, el 10 de noviembre y se vende en B el día 10 de junio, teniéndose un rendimiento de 51%.

**Figura 2**



Fuente: Investing, 2022.

Al comparar con la Figura 3, donde se optimizan las entradas y salidas del mercado, analizando ciclos de menor tamaño al tratado en el caso anterior, se dan así las entradas al mercado en los puntos A, C, y E y, aprovechando los cortos en los puntos B, D y F, da como resultado un rendimiento de 114% para el mismo periodo de tiempo del ejercicio anterior. Cabe mencionar que este es un caso hipotético, debido a que estar el 100% del tiempo del mercado puede no ser viable.

Figura 3

*Futuros de la Soya, inversión con ciclos de diversos marcos de tiempo*



Fuente: Investing, 2022.

#### ESTRATEGIA 1

TIPO	BUY
ENTRADA	\$ 1.180
SALIDA	\$ 1.776
GANANCIA	\$ 596
<b>RENTABILIDAD</b>	<b>51%</b>

#### ESTRATEGIA 2

TIPO	BUY	SELL	BUY	SELL	BUY	SELL	BUY
ENTRADA	\$ 1.180	\$ 1.284	\$ 1.218	\$ 1.725	\$ 1.582	\$ 1.753	\$ 1.585
SALIDA	\$ 1.284	\$ 1.218	\$ 1.725	\$ 1.582	\$ 1.753	\$ 1.585	\$ 1.776
GANANCIA	\$ 104	\$ 66	\$ 507	\$ 143	\$ 171	\$ 168	\$ 191

GANANCIA TOTAL \$ 1.350  
**RENTABILIDAD 114%**

### 2.1.2 Ciclos

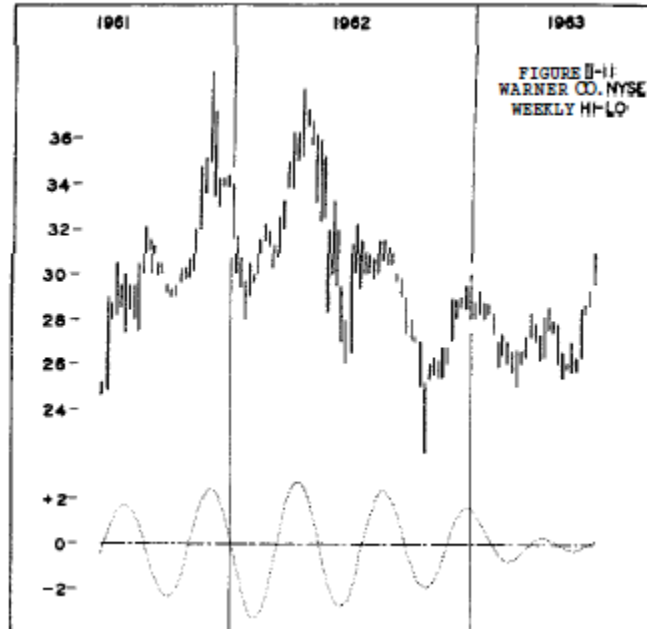
El comportamiento del precio de los activos se ve impactado por varios factores en conjunto, como son los factores fundamentales: guerras, decisiones políticas, resultados de empresas, gremios, clima, etc.; y por razones aleatorias, como las

emociones, necesidades, o ideas subjetivas de los inversionistas. Aunque la mayoría de los inversionistas siente que esta clase de causas tiene gran efecto en el comportamiento del precio, se han tenido varias referencias en la historia donde simplemente se tiene un efecto de volatilidad de poca duración y, posteriormente, se reestablece el comportamiento que el activo ya traía.

Hay una tercera causa para el comportamiento de los precios de los activos, llamada Motivación "X", que se basa en que al menos el 23% de todos los movimientos de los activos tienen forma oscilatoria (cíclica) y son semi predecibles. Al ser de esta naturaleza, comparte características similares con el manejo de las ondas, donde prevalece el dominio de buenas bases matemáticas y conceptos físicos, pero no es tan sencilla su implementación para el público general.

**Figura 4**

*Representación de los ciclos en los precios de un activo*



Fuente: Hurst, 1975.

Se podrían agrupar entonces sus características en 4 principios:

1. Principio de similitud: donde se detalla que todos los activos cuentan con que sus ciclos compartan similares atributos en su ciclicidad, duración de sus componentes y sus picos y valles tienen cierta sincronía, y las magnitudes relativas son similares.
2. Principio de variación: al tenerse un 75% de participación de las causas de factores fundamentales en el comportamiento de los activos, se tienen variaciones de magnitud y duración entre activos, la sincronía no es perfecta y tiene variaciones entre activos y entre épocas del mismo activo, al igual que en todos los activos no se ve la influencia de los componentes de los mismos marcos de tiempo.
3. Principio de nominalidad: después de la experiencia, el autor logra obtener las siguientes duraciones de ciclos, observadas como aproximación a ser comunes en todos los activos:

**Tabla 1**

*Valores nominales de los ciclos*

**Table II-1**

<i>Years</i>	<i>Months</i>	<i>Weeks</i>
18		
9		
4.5		
3.0		
1.5	18	
1.0	12	
.75	9	
* .50	6	26
* .25	3	13
	1.5	6.5
	.75	3.25
	.375	1.625


\*The 26 and 13-week components often appear in data as a combined effect of 18-week nominal duration.

Fuente: Hurst, 1975.

4. Principio de Proporcionalidad: mientras mayor duración en tiempo tenga un componente, mayor magnitud tendrá. Por ende, los ciclos mayores como el de duración de 18 años, tendrá una mayor magnitud en comparación con los ciclos menores como el de 13 semanas.

**Figura 5**

*Proporción de los ciclos según su duración*



Fuente: Hurst, 1975.

### **2.1.3 Patrones chartistas y su relación con la teoría de ciclos**

La teoría de ciclos de los precios de los activos está directamente relacionada con la formación de algunos patrones chartistas, patrones que son formas predeterminadas, que han servido para predecir el comportamiento, pero su uso exclusivo no es muy confiable, por lo cual son usados por lo general acompañados de otras estrategias. Al entender la relación que se tiene con la teoría de ciclos de los precios, permite generar más confianza en su efectividad y lograr usarlos de manera conjunta, para predecir el comportamiento de los precios.

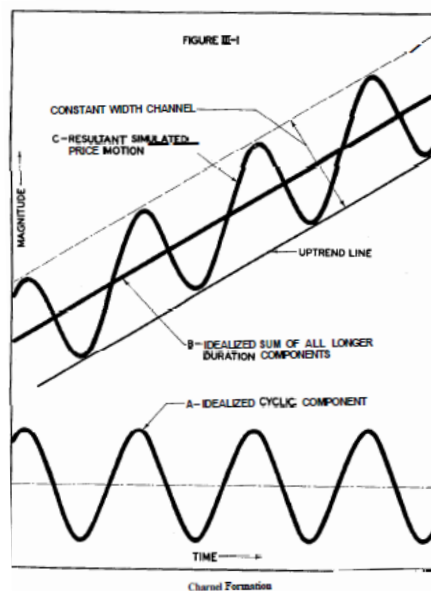
**Líneas de tendencia y canales:** se forman de acotar los límites del componente resultante de precio que, en este caso, para generar una idea fácil de comprensión,

se muestra la resultante de la suma de dos componentes, A y B, siendo la suma la resultante C. Al ver que sus valles, al desarrollarse el tiempo son superiores, se confirma una tendencia alcista y, en caso de que sus picos al desarrollarse el tiempo fuera de menor valor, se confirmaría la tendencia bajista. Estas líneas de tendencias al ser proyectadas y llegarse el caso de romper con el precio, se confirmaría el fin de tendencia.

El ancho de canal se mide entre las líneas que unen los picos y los valles, siendo esta medida de gran utilidad para predecir la magnitud posible del próximo precio.

**Figura 6**

*Canal envolvente en tendencia alcista*



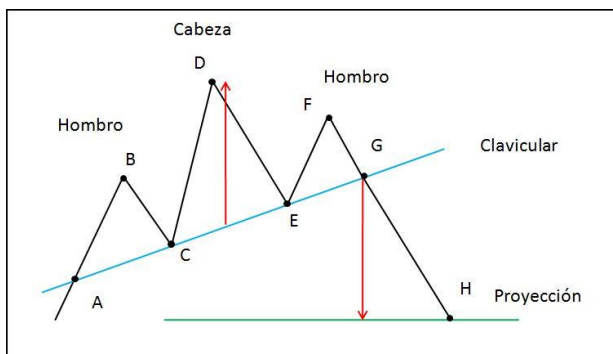
Fuente: Hurst, 1975.

**Formación de hombro – cabeza – hombro:** es uno de los patrones más usados por el chartismo clásico, explicando su origen desde la teoría de ciclos, simplemente como el resultante de 3 componentes: uno con un marco de tiempo mayor, en su parte alcista, un segundo que presenta un ciclo completo y, por último, un componente de menor marco de tiempo, que presenta la formación de varios ciclos. Una de las señales típicas de su uso, es el presentado en la Figura 7, hombro

cabeza hombro, trazándose una línea llamada línea clavicular, comparada con la clavícula del cuerpo. Al ser esta penetrada por el precio, se predice tendencia bajista.

**Figura 7**

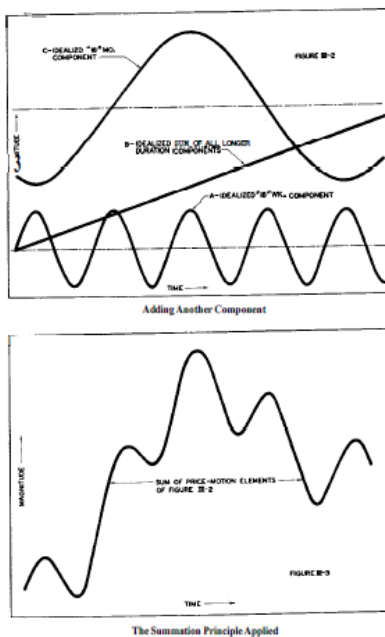
*Formación de patrón hombro cabeza hombro*



Fuente: Hurst, 1975.

**Figura 8**

*Composición resultante de la sumatoria de componentes en un precio*




Fuente: Hurst, 1975.

**Formación doble cabeza o doble piso:** se forma de manera similar al anterior, solo que en esta se tiene un desfase o movimiento en el tiempo de sus componentes, es decir, se produce de manera previa o posterior al anterior caso, formándose así no tres picos o valles, sino solo 2 formaciones.

**Figura 9**

*Cambio en la fase del ciclo*




The Effect Of Cycle Timing Change

Fuente: Hurst, 1975.

**Figura 10**

*Formación doble cabeza*



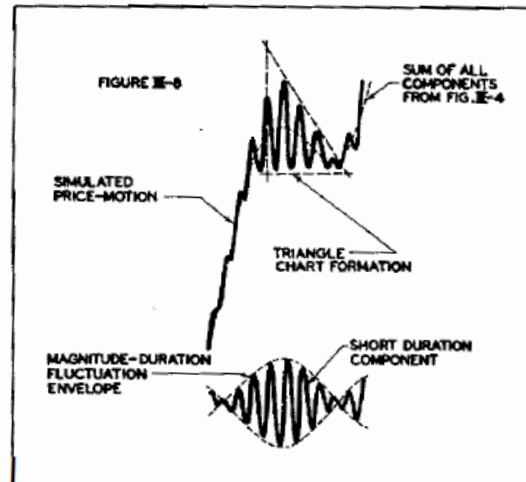
Fuente: Hurst, 1975.

**Formación de triángulos:** al agregarse un componente de menor duración y amplificar el hombro izquierdo de la Figura 10, se puede observar la formación de

un triángulo, generándose su uso para predecir la continuación de la tendencia de mayor duración, al romper el precio la forma triangular, no de manera estricta, como el mostrado en la Figura 11, sino de varias formas triangulares.

**Figura 11**

*Formaciones triangulares*




How Triangles Come About

Fuente: Hurst, 1975.

El uso exclusivo de este tipo de patrón, sin ningún complemento, no es suficiente para una adecuada predicción, puesto que se tiene como regla que la tendencia que se tenía antes del triángulo continuara después de él, pero se presenta situaciones donde esta no se cumple a cabalidad. Este tipo de error puede predecirse al usarse la teoría de ciclos como base de estudio, y así su uso brindaría un gran potencial al combinarse con el chartismo puro.

Figura 12

*Agotamiento de tendencia confirmada por formación triangular*



Fuente: Hurst, 1975.

**Medias Móviles:** son líneas presentadas en conjunto con la gráfica de precios, que ayudan al entendimiento del comportamiento del precio. Pueden ser de varios tipos, esto dependiendo del tamaño adecuado para el marco de tiempo presentado en la gráfica de precios y de la naturaleza del activo como tal. Su cálculo se toma por lo general de los precios de cierre, donde se promedian el tamaño a analizar de los últimos precios y se desfasa hacia la izquierda en la mitad del tamaño de la muestra. Permite minimizar el efecto de los componentes de menor marcos de tiempo, e inclusive el ruido del mercado y resaltar las posibles tendencias, funcionando como un filtro, dándole limpieza al comportamiento en el marco de tiempo deseado a estudiar.

A través de la historia se han desarrollado varios tipos de medias móviles, no siendo mejores las más actuales, sino teniéndose un más amplio portafolio para formar la estrategia de trading.

Se han encontrado combinaciones de los tamaños de las medias móviles de uso general por los inversionistas, en las que se pueden encontrar:

- 5 y 20 días

- 10 y 50 días
- 4, 9 y 18 días
- 200

En el caso de usarse 3 medias móviles a la vez, el procedimiento para el análisis se basa en que se debe estar preparado para el momento en que la media móvil más pequeña atraviese a la mediana, y si la tendencia sigue su rumbo, la media móvil mediana atraviese la de mayor valor, dándose así la confirmación, eliminando los ruidos y falsas señales, que puede dar la media móvil más pequeña al ser más sensible a los cambios. El objetivo del uso es lograr la mejor combinación que no sea tan sensible a los cambios del mercado, pero tampoco tan insensible que genere reacciones tardías a los movimientos.

**Media móvil simple:** su cálculo es generado del promedio de los últimos datos de cierre del precio; entre sus desventajas está que les da el mismo peso a todos los datos promediados, sin importar su posición.

$$\text{Media Móvil Simple} = \frac{\text{Suma Precio Cierre de X sesiones}}{X}$$

**Media móvil exponencial:** se calcula agregándole un elemento que genera una línea que les da mayor peso a los valores más recientes, siendo estos más relevantes y brindándole una mayor sensibilidad ante los cambios abruptos.

$$\text{Multiplicador} = [2 \div (\text{cantidad de períodos seleccionados} + 1)]$$

$$\text{EMA actual} = [\text{Precio de cierre} - \text{EMA (día anterior)}] \times \text{multiplicador} + \text{EMA (día anterior)}$$

**Media móvil Arnaud legoux:** se calcula con unas bases estadísticas más sólidas, presentando gran ventaja al ser mucho más sensible al precio, disminuyendo el retardo que tienen las demás y pudiendo aprovechar los movimientos desde sus inicios.

The diagram shows a normal distribution curve with the following components labeled:

- 1/NORM**: The normalization constant.
- SIZE**: The upper limit of the summation index  $i$ .
- Window size**: The summation index  $i$ .
- Offset**: The mean of the distribution,  $i - \text{offset}$ .
- Sigma**: The standard deviation,  $\sigma$ .

$$\frac{1}{NORM} \sum_{i=1}^{SIZE} p(i)e^{-\frac{(i-\text{offset})^2}{\sigma^2}}$$

### 2.1.4 Canales envolventes

Para la maximización de beneficios con la teoría de ciclos, es esencial el Timming, que es entender en qué momento de desarrollo se encuentra el ciclo y así determinar si se debe comprar (Buy), vender (Sell), mantenerse en posición (Hold) o simplemente esperar fuera del mercado (Wait).

Lo primero es identificar los ciclos dominantes en el activo y el estado presente del mismo, esto no siempre será 100% acertado, pero nos brindará una alta probabilidad estadística de la predicción de los comportamientos del precio.

Para ejemplo, se toma el marco de tiempo semanal, donde se encontrará un ciclo que está en el rango nominal del modelo, entre 13 a 26 semanas, este será la base, posteriormente se podrá ir estrechando la banda dependiendo de los datos de cada activo. Luego se calcula la altura desde la media móvil que más se acerca al comportamiento cíclico y los máximos y mínimos, y estas medidas se promedian con el fin de crear un ancho definido al canal envolvente.


Posteriormente, se va estrechando el ancho y pueden quedar por fuera del canal algunos picos y valles, los cuales representarían los picos y valles del primer componente dominante. Al bajar el ancho gradualmente, se encontrará el segundo conjunto de picos y valles, generándose el segundo componente del modelo y, posteriormente al estrechar aún más el canal, producirá el tercer componente.

### 2.1.4.1 Predicción usando bandas envolventes

Inicialmente se grafica el precio en el marco de tiempo en velas japonesas y, dependiendo del tamaño de la muestra graficada, se mira el comportamiento de los mínimos y máximos de la muestra, relacionándolos con los valores de nominalidad que se tienen del modelo. Se plantea un primer canal envolvente donde se cubra los máximos y mínimos. Se plantea un canal superior al periodo del anterior, igualmente tratando de relacionarlo con la nominalidad. Para dar mayor precisión del momento en el cual tomar las decisiones, se analizan los ciclos más pequeños que conforman el primer canal. Se miden y promedian las distancias de los 3 componentes formados y se proyecta el comportamiento del activo en el futuro, pudiéndose así comprar, vender, esperar, o simplemente quedarse por fuera de mercado, mientras se presenta el mejor momento.

**Figura 13**

*Formación envolvente de los ciclos*



Rough Prediction Using Envelopes

Fuente: Hurst, 1975.

### 2.1.4.2 Bandas de Bollinger y sobres porcentuales

Dentro del modelo de las bandas envolventes, se han venido desarrollando varias metodologías y usos alternativos, como los sobres porcentuales para la media

móvil, que se basa en graficar la media móvil que mejor represente los movimientos del precio, y con ella como referencia, graficar una media móvil superior que estará calculada aumentándose un porcentaje definido, lo mismo para una media móvil inferior disminuida en el mismo valor. Así, se genera un canal que, al ser cruzado por el precio, dará señales de que se encuentra sobrecomprada en caso de que el precio toque el límite superior, o sobrevendida, en caso de que el precio toque el límite inferior. Hay grandes variaciones de este tipo de indicador, en los que encontramos el canal de Keltner, que usa la media móvil de 20 periodos y, para su límite superior usa  $\text{máximo} + \text{mínimo} + \text{cierre} / 3$  y para su límite inferior  $\text{máximo} - \text{mínimo} - \text{cierre} / 3$ , como se muestra en la siguiente gráfica:

**Figura 14**

*Bandas de sobres porcentuales*



Fuente: Investing, 2022.

Con la misma forma de diseño se grafican las Bandas de Bollinger, solo que en este caso se usa generalmente la media móvil de 20 días y el cálculo de los límites del canal no se calculan por porcentajes, sino por desviaciones típicas para ambos umbrales. Al usarse las desviaciones típicas, se tiene entonces que el precio estará dentro de la banda con seguridad en un 95%. Es por ello que se adiciona su uso para el cálculo de metas de precio, estando el precio en la banda inferior, y cruzando

por debajo de la media de 20 días, pasa a ser precio objetivo el límite superior de la banda. Similar pasa si el precio viene del límite superior de la banda y cruza la media de 20 días, teniéndose como objetivo el límite inferior en este caso para posición corta.

Las bandas de Bollinger, al ser construidas con las desviaciones típicas, presentan ensanchamiento de la banda cuando se tiene mayor volatilidad, y se estrechan cuando la volatilidad disminuye, o se está en tendencia definida.

**Figura 15**

*Bandas de Bollinger*



Fuente: Investing, 2022.

### 2.1.4.3 Valid trend line (VTL)

Son líneas que se forman cuando se tienen tendencias definidas, con el fin de precisar el momento en que dicha tendencia cambiará de rumbo. Para el caso de tendencias alcistas, se forma uniéndolo con una línea los mínimos presentados y, en caso de tendencia bajista, se forma uniéndolo con una línea los máximos. En el punto donde corte la VTL, se toma la decisión de compra o venta, según el momento.

Figura 16

*Línea de tendencia alcista*

Figura 17


*Línea de tendencia bajista***2.1.4.4 Edge band transition timing**

Se basa en usar los límites del canal envolvente, junto con las Valid Trend Lines, para determinar señales de compra o venta. En la siguiente imagen, se observa cómo el trabajo en conjunto de estas dos herramientas generó la señal, primero

determinándose la zona donde se proyectaría el precio tanto en valor como en tiempo, y posteriormente, confirmándose con el cruce del precio en las VTLs proyectadas. Cabe anotar que esta técnica no genera el mejor rendimiento anual, puesto que se puede perder tiempo con el dinero invertido hasta que se tiene el movimiento de precio.

**Figura 18**

*Zona de proyección del precio*



The Buy Signal—And Profits In The Pocket!

Fuente: Hurst, 1975.

#### **2.1.4.5 Mid band transition timing**

A diferencia de la Edge band, esta presenta la señal de compra no de manera tan inmediata, o sea, que no solo se basa en lo que sugieren los ciclos de menor duración, sino que también incluye los de mayor; en este caso particular, se tiene que los ciclos cortos y largos están entrando en un mínimo, por eso su salida de ese valle es demorada. En su implementación, se espera a que pase el precio de la señal proporcionada por el Edge band y el precio se detenga por causa de los ciclos de mayor duración. Posteriormente se usan las VTLs relacionadas con el ciclo en que se encuentra.


Con esto no se espera el mejor rendimiento por trade, pero sí un alto rendimiento por unidad de tiempo y ese es uno de los pilares de esta filosofía, ganar lo máximo en el menor tiempo posible.

Esta herramienta combinada con el seguimiento de los ciclos del activo, permite un correcto pronóstico:

1. Componentes de mayor duración a 19 semanas: alcista
2. Componente de 19 semanas: 3,5 semanas en tendencia alcista
3. Componente de 4 semanas: llegando a mínimo, preparándose para cambio de tendencia
4. Componente de 2 semanas: llegando a mínimo, preparándose para cambio de tendencia
5. Componente de 1 semanas: llegando a mínimo, preparándose para cambio de tendencia

**Figura 19**

*Zona de proyección del precio*



Fuente: Hurst, 1975.

Como resultado, la comparativa entre ambas técnicas, suponiendo que ambas venden en 13, sería:

- Edge band transation timming: 73,5% en 65 días, o sea, 418% anual.
- Mid band transation timming: 53% en 36 días, o sea, 539% anual.

### **2.1.5 Como conservar el dinero ganado**

Para evitar perder lo ganado mediante el uso adecuado de las técnicas antes mencionadas, en la operación debe asignarse siempre un nivel de pérdida determinado, el cual nos proporciona el límite máximo que estamos dispuestos a perder, en el caso de que se tenga un cambio en el comportamiento del precio, en comparación con el que predecimos. Generalmente es mal calculado como un valor arbitrario, según el nivel de riesgo que queramos correr en la operación, un valor que nuestro bróker nos indique, o simplemente un valor al azar, cercano a nuestra entrada en la operación. Cabe resaltar que es totalmente ineficiente y que depende totalmente de la psicología personal de cada trader.

Se proponen herramientas que tienen más lógica en la decisión de establecer los *stop loss* (parada de pérdidas), como es usar las VTLs, pero a diferencia de como se ha venido usando, se utiliza la VTL del límite inferior del canal formado, proyectando una línea horizontal, como precio *stop loss*.

Con el fin de administrar eficientemente la operación, el nivel de *stop loss* no puede quedarse estático, por ende, se convierte en *trailing losses levels* (TLL), en este caso tomando como niveles de referencia los mínimos que el precio muestre al tocarse las VTL inferiores. También es usado el *trailing stop loss*, donde se determina un % de pérdida desde el precio máximo ganado, por lo tanto, si el precio se devuelve, se logra una ganancia, aunque no sea la máxima lograda y evitar así la pérdida total. Pero la determinación de este porcentaje trae de nuevo la problemática de la arbitrariedad y la subjetividad.


#### **2.1.5.1 No Real time envelops (técnica adicional)**

Establecer un diagrama de ciclos de todos los componentes de interés en un gráfico real puede parecer no acertado, debido a la variabilidad y a la inhabilidad de graficar

separadamente cada componente, al igual que entender en qué momento de los ciclos mayores se encuentra, esto alterando la duración del precio. Es por esto que, como técnica adicional, se puede graficar la *Non real time envelopes*. Es una gráfica que simula los comportamientos cíclicos del precio, pero con periodos constantes. Así, usándolo como plantilla, da gran claridad sobre el movimiento que va a tener, mas no de cuánto va a durar el ciclo en comparación con el movimiento real del activo.

**Figura 20**


*Proyección por no real time envelopes*



Fuente: Hurst, 1975.

Figura 21

*Toma de utilidades por no real time envelopes*



Fuente: Hurst, 1975.


### 2.1.5.2 Medias móviles (estrategia)

En el proceso de implementar las medias móviles como herramienta de ayuda, lo primero sería identificar mediante el uso de *envelops* el valor nominal de la componente dominante en el marco de tiempo a estudiar. Posteriormente se dibuja la media móvil de la misma extensión de la duración nominal de la componente dominante, y también se dibuja la media móvil de mitad de extensión. Al ser graficadas junto con el precio, sirven de gran ayuda para proyectar las magnitudes de los máximos y mínimos.

Al encontrarse las medias móviles de valor nominal y su mitad, permiten proyectar la magnitud, tanto a la baja como al alza, con un 10 % de proximidad. Siendo así en la siguiente gráfica, al encontrarse alrededor de un precio de 41, se vio que llegó hasta 32, siendo así 9 puntos que, al cambiarse de tendencia, puede llegar a tomar precios de 48 a 52.

Figura 22

*Representación de medias móviles*



Fuente: Hurst, 1975.

Figura 23

*Proyección de amplitud de la onda*



Fuente: Investing, 2022.

### 2.1.5.3 FLDS (Future line of demarcation)

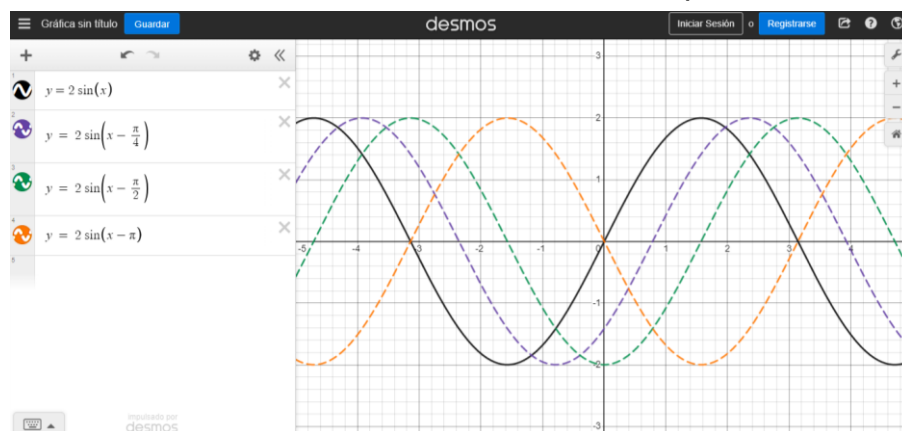
Dentro del análisis puro de los ciclos de mercado, y al comprenderse que los movimientos del mercado se derivan de movimientos ciclos, de varios marcos de

tiempo, da como resultante un movimiento que contiene varias componentes cíclicas, por eso es de vital importancia el uso las líneas futuras de *demarcation* (FLDS) en el gráfico.

Las FLDS son simplemente las líneas de precios de cierre, pero desplazadas en fase, ciertos grados a la derecha, hacia el futuro, son un reflejo del precio en el futuro. El indicador se configura con 3 de ellas, que teóricamente se van a gráficas simulando un desfase de  $45^\circ$ ,  $90^\circ$  y  $180^\circ$ . Esto al estar sustentado con bases de trigonometría, en los comportamientos que tiene una señal sinusoidal con sus pares desfasadas.

**Figura 24**

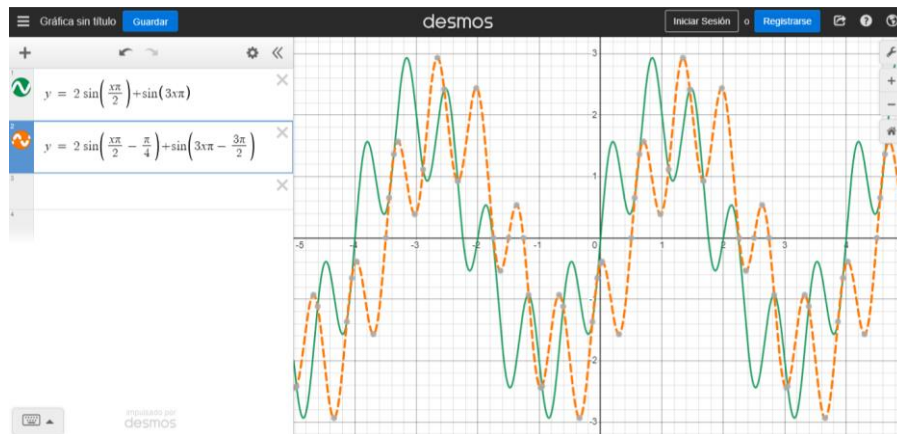
*Gráficas matemática de los ciclos del precio*



Fuente: Desmos, 2023.

Figura 25

*Formación de señal compuesta por componentes de ciclos*



Fuente: Desmos, 2023.

Su funcionamiento es representar soportes y resistencias dinámicos cuando el mercado está en tendencia, como lo muestran las Figura 25 y 26 en tendencias alcistas y bajistas, respectivamente. Cuando el precio atraviesa la línea más cercana, siendo esta la FLD de  $45^\circ$ , se cuenta con alta probabilidad de que se haga una corrección y busque acercarse a la siguiente línea, la FLD  $90^\circ$ . Al llegar a este punto, la FLD de  $90^\circ$  puede hacer la función de soporte o resistencia y así llevar al precio a que haga corrección. En caso de que el precio rompa la FLD  $90^\circ$ , se espera a que llegue a la FLD de  $180^\circ$ , teniendo similar comportamiento al caso anterior, solo que, si esta vez se rompe, sería un probable cambio de tendencia.

Figura 26

### Representación de líneas FLD en precio de USD/COP



Fuente: Investing, 2022.

Figura 27

### FLDs como indicador de resistencias y cambio de tendencia



Fuente: Investing, 2022.

Una estrategia que puede usarse con este indicador es calcular la zona probable de llegada del precio, esto cuando se tiene un mercado en tendencia y el precio rompe en contra de las tendencias FLDs. Se espera a que vuelva a recuperar el movimiento

tendencial y en el punto en que está cruzando la FLD de 180°, se mide la amplitud desde ese punto hasta el mínimo o máximo anterior, dependiendo si se venía con tendencia alcista o bajista, respectivamente. Dicha amplitud se proyecta hacia el futuro, y esta sería la zona donde probablemente se llegue. Cabe resaltar que solo se precisa la zona de llegada, mas no el tiempo, ahí es donde con el uso de otras técnicas e indicadores, se va optimizando la estrategia.

**Figura 28**

*FLDS como proyección de precio alcista*



Fuente: Investing, 2022.

Figura 29

*FLDS como proyección de precio bajista*



Fuente: Investing, 2022.

## 2.2 Osciladores

### 2.2.1 MACD (*Moving average convergence divergence*)

Se podría traducir como divergencia – convergencia de medias móviles, es un indicador que representa la diferencia que se tiene entre una señal que llamaremos “MACD”, que está compuesta por la diferencia entre 2 medias móviles del precio del activo, por lo general medias móviles de 12 y 26 periodos, y la señal “SIGNAL”, que es la media móvil exponencial de la “MACD”. Los cruces de ambas líneas tienen las mismas características del análisis de medias móviles, donde si la “MACD” atraviesa la “SIGNAL” de abajo hacia arriba, es una señal de compra, y si la “MACD” atraviesa la “SIGNAL” de arriba hacia abajo, sería una señal de venta. Igualmente, tienen la característica que cuando las líneas están muy por arriba de la línea cero, se entiende que está sobrecomprado y cuando las líneas están muy por debajo de la línea cero, está muy sobrevendido.

La diferencia que se tienen entre ambas líneas se representa como un histograma y oscila alrededor de la línea cero, siendo este nivel cuando ambas medias móviles

se cruzan. No tiene límites inferior o superior, es una representación estacionalizada, donde se infiere la tendencia dominante.

El uso del histograma, al ser la diferencia de las líneas “MACD” y “SIGNAL”, es medir el momentum del precio, mostrando la fuerza de la tendencia; así, si esta apenas está empezando, el histograma empezará a alejarse de la línea cero, o si la tendencia está perdiendo su momentum o se le está agotando la fuerza de tendencia, el histograma se acercará a la línea cero. Cuando el histograma está muy por encima de cero, pero comienza a caer hacia cero, significa que está perdiendo momentum, o sea, que la tendencia alcista se está agotando. En el caso que el histograma sea negativo, es decir, por debajo de la línea cero y empiece a subir hacia ella, está perdiendo momentum, y se estaría agotando la tendencia bajista.

**Figura 30**



Fuente: Investing, 2022.

Figura 31



También dentro de sus usos está el análisis de divergencia y convergencia. En el caso de divergencia negativa o bajista, es cuando la línea “MACD” está muy por encima del nivel cero (sobrecomprada) y sus picos estén decreciendo mientras los picos del precio están creciendo, advirtiendo así un momento de máximo de mercado. La divergencia positiva o alcista se presenta cuando los valores de la línea “MACD” está por muy por debajo de la línea cero (sobrevendida) y sus valles están aumentando, mientras los valles del precio están decreciendo, advirtiendo un mínimo del mercado.

Figura 32

*MACD indicando agotamiento de tendencia alcista*



Figura 33

*MACD indicando agotamiento de tendencia bajista*



## 2.2.2 Rsi (Índice de fuerza relativa)

Es un oscilador que permite identificar cuando el precio del activo está sobrevendido o sobrecomprado, convirtiéndolo en soporte y resistencia, que no son visibles fácilmente en el gráfico de precios; se predice el cambio de tendencia así:

- Cuando el precio va al alza, se revisan los picos o zona de sobrecompra.
- Cuando el precio va a la baja, se revisan los valles o zona de sobreventa.

- La divergencia anticipa posibles cambios de tendencia.

Su funcionamiento se basa en la medición de la fuerza, al comparar los últimos 14 días alcistas vs los últimos 14 días bajistas y, en caso de que el indicador sea positivo, significará que los días alcistas tienen más fuerza que los bajistas. En caso de que el indicador sea negativo, los días bajistas tienen más fuerza que los días alcistas. Para facilitar su comprensión se estacionaliza en una banda, cuyos rangos oscilan de 0 a 100.

Generalmente se tienen como referencias las líneas de nivel 30 y 70. Cuando el oscilador se encuentra por debajo del nivel 30, los precios están sobrevendidos, mientras que, si se encuentra por encima de la línea 70, los precios están sobrecomprados. Aunque las zonas anteriores funcionan como regla general, lo más valioso de este oscilador son las divergencias, puesto que entrar en la zona es solo una señal de alerta, llegando a ser un máximo o mínimo, pero como tal el cambio de tendencias lo proporciona la divergencia de sus picos con respecto al precio.

Divergencia alcista: se da cuando el precio viene con tendencia bajista y va presentando cada vez mínimos menores, mientras que el oscilador estando en zona de sobreventa ( $<30$ ), va presentando mínimos mayores, indicando que pronto se cambiará la tendencia de bajista a alcista.

Figura 34

*Rsi indicando agotamiento de tendencia bajista*



Divergencia bajista: se da cuando el precio viene con tendencia alcista y va presentando cada vez máximos mayores, mientras que el oscilador estando en zona de sobrecompra (>70), va presentando máximos menores, indicando que pronto se cambiará la tendencia de alcista a bajista.

Figura 35

*Rsi indicando agotamiento de tendencia alcista*



En la Figura 36 se observa cómo, aunque el oscilador RSI entra en la zona por encima del nivel 70, no se tiene divergencia, representando solo un máximo, pero luego la tendencia continúa al alza. En la Figura 37 el oscilador entra en la zona de menor a 30, pero no se tiene la divergencia, representado solo un mínimo, pero luego continuando su tendencia bajista. Estas oscilaciones pueden hacer que en una tendencia definida hagan liquidar la posición, informando erradamente del agotamiento y cambio de tendencia, pero como ya se vio, la tendencia anterior continúa cerrando posiciones tempranamente que todavía tenían mucho por ganar.

Hay escenarios que, aunque presentan divergencia, el efecto de cambio de tendencia no se hace de inmediato, a estos casos el creador del oscilador RSI, J. Welles Wilder Jr, lo llamaba las oscilaciones del fracaso, en su libro *New concepts in technical Trading systems*, publicado en 1978.

**Figura 36**



Figura 37

*Rsi indicando falso agotamiento bajista (sin divergencia)*



Fuente: Investing, 2022.

## 2.3 Mercados de futuros

### Futuro del dólar

Un contrato de futuros es un acuerdo entre partes vendedores y compradores, con el fin de negociar un activo subyacente a un precio definido hoy, en una fecha futura estimada, con características estandarizadas como:

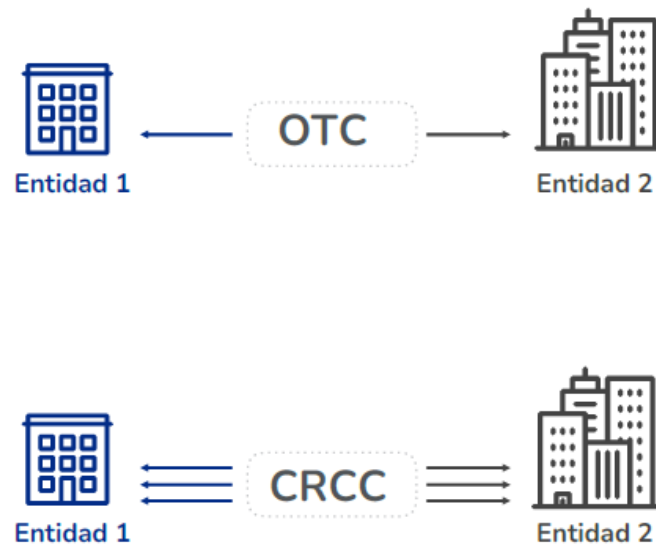
- Tamaño de contrato
- Fecha de vencimiento
- Activo subyacente
- Método de liquidación
- Reglas de negociación (Bolsa de Valores de Colombia, 2023)

Adicionalmente, se cuenta como ventaja que es regulado por la CRCC (Cámara de Riesgo Central de Contraparte) que elimina el riesgo de incumplimiento por alguna de las partes del contrato, pues hace el papel de contraparte. Cabe resaltar que en

el mercado OTC (Over The Counter) no se cuenta con este ente regulador, corriendo el riesgo de cumplimiento de alguna de las partes.

**Figura 38**

*Funcionamiento de mercados regulados*



Fuente: BVC, 2023.

Para asegurarse el cumplimiento, se solicita una garantía sobre el tamaño de la posición que, en el caso de los contratos del futuro del dólar en la Bolsa de Valores de Colombia, es del 6,3%, siendo esto una ventaja no solo en el sentido de mitigar el riesgo, sino también en que se puede apalancar la operación al solo contar con el monto de garantía.

**Figura 39**

*Tipos contratos USD/COP en BVC*

Contrato	TRM - TRX
Garantía*	6,3%

Fuente: BVC, 2023.

Figura 40

## Funcionamiento de garantía en mercado de futuros




Fuente: BVC, 2023.

En la Bolsa de Valores de Colombia se cuenta con 2 tipos de contratos para el futuro del dólar:

- TRM: Tamaño USD\$ 50.000
- TRX: Tamaño USD \$1.000

Ejemplo:

**Figura 41***Ejemplo mercado de futuros*

Fuente: BVC, 2023.


En el caso de entrar en corto para un contrato de USD\$50.000 en Diciembre (Z), a un precio de \$4.010 con vencimiento de Junio (M) con un precio de \$3.790, lograría una diferencia (spread) de \$220 pesos por cada dólar. Así, sería su utilidad al finalizar el contrato de:  $(\$4.010 - \$3.790) \times \text{USD } 50.000 = \$11'000.000 \text{ COP}$ .

## 2.4 Redes neuronales artificiales

Al investigar cómo funciona el cerebro en su función de aprendizaje, se llegó a unas aproximaciones de modelos matemáticos que lo simulan, con resultados muy importantes, de allí nacieron las técnicas de inteligencia artificial. Uno de sus métodos más destacados son las redes neuronales artificiales, que simulan la conexión y los procesos que realizan las redes neuronales cerebrales, para aprender y mejorar continuamente, al ir entrenándose cada vez más. La estructura básica del algoritmo se representa en la Figura 42:

**Figura 42**

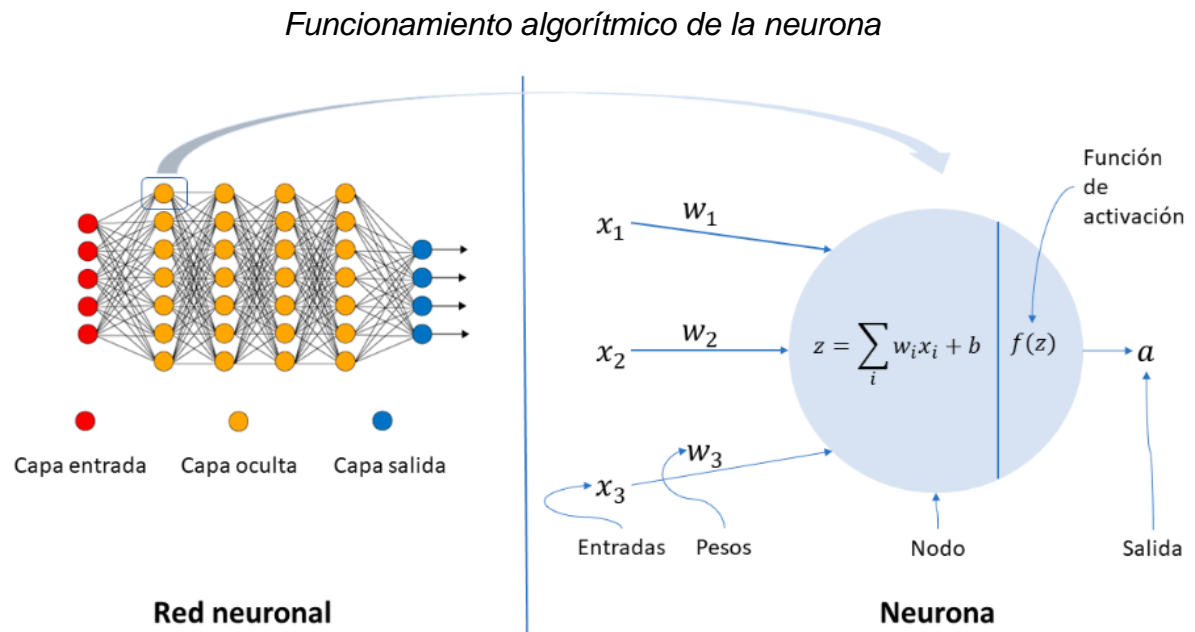
*Estructura de red neuronal artificial de 1 capa oculta con 5 neuronas*



Fuente: Efron & Hastie, 2016.

Para su representación matemática, se tiene que la estructura se compone de los pesos: Bias y las funciones de activación, como se muestra en la figura x1. A medida que el problema a resolver tiene más complejidad, la estructura de la red neuronal va integrando más de sus componentes, llegando a resolver problemas no lineales, que implican el uso de funciones matemáticas complejas, simplificándose a una estructura más sencilla, más fácil de implementar y de menor costo computacional.

Figura 43



Fuente: Ponce, 2022.


Las funciones de activación permiten darle a la red neuronal la posibilidad de resolver problemas no lineales, las más usadas son:

- Sigmoid:
- Tanh
- Relu
- Softmax

### **Sigmoid**

Usada principalmente para clasificación binaria 0 o 1.

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$


**Figura 44***Gráfica función sigmoide*

Fuente: Ponce, 2022.

**Tanh**

Muy usada para representar un rango de valores amplio, y entregar resultados en un rango continuo, como lo es un precio de un activo. Su salida está en el rango de -1 a 1.

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

**Figura 45***Gráfica función Tanh*

Fuente: Ponce, 2022.


## Relu

Función muy utilizada en el aprendizaje profundo, entre sus principales ventajas están la activación escasa y la facilidad de implementación y su rápida implementación

$$ReLU(z) = \max(0, z)$$

**Figura 46**

*Gráfica función Relu*



Fuente: Ponce, 2022.

## Softmax

Tiene forma similar a la función sigmoide, solo que permite la clasificación para más de 2 categorías, su rango de salida está entre 0 a 1. Es una generalización de regresión logística, usada para clasificación multinomial.

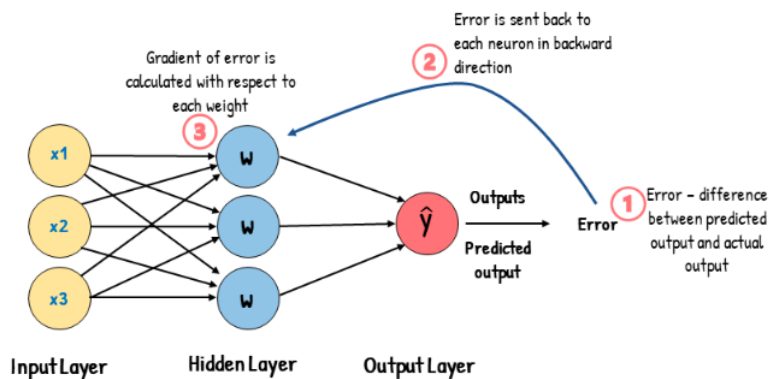
$$\phi(x_i) = \frac{e^{x_i}}{\sum_{j=0 \dots k} e^{x_j}} \quad i = 0, 1, 2, \dots, k$$

Para el entrenamiento de la red neuronal que se desea implementar, se contará con la técnica de aprendizaje supervisado (backpropagation), que se basa en tener un grupo de datos de salidas esperadas y, con ellas, comparar la salida que la red neuronal ha entregado, midiéndose el error cuadrático medio y, según su valor,

hacer cambios en los valores de la red neuronal, como los pesos y los sesgos, para así, mediante cada entrenamiento, ir mejorando la métrica, es decir, que el error tienda a cero y que se acerque cada vez más a la salida deseada.

**Figura 47**

*Metodología de aprendizaje supervisado (backpropagation)*



Fuente: Ponce, 2022.

### 3. Metodología

#### 3.1 Datos

Uno de los principales activos de los que depende la economía colombiana es el dólar, por ello se centró el estudio en el análisis de su comportamiento, para llegar a un modelo de predicción que pueda servir para todos los actores que lo necesiten: especuladores, empresarios, coberturistas o inversionistas.

Con la finalidad de contar con un rango suficiente que refleje el comportamiento del dólar, pero que a su vez sea actualizado, se tomaron datos desde el 1 de enero del año 2019 (cuando se tiene el comportamiento antes de los efectos del Covid-19), el año 2020, con los efectos de la pandemia y su repercusión en la economía y, posteriormente 2021 y 2022, que reflejan la recuperación de la parálisis que hizo la pandemia, junto con la alta inflación que generó el incentivo de las políticas monetarias para reactivar las economías. Así mismo, el año 2023 hasta el 12 de

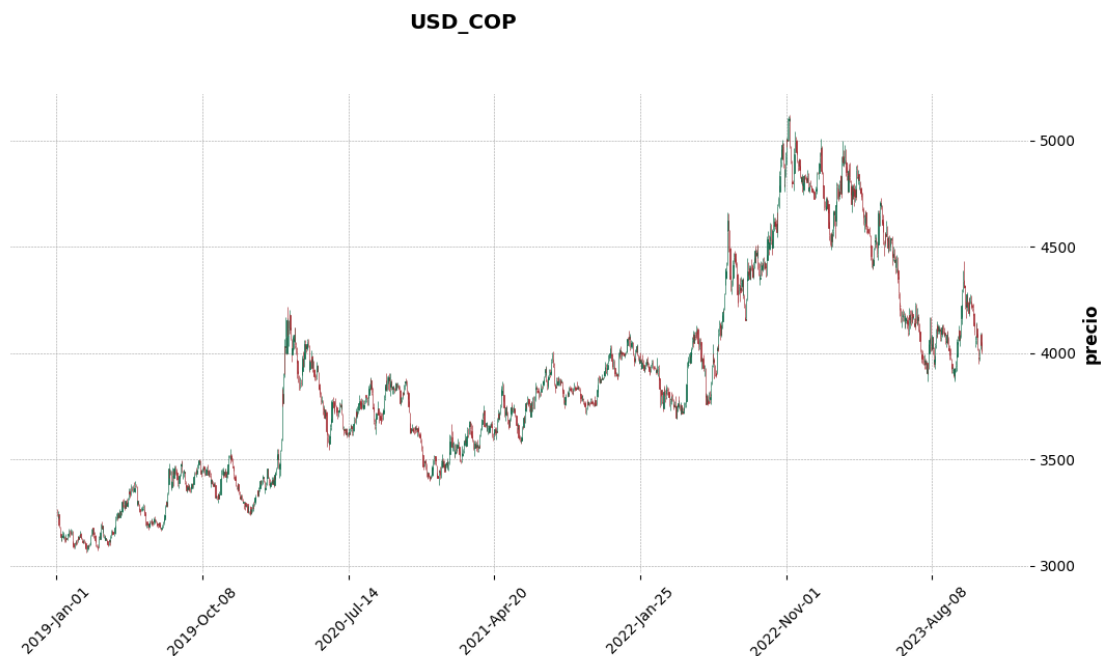
noviembre, fecha en la que se realizó el presente estudio, contando con los precios más actualizados posibles, para poder darle ese aire al modelo, contándose con un total de 1270 muestras.

El marco de tiempo a usarse fue el diario, donde cada vela representa un día de negociación bursátil. Este es de los más usados a nivel general, porque tiene una representación más acorde a los movimientos de los ciclos, y permite filtrar el ruido que le imprime algunas noticias y eventos, que solo le dan volatilidad, pero no tendencias importantes al precio.

Las fuentes, por tratarse de las más confiables y en constante actualización, fueron yahoo finance e investing. Para el caso de herramienta de visualización inicial y poder tener como referencia para ajustes, se usó investing, debido a su simplicidad y a la experiencia que ya se cuenta en su uso.

### Figura 48

*Muestra de datos de estudio, USD/COP 2019-2023*



Fuente: Investing, 2022.

## Python

A medida que se ha desarrollado la tecnología, el uso de la inteligencia artificial se ha vuelto más común, desde modelos de predicción del cáncer mediante análisis de imágenes diagnósticas, análisis de los gustos de los usuarios de internet, asistentes inteligentes como Chat GTP, modificación de imágenes, video y audio entre otras. De igual manera, las herramientas para su uso y programación también han evolucionado desde la programación, con las bases matemáticas de los algoritmos hasta la creación de módulos de uso simple, donde se brindan las entradas a la red y se esperan las salidas.

Una de las herramientas más usadas en los últimos tiempos para la programación de inteligencia artificial es Python, que cuenta con librerías como Tensor Flow, desarrollada por Google, y módulos especializados en redes neuronales como es Keras, el cual usaremos para modelar, entrenar, validar y pronosticar nuestros modelos. Al igual, con módulos para importar fácilmente de la nube los datos actualizados de los precios (yfinance), graficar tanto velas y líneas como puntos (matplotlib), y el procesamiento de los datos como matrices (Pandas), entre otras. Cabe resaltar que este lenguaje de programación es open source, lo que significa que es de libre uso, sin la necesidad de adquirir licencias y con una amplia comunidad a nivel mundial que soporta su uso.

### Figura 49

*Lenguaje de programación Python*



Fuente: Amat, 2021.

## 3.2 Indicadores

Los indicadores financieros proporcionan información clave, para la predicción del precio del activo, es por ello que se usaron 4, con los que mejores resultados se ha

tenido, en los que se encuentran Exponential moving average (EMA), Relative strength index (RSI), moving average convergence divergence (MACD), Future lines of demarcation (FLD). Se implementan en Python, con la finalidad de poder variar sus parámetros de manera estratégica, comprender su funcionamiento a fondo y extraer sus datos resultantes para insumo de los modelos de predicción.

### 3.2.1 Exponential móvil simple (EMA)

Representa un promedio de los precios del activo, en este caso se configuró con los precios de cierre (Close). Al tratarse de un estudio en marco de tiempo diario, la configuración que mejor resultados ha presentado y permite aprovechar las oportunidades del mercado son:

- Sma 7: Media móvil simple de 7 periodos
- Sma 13: Media móvil simple de 13 periodos

Figura 50

*Datos resultantes del indicador EMA*

```

MODELO1 > USD_COP2019ema.csv
1  ,Date,Close,Open,High,Low,ema1,ema2
2  0,2019/1/1,3247.5,3247.5,3248.5,3247.5,,
3  1,2019/1/2,3239.0,3246.5,3265.49,3235.08,,
4  2,2019/1/3,3244.5,3239.0,3260.25,3225.27,,
5  3,2019/1/4,3193.15,3244.5,3245.5,3189.96,,
6  4,2019/1/7,3181.99,3193.65,3194.65,3181.99,,
7  5,2019/1/8,3151.2,3181.25,3184.19,3147.0,,
8  6,2019/1/9,3136.0,3151.2,3151.2,3117.01,,
9  7,2019/1/10,3137.65,3136.0,3147.8,3118.01,,
10 8,2019/1/11,3139.15,3138.4,3164.7,3136.17,3174.678616960005,
11 9,2019/1/14,3139.6,3138.15,3158.78,3132.4,3167.6628935680005,
12 10,2019/1/15,3141.28,3139.6,3151.8,3127.1,3162.3863148544006,
13 11,2019/1/16,3117.6,3141.28,3142.78,3113.0,3153.4290518835205,
14 12,2019/1/17,3132.55,3117.85,3150.25,3117.85,3149.2532415068167,
15 13,2019/1/18,3124.0,3132.55,3134.3,3110.06,3144.202593205454,
16 14,2019/1/21,3126.5,3124.0,3131.0,3124.0,3140.6620745643636,
17 15,2019/1/22,3145.99,3126.5,3146.0,3123.38,3141.7276596514907,
18 16,2019/1/23,3151.9,3144.49,3154.2,3137.12,3143.762127721193,
19 17,2019/1/24,3171.0,3152.65,3173.53,3149.65,3149.209702176954,3163.5276174478145
20 18,2019/1/25,3151.99,3171.0,3171.0,3137.18,3149.7657617415634,3162.313131400676
21 19,2019/1/28,3158.0,3151.99,3175.01,3151.99,3151.412609393251,3161.859117569026
22 20,2019/1/29,3154.1,3158.0,3166.0,3147.0,3151.950087514601,3161.0423683512336

```

Fuente: Desmos, 2023.

Figura 51

Gráfica de precio vs EMAS  
USD\_COP



Fuente: Investing, 2022.

### 3.2.2 MACD

El índice MACD se compone de 3 partes, una línea llamada fast signal o MACD, que sale de la diferencia de 2 medias móviles exponenciales (en nuestro caso se configuró como 12 y 26 periodos), la segunda línea es una media móvil simple de la primera, la llamaremos slow y, por último, una gráfica histograma que es la diferencia entre fast signal y la slow. Cabe resaltar que a medida que se tenga el cruce de las líneas, se cuenta con probabilidad de cambio de tendencias.

Figura 52

Datos resultantes del indicador MACD


```

MODELO1 > USD_COP2019macd.csv
1 Date,Close,Open,High,Low,Ema12,Ema26,slow,fast_signal,histo
2 2019-01-01,3247.5,3247.5,3248.5,3247.5,,,,,
3 2019-01-02,3239.0,3246.5,3265.49,3235.08,,,,,
4 2019-01-03,3244.5,3239.0,3260.25,3225.27,,,,,
5 2019-01-04,3193.15,3244.5,3245.5,3189.96,,,,,
6 2019-01-07,3181.99,3193.65,3194.65,3181.99,,,,,
7 2019-01-08,3151.2,3181.25,3184.19,3147.0,,,,,
8 2019-01-09,3136.0,3151.2,3151.2,3117.01,,,,,
9 2019-01-10,3137.65,3136.0,3147.8,3118.01,,,,,
10 2019-01-11,3139.15,3138.4,3164.7,3136.17,,,,,
11 2019-01-14,3139.6,3138.15,3158.78,3132.4,,,,,
12 2019-01-15,3141.28,3139.6,3151.8,3127.1,,,,,
13 2019-01-16,3117.6,3141.28,3142.78,3113.0,3164.4866446538417,,,
14 2019-01-17,3132.55,3117.85,3150.25,3117.85,3159.573314707097,,,
15 2019-01-18,3124.0,3132.55,3134.3,3110.06,3154.1004970598515,,,
16 2019-01-21,3126.5,3124.0,3131.0,3124.0,3149.854266742951,,,
17 2019-01-22,3145.99,3126.5,3146.0,3123.38,3149.2597641671123,,,
18 2019-01-23,3151.9,3144.49,3154.2,3137.12,3149.665954295249,,,
19 2019-01-24,3171.0,3152.65,3173.53,3149.65,3152.948115172903,,,
20 2019-01-25,3151.99,3171.0,3171.0,3137.18,3152.8007128386103,,,
21 2019-01-28,3158.0,3151.99,3175.01,3151.99,3153.6006031711318,,,
22 2019-01-29,3154.1,3158.0,3166.0,3147.0,3153.677433452496,,,
23 2019-01-30,3163.2,3154.1,3168.5,3147.5,3155.1424436905736,,,
24 2019-01-31,3105.0,3163.45,3163.45,3102.49,3147.4282215843314,,,
25 2019-02-01,3089.9,3105.25,3116.98,3089.4,3138.5777259559727,,,
26 2019-02-04,3087.6,3089.9,3101.9,3082.55,3130.734998885823,,,
27 2019-02-05,3109.99,3088.6,3110.99,3081.0,3127.5434605956966,3152.079318398826,-24.535857803129602,,
28 2019-02-06,3106.0,3108.00,3110.3,3090.15,3124.2200820425123,3148.6660355544686,-24.43605351105620,
    
```

Fuente: Desmos, 2023.

Figura 53

Gráfica de precio y MACD



Fuente: Investing, 2022.

### 3.2.3 Rsi

Es el índice relative strenght index o índice de fuerza relativo, principalmente en los momentos en que el activo se encuentra sobrecomprado o sobrevendido, donde por uso general, se usan las líneas de frontera en los niveles 30 y 70. En este caso, debido a que se estudia el marco de tiempo diario, el índice se configuró con 14, lo que significa que toma el valor de las 14 velas anteriores, siendo este el que mejores resultados entrega.

**Figura 54**

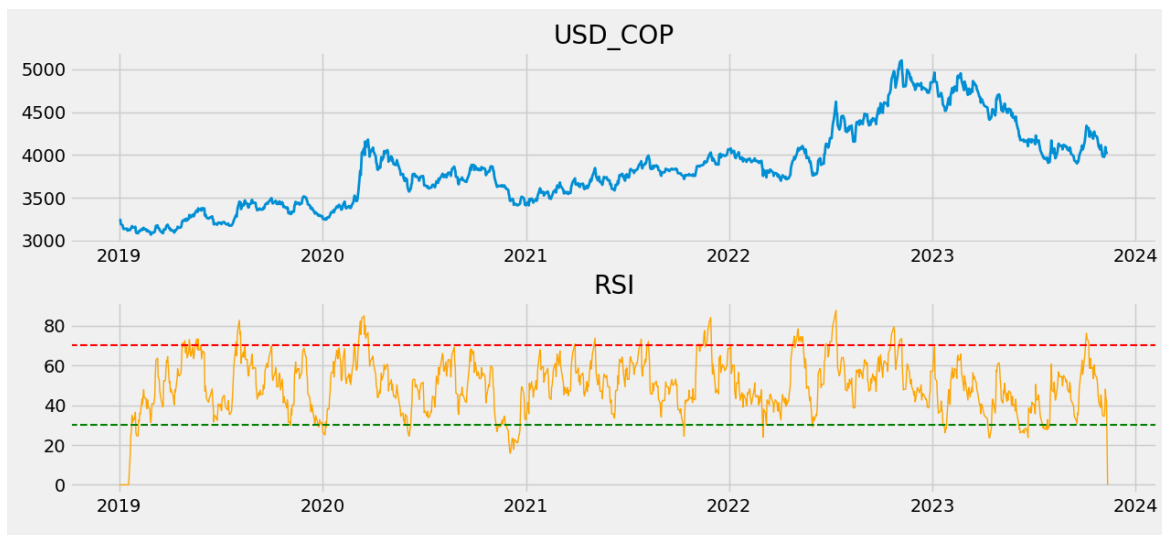
*Datos resultantes del indicador RSI*

```

MODELO1 > USD_COP2019rsi.csv
 1 Date,Close,Open,High,Low,diff_close,diff_up,diff_down,prom_up,prom_down,rsi,position
 2 2019-01-02,3239.0,3246.5,3265.49,3235.08,-8.5,0.0,8.5,,0
 3 2019-01-03,3244.5,3239.0,3260.25,3225.27,5.5,5.5,0.0,,0
 4 2019-01-04,3193.15,3244.5,3245.5,3189.96,-51.3499999999991,0.0,51.3499999999991,,0
 5 2019-01-07,3181.99,3193.65,3194.65,3181.99,-11.1600000000031,0.0,11.1600000000031,,0
 6 2019-01-08,3151.2,3181.25,3184.19,3147.0,-30.78999999999964,0.0,30.78999999999964,,0
 7 2019-01-09,3136.0,3151.2,3151.2,3117.01,-15.19999999999818,0.0,15.19999999999818,,0
 8 2019-01-10,3137.65,3136.0,3147.8,3118.01,1.65000000000091,1.65000000000091,0.0,,0
 9 2019-01-11,3139.15,3138.4,3164.7,3136.17,1.5,1.5,0.0,,0
10 2019-01-14,3139.6,3138.15,3158.78,3132.4,0.449999999998181,0.449999999998181,0.0,,0
11 2019-01-15,3141.28,3139.6,3151.8,3127.1,1.68000000000291,1.68000000000291,0.0,,0
12 2019-01-16,3117.6,3141.28,3142.78,3113.0,-23.6800000000029,0.0,23.6800000000029,,0
13 2019-01-17,3132.55,3117.85,3150.25,3117.85,14.95000000000273,14.95000000000273,0.0,,0
14 2019-01-18,3124.0,3132.55,3134.3,3110.06,-8.55000000000182,0.0,8.55000000000182,,0
15 2019-01-21,3126.5,3124.0,3131.0,3124.0,2.5,2.5,0.0,2.016428571428605,10.659285714285748,15.907810210751904,
16 2019-01-22,3145.99,3126.5,3146.0,3123.38,19.48999999999978,19.48999999999978,0.0,3.2645408163265466,9.89790
17 2019-01-23,3151.9,3144.49,3154.2,3137.12,5.91000000000309,5.91000000000309,0.0,3.4535021865889584,9.19091
18 2019-01-24,3171.0,3152.65,3173.53,3149.65,19.09999999999991,19.09999999999991,0.0,4.571109173261169,8.53442
19 2019-01-25,3151.99,3171.0,3171.0,3137.18,-19.0100000000022,0.0,19.0100000000022,4.244601375171086,9.28267
20 2019-01-28,3158.0,3151.99,3175.01,3151.99,6.01000000000218,6.01000000000218,0.0,4.370701276944595,8.61962
21 2019-01-29,3154.1,3158.0,3166.0,3147.0,-3.90000000000091,0.0,3.90000000000091,4.05850832859141,8.28251185
22 2019-01-30,3163.2,3154.1,3168.5,3147.5,9.09999999999909,9.09999999999909,0.0,4.418614876549159,7.69090386
23 2019-01-31,3105.0,3163.45,3163.45,3102.49,-58.19999999999982,0.0,58.19999999999982,4.1029995282242195,11.29
24 2019-02-01,3089.9,3105.25,3116.98,3089.4,-15.09999999999909,0.0,15.09999999999909,3.809928133351061,11.57
25 2019-02-04,3087.6,3089.9,3101.9,3082.55,-2.30000000000182,0.0,2.30000000000182,3.5377904095402712,10.9080

```

Fuente: Desmos, 2023.

**Figura 55***Gráfica de precio vs RSI*

Fuente: Investing, 2022.

### **3.2.4 FLD**

Las líneas de FLDs parten de la línea de los precios de cierre, proyectados a la derecha, o sea, hacia el futuro. Tienen bases sólidas provenientes de los ciclos de las ondas, donde la matemática, la trigonometría y los fenómenos físicos, aportan más asertividad y evita la subjetividad. En este caso, se usaron los desplazamientos de 7, 13 y 25 velas, lo que representa en el marco de tiempo diario el desplazamiento de la onda por  $45^\circ$ ,  $90^\circ$  y  $180^\circ$ , respectivamente.

Figura 56

*Datos resultantes del indicador FLD*

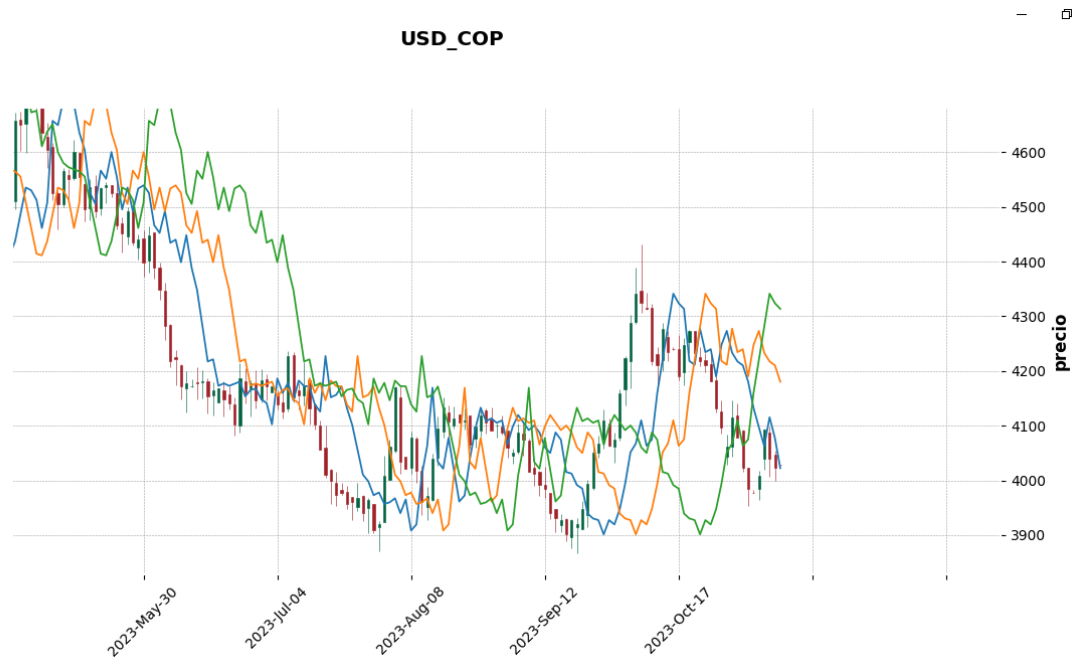
```

MODELO1 > USD_COP2019flds.csv
1 |,Date,Close,Open,High,Low,fld20, fld40, fld80
2 |0,2019/1/1,3247.5,3247.5,3248.5,3247.5,,,
3 |1,2019/1/2,3239.0,3246.5,3265.49,3235.08,,,
4 |2,2019/1/3,3244.5,3239.0,3260.25,3225.27,,,
5 |3,2019/1/4,3193.15,3244.5,3245.5,3189.96,,,
6 |4,2019/1/7,3181.99,3193.65,3194.65,3181.99,,,
7 |5,2019/1/8,3151.2,3181.25,3184.19,3147.0,,,
8 |6,2019/1/9,3136.0,3151.2,3151.2,3117.01,,,
9 |7,2019/1/10,3137.65,3136.0,3147.8,3118.01,3247.5,,
10 |8,2019/1/11,3139.15,3138.4,3164.7,3136.17,3239.0,,
11 |9,2019/1/14,3139.6,3138.15,3158.78,3132.4,3244.5,,
12 |10,2019/1/15,3141.28,3139.6,3151.8,3127.1,3193.15,,
13 |11,2019/1/16,3117.6,3141.28,3142.78,3113.0,3181.99,,
14 |12,2019/1/17,3132.55,3117.85,3150.25,3117.85,3151.2,,
15 |13,2019/1/18,3124.0,3132.55,3134.3,3110.06,3136.0,3247.5,
16 |14,2019/1/21,3126.5,3124.0,3131.0,3124.0,3137.65,3239.0,
17 |15,2019/1/22,3145.99,3126.5,3146.0,3123.38,3139.15,3244.5,
18 |16,2019/1/23,3151.9,3144.49,3154.2,3137.12,3139.6,3193.15,
19 |17,2019/1/24,3171.0,3152.65,3173.53,3149.65,3141.28,3181.99,
20 |18,2019/1/25,3151.99,3171.0,3171.0,3137.18,3117.6,3151.2,
21 |19,2019/1/28,3158.0,3151.99,3175.01,3151.99,3132.55,3136.0,
22 |20,2019/1/29,3154.1,3158.0,3166.0,3147.0,3124.0,3137.65,
23 |21,2019/1/30,3163.2,3154.1,3168.5,3147.5,3126.5,3139.15,
24 |22,2019/1/31,3105.0,3163.45,3163.45,3102.49,3145.99,3139.6,
25 |23,2019/2/1,3089.9,3105.25,3116.98,3089.4,3151.9,3141.28,
26 |24,2019/2/4,3087.6,3089.9,3101.9,3082.55,3171.0,3117.6,
27 |25,2019/2/5,3109.99,3088.6,3110.99,3081.0,3151.99,3132.55,3247.5
28 |26,2019/2/6,3106.0,3108.99,3119.3,3099.15,3158.0,3124.0,3239.0
29 |27,2019/2/7,3117.7,3106.5,3119.2,3101.75,3154.1,3126.5,3244.5
30 |28,2019/2/8,3116.05,3117.7,3125.02,3103.1,3163.2,3145.99,3193.15
31 |29,2019/2/11,3138.88,3115.55,3143.45,3110.5,3105.0,3151.9,3181.99
32 |30,2019/2/12,3126.25,3138.63,3143.5,3120.1,3089.9,3171.0,3151.2

```

Fuente: Desmos, 2023.

En la Figura 57 se observa la FLD 45° con color azul, FLD 90° con color naranja y FLD 180° con color verde.

**Figura 57***Gráfica de precio vs FLD*

Fuente: Investing, 2022.

### 3.3 Implementación de redes neuronales artificiales

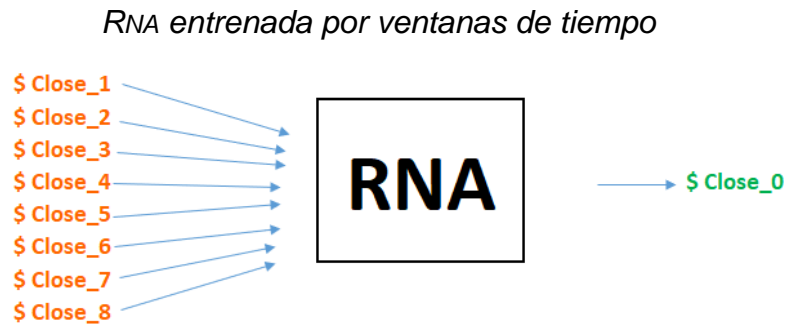
Al observar que se cuenta con muchos tipos de indicadores y cada uno de ellos tiene sus características particulares, su diversa interpretación ante cada escenario, no solo teniendo el precio presente como tema de estudio, sino también el historial de precios, la situación macroeconómica, escenarios mundiales, etc.; se deduce que tomaría mucho tiempo para que el ser humano aprenda todos los comportamientos de cada índice, sin ser imposible, esto debido a que hay traders que han tenido gran éxito al tomar sus decisiones de inversión, gracias al estudio de un grupo preferido de indicadores, pero con el factor común de que son personas con gran tiempo de trayectoria y experiencia.

Al trabajar con inteligencia artificial y ver los grandes logros que esta ciencia ha alcanzado en la actualidad, se vio la oportunidad de enseñarle a una máquina a

predecir los movimientos de un activo, en este caso, de gran importancia para el país como lo es USD/COP, con la ventaja de poder tomar menos tiempo y darle más objetividad al análisis; esto último siendo fundamental, debido a que la toma de decisiones se ve altamente influenciada por las emociones, llevando al inversionista a tomar malas decisiones dependiendo de su estado emocional. Al ser una máquina guiada por funciones de optimización, algoritmos, estructuras matriciales, entre otras, está totalmente aislada de las emociones, ciencia que se le ha llamado el psico trading.

Inicialmente al haber implementado cada uno de los indicadores ya mencionados en Python, de cada uno de ellos se tomó una base de datos, donde se tiene la fecha, precio de cierre y resultados particulares de cada indicador, que nos ayudará en el entrenamiento de cada una de las redes neuronales. Al ser datos que representan un histórico, lo óptimo es tomar ventanas de tiempo establecidas, y no dato por dato. Al intentar entrenar una red neuronal, la cual tomaría solamente un solo dato de cada variable, se llegó a resultados divergentes, donde la red no entregaba nada concluyente y el error cuadrático medio (mse) tendía a infinito, indicando que la diferencia en el dato de predicción y la realidad era muy grande.

Al investigar en aplicaciones donde se cuenta con series de tiempo, como las ventas por fecha de un negocio, producciones de cosechas, histórico de valores de sensores, etc.; se notó que los resultados entregados sí convergían y entregaban valores que, aunque no son 100% de confianza con la realidad, sí tienen gran acercamiento, viéndose el gran efecto de los valores históricos en la predicción. Por ende, se toma la metodología de ventanas de tiempo como parámetro de entrada para las redes neuronales, esperando como salida de la red neuronal el precio de cierre (Close), esto con la finalidad de generar una predicción de  $n$  días, dependiendo de los periodos de tiempo preferidos de cada trader.

**Figura 58**

Fuente: Investing, 2022.

Las redes neuronales se establecieron inicialmente con una configuración básica, por tratarse de precios, valores a predecir y no un problema tipo clasificación. Aunque la configuración de cada red neuronal varía en ciertos parámetros, como se mostrará a continuación, se hizo una amplia exploración variando cada uno de los parámetros y seleccionando los mejores, con criterio de selección del error cuadrático medio de los datos de validación.

## 4. Resultados

### 4.1 Red neuronal con precio cierre (Close)

En esta red neuronal se utilizó solamente el precio de cierre “Close”, para entrenar la red, donde se hizo una exploración ampliamente de todos los parámetros ajustables para la red, encontrándose que el mejor modelo es el #6. En la gráfica 59 se puede observar, siendo los puntos verdes los valores reales, y los puntos rojos los valores de predicción que se aproximan.

Tabla 2

## Exploración de modelos con entrada precio de cierre


MODELO	1	2	3	4	5	6	7	8	9	10
ENTRADA	Close	Close	Close	Close	Close	Close	Close	Close	Close	Close
TAMAÑO VENTANA	7	15	15	15	15	15	15	15	15	15
ITERACIONES RNA	10	10	20	100	100	100	100	100	100	100
CAPAS OCULTAS	1	1	1	1	2	4	2	2	2	2
NEURONAS POR CAPA	7	15	15	15	15	15	15	15	15	15
FUNCIONES DE ACTIVACION	tanh	tanh	tanh	tanh	tanh	tanh	Relu	Softmax	tanh	tanh
DATOS DE ENTRENO	70%	70%	70%	70%	70%	70%	70%	70%	50%	85%
DATOS DE VALIDACION	20%	20%	20%	20%	20%	20%	20%	20%	30%	10%
DATOS DE PREDICCION	10%	10%	10%	10%	10%	10%	10%	10%	20%	5%
LOSS ENTRENO	5,3%	5,6%	5,4%	4,4%	4,4%	4,3%	41,8%	1,00754E+16	5%	3%
LOSS VALIDACION	7,3%	7,9%	7,4%	6,5%	6,2%	6,2%	36,6%	73%	4%	8%
MSE ENTRENO	0,5%	0,5%	0,5%	0,3%	0,3%	0,3%	23,7%	1,2518E+16	0%	0%
MSE VALIDACION	0,8%	1,0%	0,9%	0,7%	0,6%	0,6%	19,3%	66%	0%	1%

\*

Fuente: Investing, 2022.

Figura 59

## Predicción de RNA con precio cierre



Fuente: Investing, 2022.

## 4.2 Red neuronal con precio cierre (Close) + RSI

Esta red neuronal se entrenó tomando como entrada el precio de cierre "Close" y los valores del indicador RSI. Los resultados de la exploración de los parámetros se

muestran en la Tabla 3, donde se observa que el mejor resultado lo tiene el modelo # 4, pues sus métricas tanto para los datos de entreno como los de validación, presentan los menores valores.

**Tabla 3**

*Exploración de modelos con entrada precio de cierre + RSI*


MODELO	1	2	3	4	5	6	7	8	9	10
ENTRADA	Close + rsi	Close + rsi	Close + rsi	Close + rsi	Close + rsi	Close + rsi	Close + rsi	Close + rsi	Close + rsi	Close + rsi
TAMAÑO VENTANA	7	14	14	14	14	14	14	14	14	14
ITERACIONES RNA	10	10	100	1000	100	100	100	100	100	100
CAPAS OCULTAS	1	1	1	1	2	4	4	4	4	4
NEURONAS	14	28	28	28	28	28	28	28	28	28
FUNCIONES DE ACTIVACION	tanh	tanh	tanh	tanh	tanh	tanh	Relu	Softmax	tanh	tanh
DATOS DE ENTRENO	70%	70%	70%	70%	70%	70%	70%	70%	50%	85%
DATOS DE VALIDACION	20%	20%	20%	20%	20%	20%	20%	20%	30%	10%
DATOS DE PREDICION	10%	10%	10%	10%	10%	10%	10%	10%	20%	5%
LOSS ENTRENO	21,9%	18,7%	13,5%	7,2%	11,7%	11,2%	41,1%	99,5%	12,9%	10,9%
LOSS VALIDACION	21,6%	21,1%	15,1%	8,2%	15,8%	13,5%	36,8%	73,6%	13,6%	22,5%
MSE ENTRENO	7,6%	5,6%	2,9%	0,8%	2,3%	2,2%	22,9%	121,9%	3,0%	2,1%
MSE VALIDACION	7,6%	6,7%	3,6%	1,1%	4,3%	3,0%	19,4%	66,7%	3,4%	7,6%

\*

Fuente: Investing, 2022.

**Figura 60**

*Predicción de RNA con precio cierre + RSI*



Fuente: Investing, 2022.

### 4.3 Red neuronal con precio cierre (Close) + MACD

En esta red neuronal se usó como entradas el precio de cierre “Close” y el índice MACD, en su exploración de parámetros para los 10 modelos expuestos, se encontró que el de mejores resultados en sus métricas fue el modelo # 5.

**Tabla 4**

*Exploración de modelos con entrada precio de cierre + MACD*


MODELO	1	2	3	4	5	6	7	8	9	10
ENTRADA	Close + MAC	Close + MA	Close + MA	Close + MA	Close + MA	Close + MA	Close + MA	Close + MACD	Close + MA	Close + MACD
TAMAÑO VENTANA	4	16	4	4	4	4	4	4	4	4
ITERACIONES RNA	10	10	100	1000	10	10	10	10	10	10
CAPAS OCULTAS	1	1	1	1	2	4	2	2	2	2
NEURONAS	12	48	12	12	12	12	12	12	12	12
FUNCIONES DE ACTIVACION	tanh	tanh	tanh	tanh	tanh	tanh	Relu	Softmax	tanh	tanh
DATOS DE ENTRENO	70%	70%	70%	70%	70%	70%	70%	70%	50%	85%
DATOS DE VALIDACION	20%	20%	20%	20%	20%	20%	20%	20%	30%	10%
DATOS DE PREDICCION	10%	10%	10%	10%	10%	10%	10%	10%	20%	5%
LOSS ENTRENO	5,70%	5,48%	4,40%	4,25%	5,44%	5,59%	22,35%	98,57%	5,76%	4,85%
LOSS VALIDACION	7,30%	8,88%	6,44%	9,16%	7,22%	9,14%	15,77%	78,13%	5,83%	11,43%
MSE ENTRENO	0,55%	0,51%	0,35%	0,32%	0,49%	0,51%	11,95%	119,43%	0,54%	0,41%
MSE VALIDACION	0,86%	1,34%	0,65%	1,84%	0,82%	1,42%	6,69%	77,82%	0,62%	1,81%

\*

Fuente: Investing, 2022.

**Figura 61**

*Predicción de RNA con precio cierre + MACD*



Fuente: Investing, 2022.

#### 4.4 Red neuronal con precio cierre (Close) + FLDS

En este caso la red neuronal se entrenó con el precio de cierre “Close” y las 3 líneas FLDS, 45 ° 90 ° y 180°, en este caso, el modelo que mejor resultados en sus métricas presentó es el # 4.

**Tabla 5**

*Exploración de modelos con entrada precio de cierre + FLD*

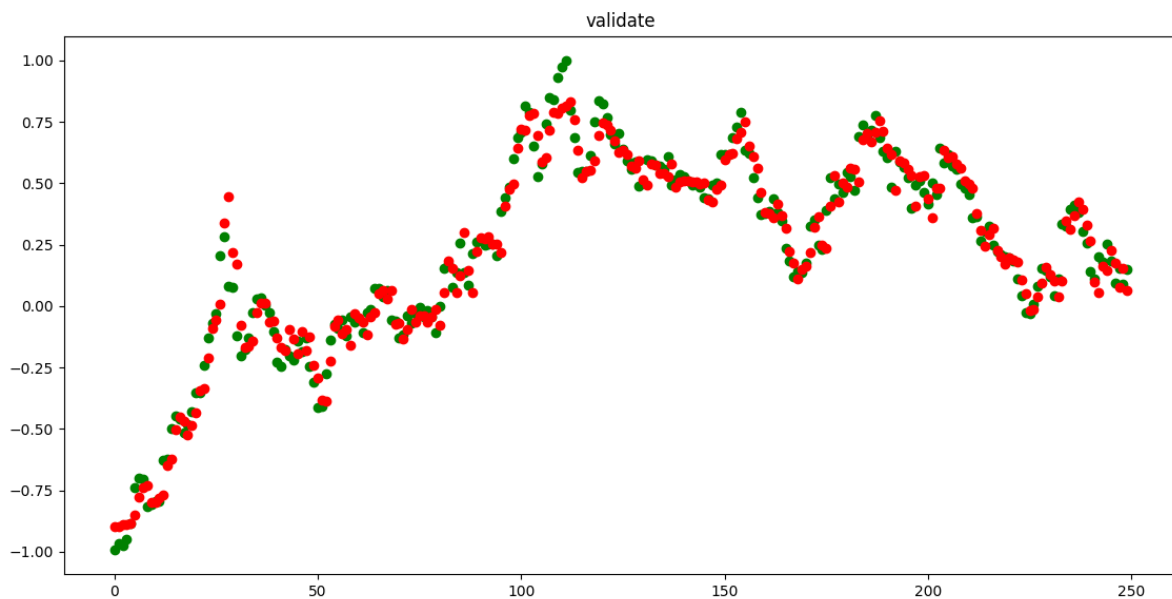
MODELO	1	2	3	4	5	6	7	8	9	10
ENTRADA	Close + FLD	Close + FLD	Close + FLD	Close + FLD	Close + FLD	Close + FLD	Close + FLD	Close + FLD	Close + FLD	Close + FLD
TAMAÑO VENTANA	4	16	4	4	4	4	4	4	4	4
ITERACIONES RNA	10	10	100	1000	10	10	10	10	10	10
CAPAS OCULTAS	1	1	1	1	2	4	2	2	2	2
NEURONAS	16	64	16	16	16	16	16	16	16	16
FUNCIONES DE ACTIVACION	tanh	tanh	tanh	tanh	tanh	tanh	Relu	Softmax	tanh	tanh
DATOS DE ENTRENO	70%	70%	70%	70%	70%	70%	70%	70%	50%	85%
DATOS DE VALIDACION	20%	20%	20%	20%	20%	20%	20%	20%	30%	10%
DATOS DE PREDICCION	10%	10%	10%	10%	10%	10%	10%	10%	20%	5%
LOSS ENTRENO	5,4%	6,1%	4,4%	4,1%	5,3%	5,5%	23,2%	99,4%	6,1%	4,0%
LOSS VALIDACION	8,1%	10,8%	6,9%	6,9%	7,2%	6,9%	14,7%	78,1%	5,2%	7,6%
MSE ENTRENO	0,5%	0,6%	0,3%	0,3%	0,5%	0,5%	12,6%	121,6%	0,6%	0,3%
MSE VALIDACION	1,0%	1,8%	0,8%	0,7%	0,8%	0,8%	6,0%	77,8%	0,5%	1,0%

\*

Fuente: Investing, 2022.

**Figura 62**

Predicción de RNA con precio cierre + FLD



Fuente: Investing, 2022.

#### 4.5 Modelo final

El modelo que mejor resultado tuvo de todos los explorados fue el modelo # 6, con entrada de solo el precio de cierre "Close". La configuración de sus parámetros es la siguiente:

**Tabla 6**


*Modelo con mejores resultados*

<b>MODELO</b>	<b>6</b>
ENTRADA	Close
TAMAÑO VENTANA	15
ITERACIONES RNA	<b>100</b>
CAPAS OCULTAS	<b>4</b>
NEURONAS POR CAPA	15
FUNCIONES DE ACTIVACION	tanh
DATOS DE ENTRENO	70%
DATOS DE VALIDACION	20%
DATOS DE PREDICCION	10%
LOSS ENTRENO	4,3%
LOSS VALIDACION	6,2%
MSE ENTRENO	0,3%
MSE VALIDACION	0,6%

Fuente: Investing, 2022.

**Figura 63**


*Predicción de RNA modelo final de USD/COP 2019-2023*



Fuente: Investing, 2022.

**Figura 64**

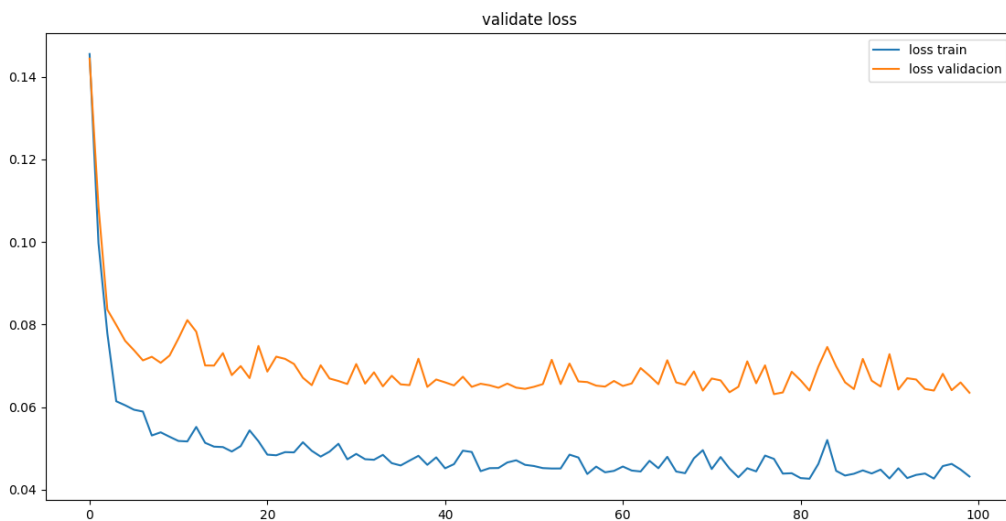
*Predicción de RNA modelo final de USD/COP oct – nov 2023*



Fuente: Investing, 2022.

**Figura 65**


*Comportamiento de pérdida (loss) en cada entrenamiento*



Fuente: Investing, 2022.

**Figura 66**

*Predicción de RNA modelo final vs precio real*



Fuente: Investing, 2022.

Los resultados obtenidos brindan gran satisfacción, debido a que representan de forma aproximada, el futuro movimiento del precio del USD/COP; claramente difiere

con un margen de error en los precios, pero al proporcionar el posible movimiento en el futuro de 7 días, inicialmente, se cuenta con una ventaja adicional para la negociación del activo.

## 5. Conclusiones

- Aunque el uso de algoritmos de inteligencia artificial brinda una ventaja en comparación con los análisis tradicionales de precios, se cuenta con unas probabilidades considerables de error, por ende, se recomienda su uso acompañado de otras herramientas.
- No siempre el contar con muchas herramientas asegura un mejor resultado, como lo demuestran los mejores resultados del modelo que solo se entrenó con el precio de cierre "Close", en comparación con los modelos que tenían precio e indicador.
- El uso de herramientas computacionales, en este caso Python, brinda una gran ventaja para el estudio de los mercados financieros, por su rapidez de procesamiento, la facilidad de obtener gráficas y la medición de estrategias.

## Referencias bibliográficas

- Amat, Joaquín (mayo de 2021). *Redes neuronales con Python*. Ciencia de datos. <https://cienciadedatos.net/documentos/py35-redes-neuronales-python>
- Arrieta, J. E. Torres, J. C. y Velásquez, H. (2009). *Predicción del comportamiento diario de la acción SURAMINV: Redes Neuronales y modelos econométricos* [Trabajo de grado, Universidad Eafit] Repositorio institucional de la Universidad Eafit. <https://repository.eafit.edu.co/handle/10784/256>
- Bagnato, Juan. (26 de febrero de 2019). Pronóstico de Series Temporales con Redes Neuronales en Python. *Aprende machine learning*. <https://www.aprendemachinelearning.com/pronostico-de-series-temporales-con-redes-neuronales-en-python/>
- Bolsa de Valores de Colombia, BVC (2023). *Derivados de USD*. <https://www.bvc.com.co/derivados-descripcion-general>
- Efron, B. & Hastie, T. (2016). *Computer age statistical Inference, algorithms, evidence and data science*, p. 351. Neural networks and Deep learning.
- Desmos (2023). *Desmos, calculadora gráfica*. <https://www.desmos.com/calculator?lang=es>
- Equipo de redactores Legis. (2021). *Cuáles son los productos que importa Colombia*. Legis. Consultado el 5 de abril 2022 de: <https://blog.legis.com.co/comercio-exterior/cuales-son-los-productos-que-importa-colombia>
- Equipo de redactores Legis. (2022). *Los principales productos que exporta Colombia*. Legis. Consultado el 5 de abril 2022 de <https://blog.legis.com.co/comercio-exterior/principales-productos-que-exporta-colombia>
- Fenalce. (2018). *Agroinsumos S.A*. Consultado el 6 de abril de 2022 de: <https://agroinsumossa.com/cultivo-del-maiz-en-colombia/>
- Fenalce. (2021). *Estadísticas*. Fenalce. Consultado el 6 de abril de 2022 de: <https://fenalce.co/estadisticas/>

- Hurst, James. (1975). *The profit magic of stock transaction timing*. Editorial Prentice –Hall.
- Investing (2022). *Gráfica del USD/COP*. <https://www.investing.com/currencies/usd-cop>
- Jason, Fernando. (31 de marzo de 2023). Relative Strength Index (RSI) Indicator explained with formula. *Investopedia*. <https://www.investopedia.com/terms/r/rsi.asp>
- López, A.Z. (2017) *Los ciclos en los mercados bursátiles: El Factor temporal en la formación de los precios* [Tesis Doctoral, Universidad Pontificia Comillas ICAI] Repositorio institucional de la Universidad Pontificia Comillas ICAI. <https://repositorio.comillas.edu/rest/bitstreams/119121/retrieve>
- Mcnelis, P. D. (2005). *Neural network in finance gaining predictive edge in the market*. San Diego, California: Elsevier Academy Press.
- Murphy, John J. (1999). *Análisis técnico de los mercados financieros*. Editorial Planeta.
- Ponce, Jahazie (10 de junio de 2022). *Conoce qué son las funciones de activación y cómo puedes crear tu función de activación usando Python, R y Tensorflow*. Jahaziel Ponce. <https://jahazielponce.com/funciones-de-activacion-y-como-puedes-crear-la-tuya-usando-python-r-y-tensorflow/>
- Peñuela, M. (s.f.). Aumenta la importación de maíz en Colombia. *Revista Alimentos*. Consultado el 6 de abril de 2022 de: <https://www.revistaalimentos.com/aumenta-importacion-de-maiz-en-colombia/>
- Welles Wilder, J. Jr. (1978). *New concepts in technical Trading systems*. <https://estrategiastrading.com/review-libro-welles-wilder/>
- West, Zack (s. f.). Calculating the RSI: 3 way to predict Market status & movement. *Alpharithms*. <https://www.alpharithms.com/relative-strength-index-rsi-in-python-470209/>
- West, Zack. (s. f.). Calculating the MACD in Python for algorithmic trading. *Alpharithms*. <https://www.alpharithms.com/calculate-macd-python-272222/>

## Anexos

### Código red neuronal "Close"

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

from keras.models import Sequential
from keras.layers import Dense,Activation,Flatten
from sklearn.preprocessing import MinMaxScaler

#Cantidad de Iteraciones de la red neuronal
EPOCHS=100 #10
#Tamaño del bloque de datos, dias.
PASOS=15 # 7

df = pd.read_csv('RED
NEURONAL\\USD_COP2019rsi.csv',index_col=1,parse_dates=True )

# index_col=1, se toma para que quede como index la columna de date,
puesto que se creó una columna con índices enteros de otro ejercicio
# parse_dates=True, para que tome las fechas como formato DATETIME64, y
así poder crear la serie válida para este código

#Extrayendo solo columna precios:
df2=df.loc[:,["Close"]]

#Distribucion de datos:
#Train
Porce_train=0.7 # 0.7
#Validate
Porce_validate=0.2 # 0.2
#Test
Porce_test=0.1 # 0.1

Size_datos= len(df2)
Size_train= int(Size_datos*Porce_train)
Size_validate= int(Size_datos*Porce_validate)
Size_test= int(Size_datos*Porce_test)
print(Size_train)
print(Size_validate)
print(Size_test)

df_train=df2.iloc[:Size_train,:]
df_validate=df2.iloc[Size_train:(Size_train+Size_validate),:]
df_test=df2.iloc[(Size_train+Size_validate):,:]

# Squeeze cambia de dataframe a series, las series funcionan con 2
elementos, como si fuera un diccionario, solo que es lineal
df = df_train.squeeze()
df_validate=df_validate.squeeze()
df_test=df_test.squeeze()

```

```

# convirtiendo dataframe a serie supervisada
def series_to_supervised(data, n_in=1, n_out=1, dropnan=True):
    n_vars = 1 if type(data) is list else data.shape[1]
    df = pd.DataFrame(data)
    cols, names = list(), list()
    # input sequence (t-n, ... t-1)
    for i in range(n_in, 0, -1):
        cols.append(df.shift(i))
        names += [('var%d(t-%d)' % (j+1, i)) for j in range(n_vars)]
    # forecast sequence (t, t+1, ... t+n)
    for i in range(0, n_out):
        cols.append(df.shift(-i))
        if i == 0:
            names += [('var%d(t)' % (j+1)) for j in range(n_vars)]
        else:
            names += [('var%d(t+%d)' % (j+1, i)) for j in range(n_vars)]
    # put it all together
    agg = pd.concat(cols, axis=1)
    agg.columns = names
    # drop rows with NaN values
    if dropnan:
        agg.dropna(inplace=True)
    return agg

# *****
# Entra una serie de 1 dimensión y sale el arreglo de supervised learning
#Cargando datos de entreno
values = df.values
values = values.astype('float32')
scaler = MinMaxScaler(feature_range=(-1, 1))
values=values.reshape(-1, 1)
scaled = scaler.fit_transform(values)
reframed = series_to_supervised(scaled, PASOS, 1)

#Cargando datos de validacion
values_val = df_validate.values
values_val = values_val.astype('float32')
scaler = MinMaxScaler(feature_range=(-1, 1))
values_val=values_val.reshape(-1, 1)

reframed_val = series_to_supervised(scaled, PASOS, 1)

values_train = reframed.values
values_val = reframed_val.values
train = values_train
test = values_val
x_train, y_train = train[:, :-1], train[:, -1]
x_val, y_val = test[:, :-1], test[:, -1]
x_train = x_train.reshape((x_train.shape[0], 1, x_train.shape[1]))
x_val = x_val.reshape((x_val.shape[0], 1, x_val.shape[1]))

# *****

```

```

# Parametros del modelo
def crear_modeloFF():
    model = Sequential()
    model.add(Dense(PASOS, input_shape=(1,PASOS),activation='tanh'))#CAPA
OCULTA 1
    model.add(Flatten())
    model.add(Dense(PASOS, activation='tanh'))#AGREGADA
    model.add(Dense(PASOS, activation='tanh'))#AGREGADA
    model.add(Dense(PASOS, activation='tanh'))#AGREGADA
    model.add(Dense(1, activation='tanh'))#CAPA SALIDA

model.compile(loss='mean_absolute_error',optimizer='Adam',metrics=["mse"])
)
    model.summary()
    return model

#Entrenamiento del modelo
model = crear_modeloFF()
print("Training...")
history1=model.fit(x_train,y_train,epochs=EPOCHS,validation_data=(x_val,y
_val),batch_size=PASOS,verbose=0)
print("Finish training!!!")

#Métricas del modelo
print(history1.history.keys())
Error_train=history1.history["loss"][-1]
mse_train=history1.history["mse"][-1]
Error_eval=history1.history["val_loss"][-1]
mse_eval=history1.history["val_mse"][-1]
msetotal=history1.history["val_mse"]
errortotal=history1.history["val_loss"]

results=model.predict(x_val)

ultimosDias = df_test["2023-07-28":"2023-9-07"]#debe ser el doble de
datos de PASOS
print(ultimosDias.info())

values_test = ultimosDias.values
values_test = values_test.astype('float32')
# normalize features
values_test=values_test.reshape(-1, 1)
# print(values)
scaled = scaler.fit_transform(values_test)
reframed_test = series_to_supervised(scaled, PASOS, 1)

#quitamos la ultima columna de salidas
reframed_test.drop(reframed_test.columns[[PASOS]], axis=1, inplace=True)

```

```

values_test = reframed_test.values
x_test = values_test[(PASOS-1):, : ]#6
x_test = x_test.reshape((x_test.shape[0], 1, x_test.shape[1]))

# Armado de ventana prediccion de tamaño (PASOS) dias

def agregarNuevoValor(x_test,nuevoValor):
    for i in range(x_test.shape[2]-1):
        x_test[0][0][i] = x_test[0][0][i+1]
    x_test[0][0][x_test.shape[2]-1]=nuevoValor
    return x_test

resultsnew=[]
for i in range(PASOS):
    parcial=model.predict(x_test)
    resultsnew.append(parcial[0])
    # print(x_test)
    x_test=agregarNuevoValor(x_test,parcial[0])

adimen = [x for x in resultsnew]
inverted = scaler.inverse_transform(adimen)
inverted

prediccion1SemanaDiciembre = pd.DataFrame(inverted)
prediccion1SemanaDiciembre.columns = ['pronostico']

realpronos = df_test['2023-9-8':'2023-9-28']
realpronosdf = pd.DataFrame(realpronos)
realpronosdf.columns = ['real']

prediccion1SemanaDiciembre.set_index(realpronosdf.index,inplace=True)
print(prediccion1SemanaDiciembre)

resultadosfinal=pd.DataFrame()
resultadosfinal["real"]=realpronosdf["real"]
resultadosfinal["pronostico"]=prediccion1SemanaDiciembre["pronostico"]
resultadosfinal["diferencia"]=resultadosfinal["real"]-
resultadosfinal["pronostico"]
mse_prediccion=np.square(np.subtract(resultadosfinal["real"],resultadosfi
nal["pronostico"])).mean()
print(resultadosfinal)
print(resultadosfinal.describe())

#Graficando resultados del entrenamiento
print( len(results) )
plt.scatter(range(len(y_val)),y_val,c='g',label="Precio real USD/COP")
plt.legend(loc="upper right")
plt.scatter(range(len(results)),results,c='r',label="Prediccion USD/COP")
plt.legend(loc="upper right")
plt.title('VALIDACION')
plt.show()

```

```
plt.plot(history1.history['loss'], label="loss train")
plt.title('loss')
plt.legend(loc="upper right")
plt.plot(history1.history['val_loss'],label="loss validacion")
plt.title('validate loss')
plt.legend(loc="upper right")
plt.show()

# Mostrando resultados
print(f"Error_train: {Error_train}")
print(f"Error_val: {Error_eval}")
print(f"mse_train: {mse_train}")
print(f"mse_val: {mse_eval}")
print(f"mse_prediccion: {mse_prediccion}")

# Graficando pronóstico
fig = plt.figure()
ax1 = fig.add_subplot(211)
ax2 = fig.add_subplot(212)
ax1.plot(prediccion1SemanaDiciembre['pronostico'],
linewidth=2,c="g",label= "Predicción de Precio")
ax1.legend(loc="upper right")

ax2.plot(realpronosdf['real'], linewidth=2,c="r", label="Precio Real
USD/COP")
ax2.legend(loc="upper right")
plt.title('PRONOSTICO 7 DIAS')
plt.show()
```