



FINGUACH

Año 3 · Número 4 · Enero - Junio 2022

Universidad Autónoma de Chihuahua
Facultad de Ingeniería

E-ISSN: 2683-3387

<https://vocero.uach.mx/index.php/finguach>



UACH
UNIVERSIDAD AUTÓNOMA DE
CHIHUAHUA

Dr. Jesús Villalobos Jión
Rector

M.E.A. Alfredo Ramón Urbina Valenzuela
Director de Investigación y Posgrado

Lic. Gustavo Macedo Pérez
Director de Extensión y Difusión Cultural

M.I. Javier González Cantú
Director de la Facultad de Ingeniería



La revista FINGUACH, año 3, No. 4, Enero-Junio 2022, es una publicación semestral editada por la Universidad Autónoma de Chihuahua, calle Escorza 900, Col. Centro, Chihuahua, Chih., C.P. 31000, Tel. (614) 442-9500 ext 2545, <https://vocero.uach.mx/index.php/finguach>. Editor responsable: Javier González Cantú. Reserva de Derechos al Uso Exclusivo No. 04-2020-042310492700-203, E-ISSN: En trámite, otorgados por el Instituto Nacional del Derecho de Autor.

Responsable de la última actualización de este Número, Javier González Cantú, Editor, Circuito No. 1, Campus Universitario II, Chihuahua, Chih., C.P. 31125, el día 25 de febrero de 2022. Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación. Queda prohibida la reproducción total o parcial de los contenidos e imágenes de la publicación sin previa autorización de la Universidad Autónoma de Chihuahua.



latindex

Contenido

Carta del Editor	2
Prediciendo el Mercado de las Criptomonedas utilizando Aprendizaje Profundo	3

Comite Editorial

M.I. Javier González Cantú
Editor en jefe

M.I. David Maloof Flores
Editor

Dr. José Luis Herrera Aguilar
Editor

Dr. Alejandro Villalobos Aragón
Editor

M.I. Jesús Roberto López Santillán
Editor

Dr. Luis Carlos González Gurrola
Editor

M.A. Luis Carlos González Martínez
Editor

M.E.S. Irma Liz Piñón Carmona
Editora





Carta del editor

La revista FINGUACH ha transitado a la distribución electrónica, buscando que cuente con Números Internacionales Normalizados de Publicaciones Seriadas (Printed ISSN y Electronic ISSN), otorgando una oportunidad para facilitar la distribución electrónica de futuras publicaciones, y abriendo puertas para ingresar a distintos sistemas de indización.

Asimismo, el Comité Editorial de FINGUACH continúa replanteando estrategias para asegurar la calidad, y mejorar la visibilidad e impacto de la revista. Esta actualización abarca esencialmente el proceso de arbitraje con revisión por pares doble ciego, en una modalidad de publicación continua (semestral, enero y julio) y, de igual manera, buscamos ampliar la base de datos de revisores (nacionales e internacionales). Trabajaremos a fin de asegurar la calidad y ética de las publicaciones con acciones que nos permitan lograr los más elevados índices.

Agradecemos a los autores que participan en cada número, a los lectores y al equipo de trabajo de la revista. En esta ocasión este espacio servirá de agradecimiento a Noel Chaparro, por compartirnos el artículo “Prediciendo el Mercado de las Criptomonedas utilizando Aprendizaje Profundo”.

Javier González Cantú
Editor



Prediciendo el Mercado de las Criptomonedas utilizando Aprendizaje Profundo

Noel Chaparro Portillo¹, Roberto López Santillán, Manuel Montes y Gómez

Dentro del mundo de las finanzas, uno de los temas con mayor interés es el de la correcta predicción de los mercados financieros. Sin embargo, hasta no hace mucho tiempo, la mayor parte de la población en México nunca había tenido contacto con ningún tipo de mercado financiero. Esto ha venido cambiando con el surgimiento de las criptomonedas, también llamadas criptodivisas, las cuales son monedas virtuales basadas en la tecnología blockchain [1]. La popularidad alcanzada por algunos criptoactivos como Bitcoin, Ethereum, Dogecoin, etc., y los bajos requerimientos para invertir en criptomonedas han hecho que una gran parte de la población mundial (incluyendo México) hayan invertido a raíz de esto.

En los mercados, el objetivo es simple: obtener una ganancia. Hay quienes prefieren invertir a largo plazo con la expectativa de que sus activos aumenten de valor, y hay quienes prefieren tomar el control y buscar camino por sí mismos comprando y vendiendo en los momentos más oportunos, es decir, haciendo trading.

Lo anterior se puede lograr siguiendo una regla muy simple, comprar barato y vender caro. Sin embargo, por simple que parezca, la mayor parte de las personas fracasan en el intento. Existen demasiados factores en la ecuación además de esta simple regla, y uno de ellos es la parte emocional, la cual, en la mayoría de los casos termina por jugar en contra del inversor promedio.

Es por esto (y algunos otros factores) que poco a poco hemos delegado la parte emocional a las máquinas, es decir, hacer trading de forma automática sin la intervención de un humano. Para lograr esto, una máquina puede ser programada de forma explícita para seguir ciertas reglas, o bien explotar ramas de la inteligencia artificial como lo es el aprendizaje automático para capturar los patrones más complejos en la información. Una de las fuentes más ricas de información es precisamente la generada por los mercados financieros, particularmente la del mercado de criptomonedas, ya que opera las 24 horas del día, los 365 días del año.

En este artículo hablaremos sobre el trabajo realizado en torno a la predicción de la dirección del precio de Bitcoin, la cual, hoy en día, es la criptomoneda más popular y con la capitalización de mercado más grande.

Como ya hemos mencionado, el mercado de las criptomonedas es una maquina continua de generar información. El nivel más granular de información que podemos tener es el que se obtiene a partir de almacenar cada una de las interacciones (abrir, cerrar, cancelar, modificar una orden de compra o venta) realizadas por cada uno de los participantes del mercado en un determinado periodo de tiempo. Este es precisamente el nivel de detalle en los datos utilizados en este trabajo, dicha información, comprende el periodo del 25 de agosto al 25 de octubre del 2021. Esto nos permitió recrear las condiciones del mercado durante este tiempo y así entrenar modelos de aprendizaje automático (particularmente de aprendizaje profundo) para predecir la dirección del precio de Bitcoin.

El utilizar esta información tan granular, nos permitió introducirnos en los dominios del High Frequency Trading (HFT), es decir, el trading que se realiza con una frecuencia muy alta, cuya principal característica es la de utilizar la velocidad y baja latencia como una ventaja competitiva contra el resto de los participantes. Bajo este paradigma de trading, los horizontes de inversión son normalmente solo fracciones de segundo.

Existen relativamente pocos trabajos publicados que utilicen datos de alta frecuencia en combinación con técnicas de aprendizaje automático. Uno de los primeros presentados fue el de Kercheval y Zhang en [2], quienes propusieron una metodología para capturar la dinámica de alta frecuencia del mercado para así realizar predicciones en tiempo real por medio de una máquina de vectores de soporte (SVM por sus siglas en inglés), con un enfoque en horizontes a muy corto plazo.

El trabajo realizado por Tsantekidis en [3], utilizó modelos secuenciales como lo es el Long Short-Term Memory (LSTM) para explotar de mejor manera la naturaleza secuencial de la información. Por otro lado, en [4], los autores proponen el uso de redes neuronales convolucionales (CNN por sus siglas en inglés) para extraer patrones en la información de forma automática.

Trabajos anteriores han utilizado técnicas estándar de preprocesamiento y normalización de datos, que generalmente se utilizan en la mayoría de las aplicaciones de aprendizaje automático. Nuestro trabajo propone un nuevo enfoque de preparación de datos que permita obtener mejores resultados en la tarea de predicción de la dirección del Bitcoin.

La **Figura 1** muestra un resumen de la metodología utilizada en nuestra investigación.

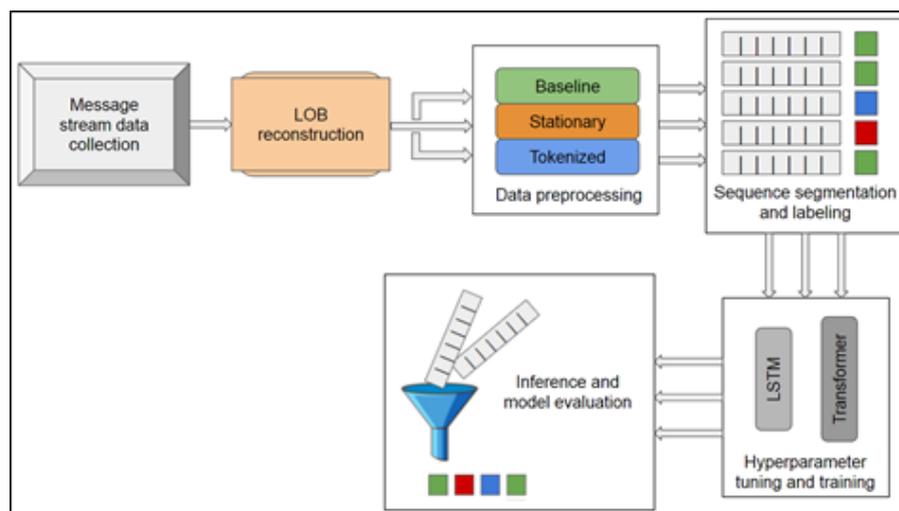


Figura 1 - Descripción general de la metodología

Como se mencionó anteriormente, la información en crudo fue utilizada para recrear el estado del mercado durante este tiempo. Con esto, se crearon tres diferentes representaciones de la información para alimentar nuestros modelos. Dichas representaciones son Baseline, la cual fue creada utilizando técnicas de preprocesamiento comúnmente utilizadas. Y dos representaciones más, Stationary, la cual modela la información de tal forma que el resultado de la representación es invariante al precio del Bitcoin, y Tokenized, cuya idea se basa en reducir el número de estados posibles del mercado al representarlos por medio de un token, y a partir de ellos utilizar técnicas de procesamiento de lenguaje natural (NLP por sus siglas en inglés) como lo es el uso de Word Embeddings.

La información se preparó entonces de tal forma que el problema se formuló como un problema de clasificación, es decir, solo tres posibles resultados se pueden predecir: Up, Down o Stationary, es decir el mercado sube, baja o se mantiene estable en cierto rango.

Se utilizaron modelos cuya naturaleza es secuencial como es el caso del LSTM y de los Transformers, estos últimos, considerados el estado del arte en una gran cantidad de tareas en las áreas de NLP y de visión artificial.

Los mejores resultados observados fueron los obtenidos al utilizar un modelo LSTM en combinación con la representación de los datos Stationary (una de las representaciones propuestas), y un horizonte de predicción de 20 eventos futuros (aprox. 0.1 segundos).

Los resultados se muestran a continuación en la Tabla 1.

Input Data	Model	Accuracy	Precision	Recall	F1-Score
Baseline	LSTM	80.10	73.60	75.08	74.28
	Transformer	74.26	66.43	66.95	66.63
Stationary	LSTM	84.07	78.93	79.49	79.20
	Transformer	81.03	75.61	73.57	74.41
Tokenized (3k Tokens)	LSTM	75.13	66.99	68.45	67.59
	Transformer	73.85	64.71	64.16	64.40
Tokenized (30k Tokens)	LSTM	74.62	66.22	67.61	66.80
	Transformer	73.53	64.39	64.26	64.32
Tokenized (300k Tokens)	LSTM	72.56	63.40	64.58	63.88
	Transformer	73.53	64.39	64.26	61.48

Tabla 1: Resultados experimentales para un horizonte de predicción $k=20$ (eventos).

Las métricas de nuestro mejor modelo fueron comparadas con el resto de los clasificadores por medio de una prueba estadística para así tener mayor certeza en nuestras afirmaciones. Los resultados fueron positivos a un nivel de significancia del 1%. En conclusión, el método aquí propuesto obtiene mejores resultados en comparación con técnicas de preprocesamiento más convencionales para la predicción del mercado de las criptomonedas, en particular para Bitcoin.

Algunas otras comparaciones se hicieron con clasificadores más simples, como lo es el clasificador que siempre predice la clase mayoritaria (en este caso la estacionaria), o bien un clasificador que siempre predice la misma dirección del mercado del periodo anterior. Los resultados muestran una marcada diferencia en comparación al mejor modelo entrenado.

Las implicaciones de estos resultados desafían directamente algunas de las hipótesis existentes en torno a la predictibilidad de los mercados, las cuales establecen que los precios se comportan como un random walk, y que es imposible encontrar patrones en la información histórica que permitan predecir la dirección futura del mercado.

Hoy en día, la predicción de los mercados financieros sigue siendo un problema abierto, sin embargo, el uso de técnicas de reconocimiento de patrones como lo es el aprendizaje automático nos acerca cada vez más a tener una mejor representación de la dinámica existente, y por ende mejores predicciones.

Referencias:

- [1] Zheng, Z., Xie, S., Dai, H.N., Chen, X., Wang, H.: Blockchain challenges and opportunities: A survey. *International Journal of Web and Grid Services* 14(4), 352–375 (2018).
- [2] Kercheval, A.N., Zhang, Y.: Modelling high-frequency limit order book dynamics with support vector machines. *Quantitative Finance* 15(8), 1315–1329 (2015)
- [3] Tsantekidis, A., Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2017, August). Using deep learning to detect price change indications in financial markets.
- [4] Tsantekidis, A., Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2017, July). Forecasting stock prices from the limit order book using convolutional neural networks.