

SISTEMA DE PREDICCIÓN DEL COMPORTAMIENTO DEL ACTIVO FINANCIERO (EUR/USD) EN EL MERCADO FOREX, UTILIZANDO HERRAMIENTAS DE APRENDIZAJE AUTOMÁTICO. CASO: ECUADOR.
PREDICTIVE SYSTEM FOR THE BEHAVIOR OF THE FINANCIAL ASSET (EUR/USD) IN THE FOREX MARKET USING MACHINE LEARNING TOOLS: CASE: ECUADOR

Mateo López Huerta

Fundación Universitaria Iberoamericana, Ecuador

[mateolopezh15@hotmail.com] [<https://orcid.org/0009-0000-4692-5867>]

Jon Arambarri

Universidad Europea del Atlántico, España

[jon.arambarri@uneatlantico.es] [<https://orcid.org/0000-0002-6450-8562>]

Saul Domingo

Fundación Universitaria Iberoamericana, España

[saul_domingo@funiber.org] [<https://orcid.org/0000-0002-7559-6131>]

Información del manuscrito:

Recibido/Received: 15/12/2025

Revisado/Reviewed: 15/01/2026

Aceptado/Accepted: 24/02/2026

RESUMEN

Palabras clave:

inteligencia artificial, psicotrading, trader, redes neuronales recurrentes, python

La presente investigación se centra en el desarrollo de un sistema de predicción para el par de divisas EUR/USD, reconocido por su estabilidad y atractiva rentabilidad en el mercado global, pero sujeto a episodios de volatilidad. El estudio busca mitigar el impacto de la gestión emocional del trader conocida como “psicotrading”, una variable que puede comprometer la efectividad de estrategias técnicas en el ámbito del trading. Con el propósito de reducir la influencia del factor humano en la toma de decisiones, se adopta la metodología propuesta por Tinoco-Figueroa S. (2024), quien aplicó algoritmos como la distancia de Lorentz y vecinos más cercanos aproximados en el análisis del par de divisas BTC/USD. En esta investigación se incluye el uso de Redes Neuronales Recurrentes, específicamente el modelo LSTM (Long Short-Term Memory), dada su capacidad para modelar series temporales financieras con alta precisión. La implementación técnica se realizó en el entorno de desarrollo Visual Studio Code – VSCODE, utilizando el lenguaje de programación Python. Los datos históricos fueron obtenidos desde la plataforma MetaTrader5, estableciendo una conexión en tiempo real para recopilar información de los últimos 60 días con intervalos de 15 minutos. En principio se realizó un diagnóstico inicial para posteriormente plantear la estrategia y evaluar el desempeño del sistema mediante métricas específicas, se comparó con los resultados obtenidos por Tinoco-Figueroa S. (2024), y se propusieron acciones de mejora junto con la exposición de las limitaciones del modelo.

ABSTRACT

Keywords:

artificial Intelligence,
psychotrading, trader, recurrent
neutral networks, python

The present research focuses on the development of a prediction system for the EUR/USD currency pair, recognized for its stability and attractive profitability in the global market, yet subject to episodes of volatility. The study seeks to mitigate the impact of traders' emotional management, known as "psychotrading," a variable that can compromise the effectiveness of technical strategies in the field of trading. With the purpose of reducing the influence of the human factor in decision-making, the methodology proposed by Tinoco-Figueroa S. (2024) was adopted, who applied algorithms such as Lorentz distance and approximate nearest neighbors in the analysis of the BTC/USD currency pair. This research incorporates the use of Recurrent Neural Networks, specifically the LSTM (Long Short-Term Memory) model, given its ability to model financial time series with high accuracy. The technical implementation was carried out in the Visual Studio Code – VSCODE development environment, using the Python programming language. Historical data were obtained from the MetaTrader5 platform, establishing a real-time connection to collect information from the last 60 days with 15-minute intervals. Initially, a diagnostic assessment was conducted, followed by the design of the strategy and evaluation of the system's performance through specific metrics. The results were compared with those obtained by Tinoco-Figueroa S. (2024), and improvement actions were proposed along with the presentation of the model's limitations.

Introducción

El presente estudio propone predecir el precio de un instrumento financiero que se cotiza en la bolsa de valores, se elige el par de divisas EUR/USD por ser un activo financiero popular y que históricamente ha demostrado estabilidad, pero también cierta volatilidad, además, son divisas utilizadas por países con las economías más grandes y fuertes del mundo, lo que le convierte en un instrumento financiero atractivo. Para la predicción utilizaremos la metodología propuesta por Tinoco-Figueroa, S. (2024), mediante el uso de dos algoritmos: 1.- la “Distancia de Lorentz” y, 2.- “Vecinos más Cercanos Aproximados”, pretendiendo ser un aporte a dicho estudio la incorporación de un tercer algoritmo 3.- Redes Neuronales Recurrentes (RNN).

Es conocido que la predicción del precio de activos financieros es todo un reto, con el uso de tecnologías a la vanguardia ha permitido a inversionistas gestionar el riesgo de mejor manera que los métodos tradicionales, sin embargo, la problemática de predecir el precio de un instrumento financiero representa un trabajo multifacético, que trae consigo la suma de constantes esfuerzos; desde tiempos antiguos esta problemática fue siempre una discusión, de ahí que constantemente se han implementado métodos para mejorar la capacidades predictivas de los modelos o enfoques empleados, y es que, el problema de predicción no solo parte del conocimiento, si no, también de aprender a gestionar las emociones, en el mundo del trading conocido como “psicotrading”; parafraseando lo que dice Naranjo K, y González G, (2022) “... los sentimientos profundos... no se pueden evitar, pero si se pueden controlar ya que juegan un papel bastante importante si se quiere operar en estos mercados financieros...”. Con la aparición de la Inteligencia Artificial (IA), se ha logrado automatizar la tarea y excluir de la escena de predicción el “psicotrading”, esto tiene su ventaja y desventaja, los sistemas no sienten, actúan con base en los algoritmos lo cual es una ventaja si el trader no sabe gestionar sus emociones, pero es una desventaja si el trader es capaz de captar de manera efectiva lo que dice el mercado, excluyendo o al menos minimizando el sentimiento propio de operar en los mercados financieros; sin embargo, en la actualidad los sistemas de predicción recogen de manera efectiva lo que el mercado realmente dice, parecería ser que el “psicotrading” se puede evitar, ya que el no excluir de la ecuación esta variable, implica varios esfuerzos que en muchas ocasiones son difíciles de manejar. La respuesta a esta problemática es excluir de la ecuación al psicotrading que la mayoría de los traders se enfrentan cada día, y poner a disposición un sistema robusto estadísticamente y rentable financieramente, que alcance altas tasas de éxito en sus operaciones, pretendiendo mejorar la propuesta por Tinoco-Figueroa, S. (2024), con una tasa de éxito del 92,86% y un ratio sharpe de 0,13, para el par de divisas BCH/USD.

Valer, S. (2023) comprobó mediante un estudio empírico que el uso de redes neuronales recurrentes en la predicción del precio de instrumentos financieros han dado buenos resultados, por lo que, se incorporará redes neuronales recurrentes, que no es más que, imitar el comportamiento del cerebro humano para la toma de decisiones, intentando mejorar la capacidad de predicción del estudio realizado por Tinoco-Figueroa, S. (2024), es decir, se creará un sistema de predicción con base en tres algoritmos y al final se evaluara a través de métricas de desempeño y se comparará con el estudio mencionado, para conocer su efectividad.

En principio se presenta el contexto inicial que da origen a la investigación, exponiendo la problemática que enfrentan los operadores financieros (traders) al momento de ejecutar sus estrategias en los mercados. Se reconoce que, independientemente de la calidad técnica de una estrategia, la falta de dominio sobre el

componente emocional (psicotrading) puede derivar en decisiones erróneas y resultados adversos.

Posteriormente se establece la metodología de recolección de datos, detallando la plataforma financiera seleccionada para la obtención de información y justificando su elección en función de los requerimientos del estudio. Análogamente, se describe el enfoque aplicado para la limpieza de los datos, con el objetivo de construir un conjunto estructurado (dataframe) libre de sesgos y de variables que pudieran generar confusión en el análisis; cabe señalar que un dataframe es una estructura de datos bidimensional, organizada en filas y columnas, similar a una hoja de cálculo o una tabla de base de datos.

A continuación, se presenta un diagnóstico preliminar que permite caracterizar el activo financiero objeto de estudio, mediante la visualización de diversos gráficos que facilitan el análisis exploratorio. Entre estos se incluyen: gráficos del precio de cierre de los últimos 60 días con intervalos de 15 minutos, distribución del precio de cierre, diagramas de caja (boxplots) y análisis de correlación entre variables del dataframe. Acto seguido, se expone la propuesta derivada del diagnóstico y los resultados obtenidos en el proceso de levantamiento de información, orientada al aprovechamiento de la oportunidad identificada; se describe el desarrollo del sistema de predicción del precio del activo EUR/USD, abordando los aspectos técnicos del código implementado, tales como la creación del bucle (estructura de control que permite repetir instrucciones hasta que se cumpla una condición específica), así como los elementos contenidos en dicho bucle: listas, indicadores técnicos, condiciones de apertura y cierre de posiciones, generación de señales, y la aplicación de los tres algoritmos que constituyen la base metodológica del estudio.

Seguidamente, se presenta de manera sistemática los resultados obtenidos a partir de la implementación del sistema de predicción del precio del par de divisas EUR/USD. Se realiza una evaluación exhaustiva de las métricas de desempeño seleccionadas, tales como el error cuadrático medio (MSE), el coeficiente de determinación (R^2), y otras métricas relevantes que permiten valorar la precisión y eficiencia del modelo propuesto, esta evaluación se complementa con una comparación directa respecto a la metodología desarrollada por Tinoco Figueroa S. (2024), con el fin de identificar similitudes, diferencias y posibles mejoras en cuanto al enfoque predictivo. Luego, se analizan los resultados obtenidos en función de su aplicabilidad práctica en escenarios reales de trading, considerando tanto el comportamiento del modelo ante datos históricos como su capacidad de adaptación a condiciones de mercado cambiantes, se discuten las fortalezas del sistema desarrollado, así como sus limitaciones técnicas y operativas.

Por último, se plantea un conjunto estructurado de acciones orientadas a mejorar el rendimiento global del sistema propuesto. Estas acciones comprenden, en primer lugar, la optimización operativa de los procesos internos, con el objetivo de reducir redundancias, mejorar la eficiencia computacional y facilitar la escalabilidad funcional. En segundo lugar, se recomienda avanzar hacia una modularización sistemática de los componentes, lo cual permitiría una mayor flexibilidad en la gestión de actualizaciones, pruebas unitarias y adaptaciones específicas según el contexto de aplicación, y; se sugiere la incorporación de métricas geométricas y de causalidad como parte del esquema de evaluación del modelo, con el fin de enriquecer el análisis estructural de los datos y fortalecer la capacidad explicativa del sistema frente a fenómenos complejos y no lineales.

En los estudios, investigaciones y actualizaciones legales que se han realizado en materia tributaria y financiera, sin bien han demostrado avances, no obstante, existen oportunidades de mejora en el campo de inversión bursátil, a continuación se expone los antecedentes de la investigación:

Marco Regulatorio Ecuatoriano

El marco legal en el que se desenvuelve la actividad del trading en el Ecuador se contextualiza o se configura en 4 normativas: 1) El Código Orgánico Monetario Financiero – Libro II - Ley de Mercado de Valores (2014) y su reglamento, 2) la Ley orgánica de Comercio Electrónico, Firmas y Mensajes de Datos (2002), 3) El Código Tributario (2005), si bien, estas normas no regulan en sentido amplio la actividad del trading a nivel internacional, sin embargo, para activos financieros que cotizan dentro de la bolsa de valores de Quito y Guayaquil esta actividad parece estar regulada; importante mencionar, que dentro Ecuador existen pocas plataformas locales de trading que brinden este servicio, y es que, a manera de comparación, no es igual comprar un activo financiero en la bolsa de New York o de Londres, a la de Guayaquil o Quito, pues en la bolsa de valores de Ecuador no existen tantos compradores y vendedores, lo que le hace menos atractivo al mercado local, para actividades con rendimientos corto plazistas; lo contrario podría pasar con el inversionista de largo plazo, cuyo objetivo es encontrar rendimientos en tiempos más prolongados. En el año 2022 la Asamblea Nacional de Ecuador aprueba 4) la Ley Orgánica para el Desarrollo, Regulación y control de los Servicios Financieros Tecnológicos o también llamada la Ley Fintech, en el art 3 y 5 de la normativa establecen el ámbito de aplicación, los cuales son:

- “... i) Infraestructuras tecnológicas para canalizar medios de pago;
- ii) Servicios financieros tecnológicos;
- iii) Sociedades especializadas de depósitos y pagos electrónicos;
- iv) Servicios tecnológicos del mercado de valores; y, (lo resaltado me corresponde)
- v) Servicios tecnológicos de seguros.”

El artículo 8 de la Ley Fintech, establece que las instituciones encargadas del control del cumplimiento de la normativa son: 1) El Banco Central del Ecuador, 2) La Superintendencia de Compañías, Valores y Seguros y 3) La Superintendencia de Bancos o la Superintendencia de Economía Popular y Solidaria en el ámbito de sus competencias; sin embargo, en el artículo 8.7 del Código Orgánico Monetario y Financiero, establece que el control de estas compañías estará a cargo de la Superintendencia de Compañías Valores y Seguros.

En el análisis normativo que realiza Ochoa Castillo, S (2024), manifiesta que, si bien la normativa actual regula la actividad del trading dentro del país, sin embargo esa normativa es local, no existe normativa o regulación alguna para compra-venta de activos financieros en plataformas internacionales en el contexto tributario, la personas que se benefician del trading no pagan impuestos, lo hicieran, si compraran o vendieran activos financieros en la plataformas o con brokers locales, es decir, realizar trading es una actividad que no está prohibida, sin embargo, no existe regulación en materia tributaria; sin embargo, para las plataformas que ofrecen servicios financieros dentro del mercado de valores local si los hay, no existen tributos para los traders que compran o venden con brokers o plataformas internacionales, a más de impuestos por salida de divisas (ISD) que no representa un impuesto directo a la beneficios del trading, y es que regular esta actividad será un desafío para el sistema tributario ecuatoriano.

Sustento Teórico

Métodos Lineales

Por su fácil interpretación, tienen ventaja sobre otros modelos, por ejemplo, los modelos ARIMA o ARIMAX, con la entrada en los años 90 con los modelos ARCH y Garch se da más importancia a la volatilidad de los datos, sin embargo, es frecuente que los

errores estimados tengan exceso de curtosis. (Frances y Ghijsels. 1999, citado por Garcia, M y et al. 2013.)

Metodos no Lineales

Es conocido que el precio de los activos financieros se mueve de forma no lineal, lo cual, algunos autores lo califican de métodos más efectivos para predicción, entre estos están: las Redes Neuronales Artificiales que tienen la facultad de capturar las relaciones no lineales entre los valores de entrada y salida. Zemke, 1999. (citado por Garcia, M y et al. 2013.), plantea que los mercados con menor número de operaciones, son más fáciles de predecir, utiliza técnicas de Aprendizaje Automático para predecir el valor del índice WIG a través de decisiones binarias, las cuatro técnicas que utiliza son: predicción con redes neuronales, clasificador bayesiano, K-nearest neighbor y K-nearest neighbor prediction scrutinized, en su estudio concluyo que mediante la técnica K-nearest neighbor y redes neuronales, con 64% de efectividad, se tienen mejores predicciones, debido a que la bolsa de valores está dominada a su relaciones no lineales de los datos. Por su parte Lu, Chang, Chen y Lee, 2009. (citado por García, M y et al. 2013.), realizan la predicción del índice B-Share de la bolsa de valores de Shanghai utilizando las metodologías MARS (multivariate adaptative regression splines), BPN (backpropagation neural network), SVR (support vector regression) y MLR (multiple linear regression), en el estudio se concluyó que el Modelo MARS es el que arroja mejores predicciones en termino de error y precisión que los demás, con un porcentaje de error del 1.5% y precisión del 82%. En otro estudio Gurasen, Kayakutlu y Daim, 2011. (citado por Garcia, M y et al. 2013.), compara 3 modelos para conocer su efectividad, estos son: el multi-layer perceptrón (MLP), el Dynamic artificial neural network (DNA2) y un modelo hibrido de redes neuronales y Garch, los modelos se evaluaron con el error al cuadrado medio y la desviación absoluta media, y concluyo que el modelo que arroja mejores resultados es el modelo clásico MLP.

Modelos Híbridos

Estos modelos como su nombre lo indica, combinan diferentes técnicas, lineales y no lineales. En un Estudio realizado por Wang, Wang Zhang Guo, 2012. (citado por Garcia, M y et al. 2013.), presenta un modelo hibrido (PHM), que es una combinación de los modelos Arima, exponential smoothing model (ESM) y BPNN, que captura la relaciones lineales y no lineales en una serie de tiempo, se utilizó los datos mensuales de los índices SZII de China y el Dow Jones Industrial Average Index (DJIAI-USA), lo resultados demostraron que con el modelo hibrido PHM entrega mejores salidas en términos de error y precisión que otros modelos como ARIMA, ESM Y BPNN, debido a su robustez. Otro estudio realizado por Dai, Wu y Lu (2012) y que llama la atención debido a los resultados alcanzados en la predicción del índice Nikkei 225 y Shanghai B-share, ya que presenta precisiones mayores al 80%, plantearon un modelo de predicción de series de tiempo mediante la combinación de análisis no lineales de componentes independientes y redes neuronales, sus resultados fueron fantásticos, no solo mejora la precisión de la predicción del enfoque de redes neuronales, si no, que supera los 3 métodos de comparación. Valer, S. (2023) realiza un estudio para predecir el precio de 4 activos financieros (TESLA, S&P500, Bitcoin y Petróleo), utiliza 3 metodologías: 1. Regresión Lineal, 2. Máquinas de vector soporte para la regresión (SVR) y Redes Neuronales (LSTM y GRU), los resultados muestran que ninguno de los modelos arrojan un rendimiento sobresaliente en términos de R^2 al tratar de predecir la serie completa en días, sin embargo si se reduce a la mitad el periodo de predicción, las tendencias resultan predecibles en incluso se puede llegar a obtener precios exactos, de los 3 modelos los de

mejores predicciones, son los basados en redes neuronales. Tinoco-Figueroa, S. (2024), en su estudio “Machine Learning en Mercados Financieros”, presenta un modelo de predicción de precios basado en la “Distancia de Lorentz” y el uso del algoritmo “Vecinos más cercanos Aproximados” para ejercer actividades de trading, es decir, inversiones a corto plazo, aplicado al par de divisas BCH/USD, los resultados muestran una tasa de éxito del 92,86%.

Modelos de Predicción con variables Macroeconómicas

Existen algunos estudios, que demuestran la significancia de los activos financieros con variables macroeconómicas, como la tasa de inflación, la tasa de interés, el precio del dólar, el PIB entre otros. Kwon y Shin (citado por García, M y et al. 2013.) en su estudio en base a una prueba de cointegración y otra de causalidad de Granger, encuentra que los índices bursátiles están cointegrados con un conjunto de variables macroeconómicas: índice de producción, tipo de cambio, balanza comercial y la oferta monetaria, que ofrecen relación directa de equilibrio a largo plazo con cada Índice Bursatil; así mismo, Caldas y Pires (citado por García, M y et al. 2013.) evidenciaron a través del uso de variables macroeconómicas como el riesgo país y el principal índice de mercado Brasileño (Ibovespa), con las técnicas econométricas de Mínimos Cuadrados Ordinarios (MCO) y del Método de Generalización de Momentos (GMM), demostraron que la política monetaria, la gestión de la deuda pública, la credibilidad y la reputación, afectan al riesgo país y el desempeño del mercado de valores brasileño.

Selección de Metodología a utilizar

Debido a que se eligió un proyecto de intervención, se procede a explicar las características del modelo teórico con el que se desarrollara la propuesta. A continuación, se describen las características del método de Tinoco-Figueroa, S. (2024), el cual es la base para desarrollar el proyecto que se plantea.

El método que se utilizará es con base a la metodología propuesta por Tinoco-Figueroa, S. (2024), en el que al modelo de predicción el activo financiero BCH/USD incorporó 2 algoritmos, el primero llamado la “distancia de Lorentz” y el segundo “Vecinos más cercanos aproximados”. Desde la ciencia de datos, la distancia de lorentz se utiliza como una medida de similitud en conjunto de datos multidimensionales y la de vecinos cercanos más aproximados identifica puntos similares en un espacio multidimensional y captura esos puntos para predecir los movimientos; esto ha sido probado en su estudio y ha dado buenos resultados, una tasa de éxito del 92,86%, y con un ratio Sharpe de 0,13; lo que pretende realizar el presente estudio es incluir a dicho método Redes Neuronales Recurrentes para mejorar la capacidad de predicción y los retornos esperados con relación al riesgo asumido, pues conocemos que según la teoría la aplicación de Redes Neuronales Recurrente ha mejorado la capacidad de predicción en datos financieros como los estudios de Zemke, (1999), Dai, Wu y Lu (2012), Valer, S. (2023).

Método

Metodología para la recolección y tratamiento de la información

La metodología que se utilizó para la recolección y tratamiento de datos se basa en la metodología utilizada por Tinoco-Figueroa (2024), la diferencia radica en las herramientas usadas para el tratamiento de la información, el entorno en el que se desarrolló el estudio de Tinoco-Figueroa (2024), fue en Google Colab y la obtención de

datos en Alpaca Markets, en el presente estudio se utilizó la herramienta VSCODE con el intérprete Python 3.11.3(.venv) y se obtuvo la información del bróker MetaTrader5, no se utiliza el mismo entorno y proveedor de datos, debido a que, el proveedor Alpaca Markets no cotiza el par de divisas EUR/USD, es un proveedor que oferta únicamente par de divisas con criptomonedas. Posterior se ordenó la información en un Data Frame con las siguientes variables:

- Open = precio de apertura
- High = precio más alto del día
- Low = precio más bajo del día
- Close = precio de cierre
- tick_volume = volumen de transacciones

Los datos se obtienen en tiempo real, con una temporalidad de 60 días, con un intervalo de tiempo de 15 minutos, aquí es importante mencionar que, para la obtención de datos en tiempo real, fue necesario trabajar simultáneamente con el aplicativo abierto de MetaTrader5 y VSCODE, de tal forma, que permite enlazar los terminales para su conexión y obtención de datos.

El algoritmo clave del presente estudio es la distancia de Lorenz, para esto se instaló la librería *advanced_ta* que es una librería para análisis técnico avanzado, una vez importado el módulo se utilizó la función “*LorentzianClassification*”, que permitió obtener la distancia Lorentziana (espacio – tiempo en relatividad), se calculó indicadores técnicos y ordenó en el data frame, estos indicadores son:

- RSI = Mide Fuerza del Movimiento
- WT = Indicador de momentum
- CCI = Detecta sobrecompra/sobreventa
- ADX = Mide fuerza de tendencia
- SMA = Promedio móvil simple


Por otra parte, se utilizó la función *neighborsCount*, con el cual el modelo buscó patrones históricos similares al patrón actual de las ultimas 4130 velas, es decir esta función permitió una clasificación basada en vecinos más cercanos aproximados, detectar patrones repetitivos en el mercado, generar señales de trading basadas en comportamiento histórico y evitar el ruido de los datos.

Diagrama Conceptual del Sistema

El diagrama presentado ilustra la arquitectura modular del sistema de predicción, abarcando desde la fase de adquisición de datos hasta los procesos de modelado, inferencia y evaluación de rendimiento. Esta representación esquemática sintetiza de forma estructurada las funcionalidades operativas del sistema, evidenciando la integración secuencial de componentes analíticos, clasificatorios y predictivos.

Figura 1

Diagrama Conceptual del Sistema



El diagrama presentado ilustra la arquitectura modular del sistema de predicción, abarcando desde la fase de adquisición de datos hasta los procesos de modelado, inferencia y evaluación de rendimiento. Esta representación esquemática sintetiza de forma estructurada las funcionalidades operativas del sistema, evidenciando la integración secuencial de componentes analíticos, clasificatorios y predictivos.

Paso 1

Se instaló en el terminal de VSCODE e importó los siguientes módulos:

Matplotlib.dates: Manejo de fechas en gráficos de tiempo.

Mplfinance: Librería especializada en gráficos financieros tipo velas.

Chain: Permite concatenar múltiples iterables de forma eficiente.

Warnings: Controla o suprime advertencias durante la ejecución.

Datetime, timedelta, date: Manipulación de fechas y tiempos, útil para series temporales.

MetaTrader5: API oficial para conectarse a la plataforma de trading MetaTrader 5. Permite descargar datos de mercado, enviar órdenes, etc.

Pandas: Manipulación de datos en estructuras tipo DataFrame.

Pandas_ta: Extensión de pandas para aplicar indicadores técnicos como RSI, SMA, MACD, etc.

Numpy: Cálculo numérico eficiente, especialmente con arrays.

Matplotlib.pyplot: Visualización de datos en gráficos.

Pytz: Manejo de zonas horarias, útil para sincronizar datos de mercado.

Advanced_ta.LorentzianClassification: Implementa un clasificador basado en funciones de Lorentz, útil para detectar patrones o anomalías en series temporales.

MinMaxScaler: Escala los datos entre 0 y 1, necesario para redes neuronales.

Sequential, LSTM, Dense: Componentes de Keras para construir redes neuronales, en este caso una red LSTM (Long Short-Term Memory), ideal para modelar series temporales como precios financieros.

Mean_squared_error, mean_absolute_error, r2_score: Métricas para evaluar el rendimiento del modelo.

Math: Funciones matemáticas estándar (logaritmos, raíces, etc.).

Para lograr la conexión con MetaTrader5 desde VSCODE, fue necesario crear una cuenta demo en el aplicativo, y mantener sesión iniciada para que VSCODE pueda conectar, esto debido a que, MetaTrader5 no gestiona credenciales por si sola y necesita que el terminal de MT5 está abierto y logeado con una cuenta activa.

Se creó listas, que permitan almacenar los resultados e incluirlos en el DataFrame, con el objetivo de evaluar las simulaciones en el testeo previo y verificar los resultados en la predicción, las listas son las siguientes:

total_trades_list = Número Total de Operaciones

winning_trades_list = Numero de Operaciones Ganadas

lost_trades_list = Numero de Operaciones Perdidas

win_rate_list = Porcentajes de Numero de Operaciones Ganadas / Numero de Operaciones Perdidas

pips_acum_list = Acumulacion de Pips ganados o perdidos por estrategia

real_pips_acum_list = Similar a pips_acum_list pero ajustado por costos reales

j_values = Parametro

sharpe_ratio_list = Mide rendimiento ajustado del riesgo

Descarga y Preparación de Datos: Se descargó los datos del bróker metatrader5 y se preparó en un DataFrame.

Paso 2

En base a los 3 algoritmos establecidos se creó un sistema de predicción, lo cual, se explica de la siguiente forma:

Normalización Min-Max: Se realizo la normalización de los datos en una escala entre 0 y 1, esto evita que variable con valores grandes dominen el modelo.

Indexación Temporal: Se organizo los datos según el tiempo, asignando marcas temporales.

Reordenamiento de columnas: Se ordena las columnas, según el siguiente orden: open, high, low, close, tick_volume.

Paso 3

Creación de bucle sobre valores de j: Dentro del bucle principal se implementó el sistema de predicción, en el que el parámetro "j", cambiara en intervalos de 1, para simular la efectividad de la estrategia.

Clasificación Loretziana: Se aplica un clasificador basado en la distancia de Lorentz, que utiliza indicadores técnicos como el RSI, WT, CCI, ADX y SMA como features, así mismo, se configuran filtros de volatilidad, régimen de mercado y suavizado de Kernel, el objetivo es detectar señales de entrada (posición larga o posición corta)

Paso 4

Vecinos más cercanos Aproximados: Dentro del clasificador Lorentziano se utilizó la función neighbors=2, este parámetro controla la suavidad y sensibilidad del modelo, con el numero 2 se busca un equilibrio entre precisión y generalización, comparando cada punto con sus 2 vecinos más cercanos en el espacio Lorentziano.

Paso 5

Normalización y Modelado LSTM: Se normaliza los precios de cierre para modelar la dinámica temporal del precio y se crean secuencias para entrenar la red neuronal LSTM, que predecirá el próximo valor de cierre, entre más simulaciones tenga el modelo, mejor entrenado estará.

Construcción de trades: Se crea un DataFrame para registrar cada señal detectada

Evaluación de Señales: Se compara cada señal para determinar si fue ganadora o perdedora

Cálculos de Pips acumulados: Se suman los pips obtenidos para cada operación del mismo tipo, esto permite evaluar la rentabilidad acumulada.

Entrenamiento del modelo: Se ajustan parámetros internos, para que las predicciones del modelo se acerquen lo más posible a los valores reales, proceso de aprendizaje de la red neuronal.

Paso 6

Visualización final: Una vez que se ha simulado el modelo con 200 valores de j (parámetro), se evalúa el sistema de predicción desde el punto de vista estadístico y financiero, para conocer su robustez y rentabilidad.

A continuación, se exponen los indicadores, que servirán para evaluar el modelo:

- Error cuadrático medio (MSE): Se espera un valor cerca de 0, pues eso nos dirá que el modelo predecirá muy cerca de los valores reales.
- Error de Raíz cuadrada Media (RMSE): Se espera un valor cerca de 0, pues es nos dirá que el modelo predice con precisión
- Error Absoluto Medio (MAE): Se espera un valor cercano a 0, esto confirmara la idea de que el modelo predice por los menos muy cerca a los valores reales.
- Coeficiente de Determinación (R^2): Se espera un valor cercano a 1, pues nos dirá que el modelo captura bien la estructura del mercado, es decir los algoritmos están entendiendo de manera precisa la dinámica del activo financiero.
- Tasa de Éxito: Se espera una tasa mayor al 85%, esta quiere decir que de cada 10 operaciones ejecutadas 8,5 son exitosas, si bien la tasa de éxito en el estudio de Tinoco-Figueroa S. (2024), fue de 92,86%, una tasa mayor al 85%, es una tasa muy aceptable, sin embargo, se intentará, mejorar la tasa de mencionado estudio.
- Ratio de Sharpe: Se espera una tasa mayor al 0,5%, esto nos indicará una rentabilidad aceptable con respecto al riesgo asumido, el ratio de sharpe en el estudio de Tinoco-Figueroa S. (2024), fue de 0,13%, si bien se califica de una tasa aceptable por el número de pips acumulados, sin embargo, se intentará mejorar la tasa.
- Pips Acumulados: Se espera pips positivos, pues esto nos dirá que la estrategia está siendo rentable.
- Pips Acumulados Reales: A diferencia de los pips acumulados, se toma en cuenta los costos reales de cada operación, al igual, se espera pips positivos.

Resultados

Resultados del Levantamiento de Información

Con una temporalidad hasta de 60 días, se obtienen 4223 velas (la Tabla 1 muestra las primeras 5 velas), las cuales tienen 8 columnas. La variable “time” aparece en formato UNIX timestamp, y se consigue de los datos más actuales al momento de realizar la ejecución del Código.

Tabla 1


Data Frame a 15 minutos por 60 días

(4223, 8)								
No Vela	time	open	high	low	close	tick_volum e	sprea d	real_volum e
0	175495680	116.06	116.12	116.06	116.11			
	0	8	3	7	4	20	51	0
1	175495770	116.11	116.11	116.10	116.11			
	0	4	8	0	4	90	45	0
2	175495860	116.11	116.13	116.10	116.12			
	0	4	0	5	7	249	30	0
3	175495950	116.12	116.14	116.10	116.14			
	0	7	9	9	0	179	29	0
4	175496040	116.13	116.18	116.12	116.14			
	0	9	2	2	1	553	8	0

Como se observa en la tabla 1 - vela No “0” de la variable “tick volume” es igual a 20, lo cual muestra “baja actividad”, es decir pocos compradores y vendedores, con un spread alto No “51” lo que infiere que en esa vela hubo baja liquidez, es importante mencionar que el spread es la diferencia entre el precio de compra y el precio de venta; observamos que el “real_volume” está en 0, lo que significa que el bróker MetaTrade5 no tiene información de la variable.

Figura 2

Precio de Cierre EUR/USD intervalo 15 minutos por 60 días




La Figura 2 muestra el movimiento del precio de cierre del activo EUR-USD, el cual, presenta valor mínimo - máximo de 1.15463 y 1.18948 respectivamente, es decir, diferencia de 348,5 Pips (Punto porcentual o unidad mínima de variación de precio) durante el periodo de 60 días, dependiendo del tamaño del lote, esto puede considerar una ganancia o pérdida considerable.

Considerando que el par de divisas EUR-USD en condiciones normales, mantiene su estabilidad, sin embargo, dicho par de divisas ha mostrado volatilidad en el mercado, evidenciándose su sensibilidad ante eventos económicos o políticos.


Seguidamente, la Figura 3 muestra el tipo de distribución que sigue el par de divisas EUR-USD, se trata de una distribución normal, esto quiere decir que tiene forma de campana o es aproximadamente simétrica; sugiere que aunque el precio pico más común ha sido alrededor de 1.17000 durante los 60 días, la amplitud del histograma (desde 1.15463 y 1.18948) muestra variaciones significativas, esto respalda la idea de un mercado con volatilidad moderada-alta; sin embargo, su simetría demuestra que los precios fueron relativamente equilibrados, es decir, sin sesgo extremo del tipo de cambio.

Figura 3


Distribución de precios de cierre



En la Figura 4 se observa el nivel de actividad en cada vela, se evidencia que existen momentos donde la actividad supera los 4000 ticks, es decir ha habido más de 4000 operaciones de compra-venta en dicha vela, lo que demuestra alta participación de inversionistas, por el contrario, hay momentos en donde se evidencia baja participación, lo que, puede demostrar consolidación del precio o bajo interés de los inversionistas.

Figura 4*Volumen de ticks por vela a 15 minutos*

Ahora bien, en la Figura 5 se presenta un “Boxplot” o “Diagrama de Caja” con las variables del Dataframe (a excepción de tick_volumen, por la escala de los datos), para visualizar la distribución estadística de los datos, la línea verde muestra la mediana, la caja muestra donde se concentra el 50% de los datos, los bigotes o línea azul la extensión de los datos, y los puntos negros, los datos atípicos u outliers.


Figura 5*Boxplot de precios OHLC*

Se evidencia que existe baja dispersión de los datos, pues la mediana y la caja esta alineada en todas las variables, lo que sugiere simetría y ausencia de ruido fuerte, es decir, comportamiento coherente y estable de los datos, sin embargo, existen datos atípicos lo que indica presencia de movimientos extremos en ciertas velas, lo que demuestra alta volatilidad o rupturas bruscas.

En la figura 6 se muestra la correlación existente entre las variables del DataFrame; las variables “open”, “high”, “low” y “close” están perfectamente correlacionadas entre sí, por el contrario, “tick_volumen”, presenta correlaciones muy bajas con las demás variables, lo que indica que puede haber alta actividad sin grandes movimientos de precio.

Figura 6

Matriz de correlación entre valores



A continuación, se presenta una tabla resumen en donde se determinan los hallazgos claves del análisis efectuado:

Tabla 2

Resumen de Hallazgos Clave por Figura

Grafico	Variable	Hallazgos Clave
Precio de cierre EUR/USD (15 min, 60 días)	Precio de cierre	Valor mínimo (1.15463) – máximo de (1.18948), diferencia de 348,5 Pips durante de 60 días (oportunidad)
Histograma de precios de cierre	Precio de cierre	Mercado con volatilidad moderada-alta, precios relativamente equilibrados
Volumen de ticks por vela (15 min)	Volumen de transacciones	Momentos de alta participacion (4000 ticks por vela), y momentos de baja participacion, lo que, puede demostrar consolidacion del precio

			o bajo interes de los inversionistas (cotización 1,17000).
Boxplot de precios OHLC	Precio de apertura, Precio más alto del día, Precio más bajo del día, Precio de cierre	de	Baja dispersión de los datos, simetría y ausencia de ruido fuerte, sin embargo, existen datos atípicos lo que indica presencia de movimientos extremos en ciertas velas (oportunidad)
Matriz de correlación entre variables	Precio de apertura, Precio más alto del día, Precio más bajo del día, Precio de cierre, Volumen de Transacciones	de	Variables “open”, “high”, “low” y “close” perfectamente correlacionadas entre sí, por el contrario, “tick_volumen”, presenta correlaciones muy bajas, la cantidad de transacciones que se haga en una vela no explica el movimiento del precio.

Conclusiones

De acuerdo a los objetivos planteados, el proyecto ha sido exitoso en cuanto a la robustez estadística, sin embargo, en cuanto a las métricas de rentabilidad a presentado falencias; por la característica del activo financiero empleado para el modelo, según el diagnóstico inicial presentó estabilidad y solo en ciertos momentos volatilidad, por lo que, si bien, el sistema demostró solidez en la capacidad de predicción estadística, pero no fue capaz de capturar los movimientos bruscos del mercado, para generar rentabilidad aceptable en base al riesgo asumido. Al igual que la metodología de Tinoco Figueroa S. (2024), se recogieron los datos históricos de los últimos 60 días, con un intervalo de tiempo de 15 minutos, es decir, se obtuvieron 4223 velas o registros de datos; esta información permitió analizar y entrenar al modelo propuesto, se realizaron 200 simulaciones en el sistema VSCODE con los resultados que se exponen a continuación:

Métricas de Desempeño Estadístico

Error Cuadrático Medio: El resultado obtenido en las 200 simulaciones fue muy bajo o cercano a cero, de 0,0000 esto demuestra que los valores predichos están bastante cerca de los valores reales, es decir, una excelente capacidad predictiva.

Raíz cuadrada del Error Cuadrático Medio: Al igual que el anterior indicador, presento valores muy bajos oscilando en las 200 simulaciones entre los valores de 0,00067 a 0,00096, lo que corrobora lo manifestado, el sistema predice bien en términos estadísticos.

Error Absoluto Medio: Esta métrica que indica cuanto se equivoca el modelo en promedio, obtuvo valores muy cercanos a cero, en las 200 simulaciones oscilan entre 0,00047 y 0,00060, significa que el modelo tiene muy buena capacidad predictiva.

Coeficiente de Determinación R^2 : En las 200 simulaciones presentó valores mayores al 0,98%, lo que significa que el modelo explica el 98% de la varianza, es decir, tiene un excelente ajuste.

Tasa de Éxito: Con 254 operaciones abiertas, se evidencio 226 operaciones ganadas y solamente 28 operaciones perdidas, es decir, una tasa de éxito del 88,98% en la mejor simulación, sin embargo, hay que destacar que en la peor simulación la tasa de éxito no bajo del 87%, lo que, demuestra que la tasa de éxito es muy alta e indica que las predicciones están fuertemente correlacionadas con los valores reales. Si bien la tasa es menor al 92,86% de Tinoco Figueroa S. (2024), sin embargo, es importante destacar que en las 200 simulaciones la tasa de éxito se comportó coherente y estable, bajando en un solo punto porcentual, a diferencia del estudio en mención en donde en una simulación se demuestra una tasa de éxito del 84,62%, es decir disminuye más de 8 puntos porcentuales.

Métricas de Desempeño de Rentabilidad


Pips Acumulados: El valor máximo de los pips acumulados se da en la interacción $j = 2$, con apenas 0,001695 pips, lo cual indica una rentabilidad marginal. Este resultado sugiere que, aunque el modelo puede estar acertando direcciones, la magnitud de los movimientos aprovechados es insuficiente para generar beneficios operativos relevantes.

Pips Acumulados Reales: Los pips acumulados reales presentan un valor negativo de -2.54, lo que evidencia que la estrategia no logra superar los costos operacionales ni compensar el riesgo asumido. Este resultado refuerza la necesidad de revisar los filtros de entrada/salida, el ratio riesgo/beneficio, y la estructura de gestión de operaciones.

Ratio de Sharpe: El Ratio de Sharpe máximo alcanzado es de 0.05 en la interacción $j=2$, un valor muy por debajo del umbral mínimo aceptable (usualmente ≥ 1.0). Esto indica que la estrategia no está generando retornos ajustados al riesgo de manera eficiente, y que el modelo, aunque preciso en predicción, no traduce esa precisión en rentabilidad neta.

Figura 7


Resultados de Estrategia de Trading (Tinoco-Figueroa) + LSTM para diferente valor de j values



La Figura 7 muestra que, a lo largo de las 200 simulaciones realizadas, cada valor del parámetro j genera más de 250 operaciones. Se observa una tendencia consistente: el número de operaciones ganadoras supera las 220, mientras que las operaciones perdedoras se mantienen por debajo de 30. Esto se traduce en una tasa de éxito superior al 87%, lo cual evidencia una alta capacidad de predicción estadística por parte del modelo. No obstante, al analizar métricas de rentabilidad como el Ratio de Sharpe y los Pips Acumulados Reales, se confirma que, a pesar de la precisión direccional, la estrategia no logra traducir esa ventaja en beneficios netos. Esto sugiere que el sistema, aunque eficaz en términos de predicción, no es rentable operativamente, posiblemente debido a factores como el manejo del riesgo, los costos transaccionales o la estructura de salida de las operaciones.

Figura 8

Gráfico de Velas del Activo Financiero EUR/USD durante el periodo 17 de agosto al 15 de octubre 2025



La Figura 8 representa un gráfico de velas con datos de 60 días con un intervalo de 15 minutos, en el cual según la estrategia planteada nos indica: triángulo rojo, existe tendencia bajista es decir el precio cerro mas bajo en la pugna entre compradores y vendedores (señal de venta); del mismo modo, el triángulo verde indica tendencia alcista el precio cerro mas alto (señal de compra).

Discusión

La metodología planteada por Tinoco-Figueroa S. (2024), analizo un activo financiero de alta volatilidad (BTC/USD), al parecer el enfoque planteado captura de mejor forma los cambios de mercado, a diferencia de un activo con mayor estabilidad como el analizado en esta investigación (EUR/USD), que aunque el sistema capturó de buena forma la capacidad de predicción, sin embargo, no capturo información relevante como, cuando entrar o salir de una posición, sería interesante entonces, probar el sistema propuesto con un activo financiero de alta volatilidad

Conforme a los objetivos establecidos en la presente investigación, el modelo propuesto ha demostrado un desempeño estadístico satisfactorio, evidenciado en métricas de ajuste y precisión que validan su capacidad predictiva en términos cuantitativos. No obstante, al evaluar su aplicabilidad práctica en escenarios reales de inversión, se observó que dicho desempeño no se tradujo en una rentabilidad creciente sostenida en el tiempo.

Esta discrepancia sugiere que, si bien el modelo es técnicamente robusto desde una perspectiva estadística, aún presenta limitaciones en su capacidad para generar beneficios económicos tangibles, lo cual plantea la necesidad de futuras mejoras orientadas a optimizar su eficacia financiera

Por lo tanto, los resultados obtenidos en esta investigación evidencian una alta capacidad predictiva del modelo propuesto, aunque limitada rentabilidad operativa. Esta paradoja plantea oportunidades concretas para el desarrollo futuro, tanto en el ámbito

técnico como en el académico. A continuación, se presentan las líneas de trabajo recomendadas:

Propuestas

Optimización Operativa y Modularización

Se propone incluir al diseño de un sistema de validación modular, filtros operativos dinámicos, ajustables por sesión horaria, volumen transaccional y volatilidad. Esta arquitectura permitiría adaptar las señales generadas por el modelo a las condiciones reales del mercado, reduciendo la exposición a escenarios de baja liquidez o alta incertidumbre. Además, se recomienda encapsular la lógica de simulación en funciones reutilizables que faciliten la automatización de pruebas y la exportación de métricas clave.

Integración de Métricas Geométricas y Causalidad

Finalmente, dado el interés en modelos geométricos como la Clasificación por Distancia de Lorentz, Vecinos más cercanos aproximados, se plantea incorporar métricas de curvatura y distorsión temporal para evaluar la estabilidad de las señales en función del comportamiento histórico del activo. Esta integración permitiría construir un marco de causalidad operativa, en el que las decisiones de entrada y salida no solo respondan a patrones estadísticos, sino también a estructuras geométricas del mercado.

Limitaciones

Aunque se logró el cumplimiento de los objetivos planteados, sin embargo, a continuación, se presentan las limitaciones que hubo durante el desarrollo del proyecto: Siguiendo la metodología de Tinoco Figueroa S. el trabajo se realizó con un horizonte temporal de 60 días y con un intervalo de tiempo de 15 minutos, aunque se obtuvieron 4223 velas, lo que pudiera no ser representativo.

Aunque se establecieron filtros de volatilidad, al parecer la metodología planteada por Tinoco-Figueroa S. (2024), captura esa característica de mejor manera para un activo de alta volatilidad, mas no para un activo con mayor estabilidad, por lo que, sería importante establecer un módulo de validación modular que permita activar y desactivar filtros operativos según la sesión, volumen o volatilidad.

Referencias

- Arana, C. (2021). *Redes neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales*. Universidad del Centro de Estudios Macroeconómicos de Argentina (UCEMA), <https://www.econstor.eu/bitstream/10419/238422/1/797.pdf>
- Carbo, S., Ganuza, J.J., Peña, D., & Poncela, P. (2023). *Análisis Financiero y Big Data: Aprendizaje Automático aplicado a la compraventa de criptomonedas*. Universidad Autónoma de Madrid. <https://portalcientifico.uam.es/es/es/ipublic/item/10417406>.
- Código Tributario Interno. (2005), de la Republica del Ecuador. <https://www.gob.ec/regulaciones/codigo-organico-tributario>
- da Silva, R. B. S. (2016). Abordagem histórica da bolsa de valores. *Maiêutica - Estudos Contemporâneos Em Gestão Organizacional*, 4(1). https://publicacao.uniasselvi.com.br/index.php/GESTAO_EaD/article/view/1590

- Enriquez, J. (2022). Regulación en la Ley de Mercados de Valores sobre el Bitcoin, trading y criptomonedas, frente al derecho de seguridad jurídica. <https://dspace.uniandes.edu.ec/handle/123456789/14496>
- Fresneda, N. (2023), *Iniciación al Trading*. Universidad Miguel Hernandez de ELCHE. <https://dspace.umh.es/bitstream/11000/29734/1/TFG-Fresneda%20Campoy%2c%20Naiara.pdf>
- Garcia, M., Jalal, A., Garzon, L., & López, J. (2013). Métodos para predecir índices bursátiles. *Ecos De Economía*. http://www.scielo.org.co/scielo.php?pid=S1657-42062013000200003&script=sci_arttext
- Código Orgánico Monetario Financiero – Libro II - Ley de Mercado de Valores. (2014), de la Republica del Ecuador. <https://www.cosede.gob.ec/wp-content/uploads/2019/08/LEY-MERCADO-VALORES.pdf>
- Ley orgánica de Comercio Electrónico, Firmas y Mensajes de Datos. (2002), de la Republica del Ecuador. <https://www.telecomunicaciones.gob.ec/wp-content/uploads/downloads/2012/11/Ley-de-Comercio-Electronico-Firmas-y-Mensajes-de-Datos.pdf>
- Ley Orgánica para el Desarrollo, Regulación y control de los Servicios Financieros Tecnológicos - Ley Fintech. (2022), de la Republica del Ecuador. https://www.telecomunicaciones.gob.ec/wpcontent/uploads/2023/01/RO_221_222_0215S2.pdf
- Maldonado, P. (2025), El milenial que hace dinero con derivados bancarios. *Revista Forbes Ecuador*, 7. <https://www.forbes.com.ec/money/el-milenial-hace-dinero-derivados-bancarios-n70729>
- Naranjo, K., & Gonzalez, G. (2022). El efecto de las emociones en las operaciones de trading de criptomonedas. <https://sophia.ugca.edu.co/index.php/contexto/article/view/1368/1791>.
- Ochoa Castillo, M (2024) La regularización del trading como actividad económica y su incidencia en el sistema tributario ecuatoriano. [Tesis de Pregrado, Universidad Nacional de Chimborazo, Riobamba]. <https://dspace.unach.edu.ec/handle/51000/12591>
- Pineda, C. (2022). *Aprendizaje automático y profundo en Python*. Ra-Ma Editorial.
- Schurmann, N. (2024), *Ultimate Python – Un libro para principiantes fácil de seguir*.
- Serrano Ruiz, F. (2024). *Day trading y operativa bursátil para dummies*. Ediciones HOEPLI.
- Soluciones Coherentes, Inc. (2025), El papel de la IA en el modelado y la previsión financiera. <https://www-coherentsolutions-com.translate.goog/insights/ai-in-financial-modeling-and-forecasting? x tr sl=en& x tr tl=es& x tr hl=es& x tr pto=tc>
- Tinoco-Figueroa, S. (2024). Machine learning en mercados financieros: generando predicciones mediante la clasificación lorentziana y vecinos más cercanos aproximados. [Trabajo de obtención de grado, Tlaquepaque, Jalisco: ITESO.]. <https://hdl.handle.net/11117/11403>
- Valer, S. (2023). *Predicción precios de Activos Financieros Empleando Aprendizaje Automático*. Universidad de Catabria. <https://repositorio.unican.es/xmlui/handle/10902/30241>