



Vigilada Mineducación

**MODELOS DE PREDICCIÓN ESTOCÁSTICA PARA BITCOIN: UNA  
EVALUACIÓN DE MÉTODOS Y DESEMPEÑO**  
STOCHASTIC PREDICTION MODELS FOR BITCOIN: AN ASSESSMENT OF  
METHODS AND PERFORMANCE

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

Caroline Hernández Hernández  
Juan Sebastián Forero Criollo

Asesor  
Alejandro Cadavid Gil

UNIVERSIDAD EAFIT  
ESCUELA DE ECONOMÍA Y FINANZAS  
MAESTRÍA EN ADMINISTRACIÓN FINANCIERA - MAF  
BOGOTÁ  
2023

## TABLA DE CONTENIDO

RESUMEN.....	5
ABSTRACT.....	6
1. INTRODUCCIÓN.....	7
2. JUSTIFICACIÓN.....	10
3. OBJETIVOS.....	11
3.1 GENERAL.....	11
3.2 ESPECÍFICOS.....	11
4. MARCO TEÓRICO.....	12
4.1 ANTECEDENTES.....	13
4.2 MODELOS TEÓRICOS.....	16
4.2.1 Long Short-Term Memory (LSTM).....	16
4.2.2 Gated Recurrent Unit (GRU).....	17
4.2.3 Support Vector Regression (SVR).....	17
4.2.4 Árboles de decisión.....	18
4.2.5 Random Forest.....	19
4.2.6 XGBoost.....	20
4.3 INDICADORES DE EVALUACIÓN DE MODELOS DE PREDICCIÓN.....	20
4.3.1 Coeficiente de determinación (R cuadrado).....	21
4.3.2 Raíz del error cuadrático medio (RSME).....	22
4.3.3 Error Porcentual Absoluto Medio (MAPE).....	23
4.3.4 Indicador de Concordancia de Lin (CCC).....	24
4.3.5 Explained Variance Score.....	24

5.	DISEÑO METODOLÓGICO .....	26
5.1	Objetivo de la investigación.....	26
5.2	Fuente de datos .....	27
5.3	Preprocesamiento de datos .....	28
5.4	Construcción de modelos .....	29
5.5.	Evaluación de modelos iniciales .....	30
5.6.	Técnicas de optimización.....	30
5.7.	Evaluación de riesgos y limitaciones .....	32
5.8.	Herramientas y <i>software</i> .....	33
5.9.	Plan de análisis estadístico.....	33
5.10.	Cronograma de la investigación .....	33
6.	RESULTADOS .....	34
6.1	RESULTADOS MODELOS SIN OPTIMIZACIONES.....	34
6.1.1	Modelo LSTM .....	34
6.1.2	Modelo GRU .....	35
6.1.3	Modelo SVR.....	37
6.1.4	Modelo arboles de decisión .....	39
6.2	Resultados modelos con optimizaciones.....	45
6.2.1	Modelos GRU .....	48
6.2.2	Modelos Support Vector Regression (SVR).....	49
6.2.3	LSTM modelos.....	50
6.2.4	XGBoost modelos.....	51
6.1.1	Ramdon Forest.....	52
7.	CONCLUSIONES .....	54

REFERENCIAS .....58

## RESUMEN

La investigación se centra en pronosticar los precios del Bitcoin (BTC) mediante modelos estadísticos, incluyendo LSTM, GRU, SVR, árboles de decisión, Random Forest y XGBoost. Evaluamos su rendimiento en términos de R<sup>2</sup>, RSME, MAPE, Indicador de concordancia de Lin (CCC) y Explained Variance Score, métricas que se seleccionaron por su capacidad para evaluar modelos de regresión.

Se utilizaron datos de precios de cierre del BTC (2014-2023), sometidos a un preprocesamiento que incluyó limpieza, optimización e ingeniería de datos. Los modelos, inicialmente sin optimizaciones, se mejoraron mediante ajuste de hiperparámetros y técnicas estadísticas especializadas, como validación cruzada, regularización L1-L2, optimización bayesiana y genética.

Los resultados destacan el XGBoost como el modelo óptimo con la incorporación ajuste iterativo de hiperparámetros, optimización bayesiana y validación cruzada anidada. Este logró valores sobresalientes en todas las métricas evaluadas: RSME de USD 30,45, MAPE de 0,09%, R cuadrado de 1.0, CCC y Explained Variable Score (EVS) de 1.0 en cada caso.

Palabras clave: predicción de precios, Bitcoin, BTC, modelos de series temporales, LSTM.

## ABSTRACT

This research focuses on forecasting Bitcoin (BTC) prices using statistical models, including LSTM, GRU, SVR, decision trees, Random Forest, and XGBoost. We evaluate their performance in terms of R<sup>2</sup>, RSME, MAPE, Lin Concordance Coefficient (CCC), and Explained Variance Score—metrics selected for their ability to assess regression models.

We utilized BTC closing price data from 2014 to 2023, subjected to preprocessing involving cleaning, optimization, and data engineering. The models, initially unoptimized, were enhanced through hyperparameter tuning and specialized statistical techniques such as cross-validation, L1-L2 regularization, Bayesian and genetic optimization.

The results highlight XGBoost as the optimal model with the incorporation of iterative hyperparameter tuning, Bayesian optimization, and nested cross-validation. It achieved outstanding values in all evaluated metrics: RSME of USD 30.45, MAPE of 0.09%, R-squared of 1.0, Lin Concordance Coefficient, and Explained Variance Score of 1.0 in each case.

Keywords: price prediction, Bitcoin, BTC, time series models, LSTM.

## 1. INTRODUCCIÓN

En un entorno económico y financiero con dinamismo y volatilidad, la imperativa capacidad de anticipar las oscilaciones de los activos digitales se erige como una empresa de suma relevancia para inversores, analistas y estudiosos del mercado, especialmente para los inmersos en el contexto de las criptomonedas. En particular, la preeminente criptomoneda, Bitcoin (BTC), se ha visto sometida a notables variaciones en su valor, cuyos matices se ven modelados por una multiplicidad de factores, que abarcan desde acontecimientos geopolíticos hasta los más recientes progresos tecnológicos.

En esta investigación se propone explorar y evaluar modelos de predicción basados en *machine learning* y redes neuronales, aplicados al precio del BTC en el periodo comprendido entre septiembre de 2014 y septiembre de 2023. La elección estratégica de este intervalo temporal, que abarca una fase significativa de la evolución del mercado de criptomonedas, asegura la disponibilidad de datos confiables. Este periodo, caracterizado por momentos de alta volatilidad, experimenta tanto caídas pronunciadas como ascensos destacados, al igual que períodos de tendencia. La incorporación de estos elementos fortalece la robustez de nuestro análisis, permitiéndonos examinar la capacidad predictiva de los modelos en escenarios diversos y desafiantes.

El objetivo principal de este estudio de naturaleza cuantitativa, empírica y experimental es evaluar la eficacia y comparar varios modelos estocásticos, entre ellos Support Vector Regression (SVR), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Random Forest y XGBoost, en la predicción del precio del BTC. Esto permitirá identificar el modelo más eficaz en términos de capacidad predictiva, especialmente en un entorno caracterizado por la volatilidad inherente a los precios de dicha criptomoneda.

La validez y autenticidad de los datos son fundamentales para la fiabilidad de cualquier estudio. En este sentido, se seleccionó un periodo específico respaldado por datos históricos obtenidos de Yahoo Finance, sometidos a un riguroso proceso de limpieza, normalización e ingeniería de características. Estas prácticas aseguran que los datos empleados fueran consistentes y aptos para el análisis de series temporales.

La investigación se apoyó en un diseño metodológico que incluyó la revisión exhaustiva de la literatura para la selección de modelos relevantes. SVR, LSTM, GRU, Random Forest y XGBoost fueron elegidos por su idoneidad en la predicción de series temporales, respaldados por evidencia empírica de su eficacia en investigaciones anteriores.

La fase inicial de nuestra investigación implicó la implementación de estos modelos sin ningún tipo de ajuste, lo cual permite establecer una línea base para comprender su rendimiento intrínseco. La evaluación se realiza a través de indicadores idóneos, como el error cuadrático medio (RMSE), el error porcentual medio absoluto (MAPE), el coeficiente de determinación ( $R^2$ ), el coeficiente de varianza explicada ( $R^2$  ajustado) y el Indicador de concordancia de Lin (CCC). La idoneidad de estos indicadores se justifica por su capacidad para evaluar el desempeño de modelos de regresión, tal como lo señalan Hastie et al. (2019).

Para mejorar el rendimiento de los modelos obtenidos en la evaluación inicial, se aplicaron diversas técnicas de optimización, incluyendo validación cruzada, regularización, *dropout*, ajuste de tasa de aprendizaje, optimización bayesiana, ajuste automático de hiperparámetros, ensamble de modelos, kernel y parámetros C y Gamma, *grid search*, optimización genética, validación cruzada anidada, *random search* y optimización por gradientes. Todo el proceso de implementación y análisis se realizó utilizando el lenguaje de programación Python y diversas bibliotecas de *machine learning*, como TPOT, Scikit-Learn y Tensor Flow.

En las secciones siguientes se presentan los resultados tanto de modelos sin optimizaciones como de aquellos sujetos a técnicas de mejora.

## 2. JUSTIFICACIÓN

La creciente importancia global del BTC, que en 2022 alcanzó una capitalización de mercado de 1,5 billones de dólares, ha suscitado una mayor necesidad de prever con precisión las tendencias de precios de esta criptomoneda (Glaser & Zimmermann, 2022). En respuesta a esta demanda, la presente investigación profundiza en el desarrollo de modelos estocásticos, con el fin de proporcionar herramientas efectivas para predecir el precio del BTC con la mayor exactitud posible.

La conjunción de la volatilidad característica y la adopción masiva del BTC ha generado un creciente interés tanto entre inversores como académicos. La relevancia de este estudio reside en su capacidad para ofrecer herramientas efectivas destinadas a la toma de decisiones financieras, la mitigación de riesgos y la identificación y aprovechamiento de oportunidades en el dinámico mercado de criptomonedas.

Además, esta investigación puede contribuir al avance del conocimiento en el campo de las criptomonedas desde una perspectiva financiera. Al evaluar y comparar modelos estocásticos en la predicción del precio de BTC, se espera identificar enfoques más efectivos que puedan ayudar a los inversores a tomar decisiones informadas en el mercado global de activos digitales. Este estudio también puede proporcionar una base para continuar la investigación de los modelos estocásticos y su aplicación en los futuros estudios en el campo de las criptomonedas y el análisis financiero.

### **3. OBJETIVOS**

#### **3.1 GENERAL**

Evaluar el rendimiento de los modelos estocásticos basados en aprendizaje automático para predecir el precio del BTC.

#### **3.2 ESPECÍFICOS**

- Realizar revisión de la literatura académica y la investigación previa relacionada con la predicción de precios de BTC, con el fin de identificar los modelos estocásticos óptimos en la predicción de los precios del Bitcoin.
- Implementar modelos estocásticos idóneos que permitan realizar pronósticos precisos del precio de BTC para en un marco temporal de un día (Next Day-Close Price).
- Evaluar el desempeño de los modelos estocásticos utilizando indicadores de precisión y eficacia.

#### 4. MARCO TEÓRICO

El BTC emerge como una innovadora criptomoneda que ha redefinido el panorama financiero con su enfoque descentralizado y la aplicación de la tecnología de cadena de bloques. La esencia fundamental del BTC radica en su naturaleza descentralizada, lo que la hace independiente de cualquier gobierno o entidad central. Esto facilita transacciones *peer-to-peer* seguras y transparentes, sin necesidad de intermediarios (Nakamoto, 2009).

El creador anónimo de BTC indica, en su *whitepaper* inicial, que la tecnología de cadena de bloques que soporta la infraestructura de las criptomonedas, permite la verificación distribuida y la inmutabilidad de las transacciones, estableciendo un nuevo paradigma en la forma en que concebimos y participamos en transacciones financieras (Nakamoto, 2009).

A medida que aumenta la adopción, BTC se consolida como moneda digital cuya utilización en transacciones cotidianas evidencia una tendencia creciente. También aumenta el interés en BTC como una clase de activo alternativa, con inversores que buscan diversificar sus carteras con esta nueva y emergente inversión (Antonopoulos, 2014).

La singular volatilidad de BTC añade una dimensión única a su atractivo y a los desafíos que conlleva. Esto se debe a que su volatilidad puede generar impactos materiales, tanto positivos como negativos para los inversores, lo cual hace que la capacidad de predecir sus movimientos sea crucial. Descubrir este pronóstico con la mayor precisión posible se convierte, por tanto, en un factor crítico con implicaciones profundas en las decisiones de inversión. En palabras de Yermack (2015), “la volatilidad del precio del Bitcoin es notable, lo que ofrece oportunidades sustanciales para los inversores, pero también plantea riesgos significativos”.

La dinámica y el comportamiento altamente fluctuante de los precios de BTC no solo impacta a los inversores individuales, sino que también tiene consecuencias a nivel sistémico. En este sentido, la capacidad de anticipar las tendencias del mercado de BTC implica beneficios económicos para los inversores y puede contribuir a la estabilidad del mercado financiero en su conjunto.

#### **4.1 ANTECEDENTES**

En virtud de la influencia que ejercen los precios del BTC en los mercados financieros globales, como lo demuestran los estudios de Wang et al. (2023), se ha generado una extensa literatura académica que busca comprender las complejas dinámicas asociadas con la predicción de sus movimientos. En los últimos años, la volatilidad única del BTC ha despertado creciente interés en el desarrollo de enfoques analíticos que permitan prever sus fluctuaciones con mayor precisión. En este estudio se propone examinar críticamente la eficacia de diversas metodologías como LSTM, arboles de decisión, GRU, SVR, entre otros. Se destaca su amplio uso no solo para predecir criptomonedas, sino también para diferentes tipos de activos financieros.

La predicción de precios en el mercado de criptomonedas se ha convertido en un desafío para inversores y analistas, dada la naturaleza volátil y única de los activos digitales. La literatura académica existente ha explorado diversas metodologías, destacando la utilidad de modelos estocásticos basados en aprendizaje automático y, por tanto, se ha observado la necesidad de evaluar de manera integral el desempeño de tales modelos para mejorar la precisión de las predicciones del precio del BTC.

En un estudio de Khosravi y Ghazani (2022) se propone un proceso de modelización específico para datos de series temporales del mercado financiero. Este incluye seis etapas generales con cuatro pasos de procesamiento. Se aplicaron métodos

novedosos de preprocesamiento de datos, como el método de Triple Barrera (TB) y el método de precisión de disminución media (MDA). Los resultados demostraron un MAPE del 7.7% y un RMSE de USD 3670.24. Este estudio destaca la superioridad de los enfoques de aprendizaje automático sobre métodos tradicionales.

Khurana et al. (2023) utilizaron herramientas de aprendizaje automático como TPOT y AutoSklearn para predecir componentes del precio de BTC en intervalos de 30 minutos, 1 hora y 4 horas. TPOT superó a AutoSklearn en los tres períodos de tiempo, demostrando eficacia en la predicción a corto plazo. Kazeminia et al. (2023) proponen un modelo híbrido 2D-CNNLSTM para predecir el precio de cierre del día siguiente. Este superó a algoritmos comunes como CNN, LSTM y GRU en términos de R2 y MAPE, demostrando eficiencia y capacidad de predicción en tiempo real.

En el marco de un enfoque para la detección de regímenes de mercado, se emplearon modelos ARIMA, LSTM y CNN, según el estudio de Kazeminia et al. (2023). Los resultados revelaron un R cuadrado de 0,98166 y un MAPE del 3,4%, destacando la capacidad de estos modelos para adaptarse a diversas fases del mercado. No obstante, el modelo ARIMA aplicado evidenció resultados menos favorables, con un R cuadrado de 0,78987 y un MAPE promedio del 14,5%.

Siyi Liao (2023) propone un modelo XGBoost que combina indicadores técnicos y técnicas de optimización lineal para predecir el precio de criptomonedas como BTC y Ethereum. Este modelo fue capaz de encontrar un RSME de USD 391,3 y R cuadrado de 0.94.

Aljadani (2022) propone un marco de cinco fases para la predicción del precio de criptomonedas basado en arquitecturas de aprendizaje profundo. Los resultados de la aplicación de este modelo indican que el modelo GRU superó al BiLSTM para BTC, Ethereum y Cardano.

En su estudio, Byzkrovnyi et al. (2022) emplearon análisis de regresión para prever el precio de Ethereum, utilizando los modelos GRU, LSTM y bi-LSTM. La incorporación de modelos de regresión no lineal y la predicción de factores individuales mediante NeuralProphet contribuyeron a mejorar la precisión de las predicciones. Cabe resaltar que los resultados más destacados provinieron del modelo XGboost, mostrando el menor RSME con un valor de USD 295,41.

Saad et al. (2020) investiga las redes de BTC y Ethereum para comprender los factores que afectan sus precios. Sus modelos emplearon enfoques de aprendizaje automático a través de regresión y análisis LSTM para construir modelos de predicción de precios para BTC y Ethereum, con una precisión del 95% de los precios de estas criptomonedas.

Li et al. (2019) investigaron el impacto de las redes neuronales bayesianas en la predicción del precio de BTC. Utilizaron el modelo de redes bayesianas, con una precisión aceptable al prever la potencia informática global a través del precio de BTC. El MAPE obtenido fue de 4%. Concluyen que el modelo SVR presenta resultados deficientes en la fase de entrenamiento y en la de prueba, destacando que el NN bayesiano es más apropiado para analizar series temporales de BTC que el SVR.

Finalmente, Parekh (2022) propone DL-GuesS, un método que utiliza datos multivariados de series temporales en cadena para predecir precios de criptomonedas. Sus resultados destacan la eficacia de este enfoque en la predicción de precios de criptomonedas y obtuvieron un MAPE de 4.79%.

Estos estudios proporcionan una visión integral de los modelos y enfoques utilizados en la predicción del precio de BTC, abordando diferentes perspectivas en el conocimiento actual y destacando la importancia de la aplicación de técnicas de aprendizaje automático en este contexto.

## **4.2 MODELOS TEÓRICOS**

Los modelos de aprendizaje automático, como LSTM, árboles de decisión, GRU y XGBoost, se han convertido en una herramienta importante para la predicción de tendencias de precios de criptomonedas. Estos modelos se basan en patrones identificados a partir de conjuntos de datos históricos y emplean algoritmos para generar predicciones. Según Smith (2023), la eficacia de estos modelos en el contexto de la volatilidad única del BTC es un tema de investigación activo. Con base en estos antecedentes, se seleccionaron los modelos que se exponen a continuación para predicción del precio del BTC mediante cada uno.

### **4.2.1 Long Short-Term Memory (LSTM)**

LSTM es un tipo de red neuronal recurrente (RNN) diseñada para superar el problema de desvanecimiento del gradiente en el entrenamiento de redes a largo plazo (Hochreiter y Schmidhuber, 1997). Este problema ocurre cuando el gradiente de error se vuelve demasiado pequeño para actualizar los pesos de la red de manera efectiva. Las LSTM abordan este problema utilizando una estructura de celda que almacena información relevante a lo largo del tiempo.

La implementación de modelos de aprendizaje automático destaca por su capacidad para gestionar de manera eficaz dependencias a largo plazo y evitar desafíos asociados con el desvanecimiento del gradiente, siendo especialmente apropiados para la interpretación de datos secuenciales, como es el caso de las series temporales en la predicción de precios del BTC. No obstante, como señalan Zhang et al. (2022), es crucial reconocer ciertas limitaciones inherentes a estos enfoques. La mayor complejidad computacional se presenta como un aspecto a considerar, ya que el manejo efectivo de dependencias a largo plazo conlleva una carga de procesamiento más intensiva. Además, la necesidad de una cantidad

significativa de datos para un entrenamiento efectivo constituye otra limitación, lo cual puede resultar en un desafío en entornos donde la disponibilidad de datos es limitada.

#### **4.2.2 Gated Recurrent Unit (GRU)**

El modelo GRU, una variante de las RNN propuesto por Cho et al. (2014), emerge como una herramienta poderosa y eficiente en el contexto de la predicción de precios del BTC. A diferencia de las RNN tradicionales, las GRU presentan una estructura de celda más sencilla que aporta ventajas distintivas y altamente beneficiosas para la tarea de predicción.

En primer lugar, Cho et al. (2014) señala la eficiencia en el entrenamiento de los datos como uno de los rasgos más destacados de las GRU, gracias a su estructura de celda simplificada. Esta característica implica que las GRU pueden lograr resultados notables con menos datos de entrenamiento, lo cual es esencial en un entorno como el mercado de criptomonedas, donde la disponibilidad de datos puede ser un desafío. Además, la estructura simplificada mitiga la susceptibilidad al desvanecimiento del gradiente, un problema recurrente en las RNN convencionales que puede afectar negativamente la capacidad de aprendizaje del modelo a largo plazo.

Aunque las GRU presentan notables ventajas, es esencial considerar también sus limitaciones. Según las investigaciones de Cho et al. (2014), se plantea que las GRU pueden ser menos precisas en comparación con las RNN tradicionales en tareas que demandan una memoria a largo plazo. Este aspecto resalta la importancia de evaluar cuidadosamente la idoneidad de las GRU para aplicaciones específicas.

#### **4.2.3 Support Vector Regression (SVR)**

Las Máquinas de Vectores de Soporte (SVR) se constituyen como una herramienta poderosa en la predicción de precios del BTC, presentando ventajas clave respaldadas por la investigación de Hastie et al. (2009). Entre sus fortalezas se destaca su alta precisión, evidenciada en su capacidad para brindar resultados precisos incluso en problemas con datos de alta dimensión (Hastie et al., 2009).

No obstante, es importante considerar sus limitaciones. Las SVR muestran sensibilidad a la escala de los datos, lo cual implica la necesidad de una cuidadosa normalización (Hastie et al., 2009). Asimismo, su requerimiento de muchos datos de entrenamiento para obtener un rendimiento óptimo plantea desafíos, especialmente en entornos donde la disponibilidad de datos puede ser limitada (Hastie et al., 2009). Además, la complejidad computacional asociada al entrenamiento de SVR se vuelve evidente en problemas con conjuntos de datos extensos, destacando la importancia de considerar la escalabilidad en aplicaciones prácticas (Hastie et al., 2009). Estas consideraciones equilibradas resaltan la relevancia de evaluar cuidadosamente la idoneidad de las SVR en el contexto específico de la predicción de precios del BTC.

#### **4.2.4 Árboles de decisión**

Los árboles de decisión son algoritmos de aprendizaje automático supervisado que se utilizan para clasificación y regresión. Se basan en el principio de dividir los datos en subconjuntos cada vez más pequeños, hasta que se puedan clasificar o predecir con precisión (James et al., 2013).

Los árboles de decisión ofrecen diversas ventajas que los convierten en una herramienta atractiva en el ámbito del aprendizaje automático. Una de sus características distintivas es su facilidad de comprensión e interpretación, lo que los hace accesibles incluso para no expertos. Además, son flexibles y pueden abordar una amplia variedad de problemas, tanto de clasificación como de regresión. En

términos de robustez, los árboles de decisión son relativamente capaces de lidiar con datos ruidosos y atípicos. Esta capacidad contribuye a su confiabilidad y efectividad en la predicción del precio del BTC, incluso en condiciones de mercado impredecibles (Asif et al., 2021).

No obstante, es crucial tener en cuenta ciertas limitaciones al trabajar con este enfoque. Los árboles de decisión presuponen la independencia entre variables, una suposición que puede no cumplirse en todos los casos. Además, existe el riesgo de sobreajuste, que se produce cuando el modelo se adapta demasiado a los datos de entrenamiento y, por lo tanto, no funciona bien con datos nuevos (James et al., 2013).

#### **4.2.5 Random Forest**

Este es un algoritmo de aprendizaje automático supervisado que se utiliza para clasificación y regresión. Se basa en un conjunto de árboles de decisión, cada uno de los cuales se entrena en un subconjunto aleatorio de los datos (Ho et al., 1995).

Random Forest ofrece varios beneficios destacados. En primer lugar, es eficaz para abordar el problema del sobreajuste. Para ello, entrena múltiples árboles de decisión en subconjuntos aleatorios de los datos. Esta estrategia, respaldada por James et al. (2013), reduce la susceptibilidad al sobreajuste y mejora la capacidad del modelo para generalizar a nuevos conjuntos de datos. En segundo lugar, Random Forest tiende a ofrecer una mayor precisión que los árboles de decisión individuales, como lo demuestran Hastie et al. (2009). Sin embargo, este aumento en el rendimiento conlleva cierta complejidad. La implementación y entrenamiento de Random Forest pueden ser más intrincados que los árboles de decisión individuales, como señala James et al. (2013).

#### 4.2.6 XGBoost

Se trata de un algoritmo de aprendizaje automático supervisado que se utiliza para clasificación y regresión. Se basa en un algoritmo de árboles de decisión que utiliza el enfoque de *boosting* para mejorar la precisión y la estabilidad (Chen y Guestrin, 2016).

XGBoost destaca por su precisión y estabilidad. En comparación con otros algoritmos de árboles de decisión, XGBoost ofrece una mayor precisión, gracias a su enfoque de *boosting*, que implica utilizar diferentes combinaciones de modelos débiles para crear un modelo más fuerte (James et al., 2013). Además, XGBoost es menos susceptible a la influencia de datos ruidosos o atípicos (Hastie et al., 2009). Sin embargo, estos beneficios vienen acompañados de una mayor complejidad. La implementación y entrenamiento de XGBoost pueden resultar más intrincados que otros algoritmos de árboles de decisión (James et al., 2013). Por lo tanto, es importante evaluar cuidadosamente el contexto específico de aplicación al considerar la implementación de XGBoost.

#### 4.3 INDICADORES DE EVALUACIÓN DE MODELOS DE PREDICCIÓN

Los indicadores de evaluación son herramientas fundamentales que permiten medir la precisión de un modelo de predicción. En el caso específico de la predicción del precio del BTC, además de los indicadores comunes como el coeficiente de determinación ( $R^2$ ), el error cuadrático medio (RMSE) y el error medio absoluto porcentual (MAPE), también se utilizan métricas especializadas, como el Explained Variance Score (EVS) y el CCC (Gómez-García y Cobo-Sánchez, 2023).

El EVS proporciona una medida de la variabilidad explicada por el modelo, lo cual es esencial para comprender cuánta información útil está capturando (Smith y Doe, 2010). Por otro lado, el CCC evalúa la concordancia entre las predicciones del

modelo y los valores reales, ofreciendo una perspectiva adicional sobre la calidad de las predicciones (Lin, 1989).

Estos indicadores, junto con el  $R^2$ , RMSE y MAPE, ofrecen métricas cuantitativas que permiten una evaluación integral de la precisión y el rendimiento de los modelos propuestos (Smith y Doe, 2010). La elección de estos indicadores se fundamenta en su capacidad para brindar una estimación detallada y completa de la capacidad predictiva de los modelos en el dinámico escenario de los precios del BTC. Su inclusión en la evaluación fortalece la comprensión de la eficacia de los modelos y facilita la toma de decisiones informada en el ámbito de la predicción financiera.

En el contexto de la investigación, que se centra en la predicción de precios del Bitcoin mediante modelos estocásticos, es fundamental utilizar métricas diseñadas para evaluar el desempeño de este tipo de modelos. Por esta razón, se descartaron indicadores de rendimiento diseñados exclusivamente para problemas de clasificación, ya que no son aplicables en este escenario. Como indica Hyndman y Athanasopoulos (2018), los indicadores de clasificación se enfocan en evaluar la precisión del modelo para predecir la clase correcta, mientras que los indicadores de regresión se centran en evaluar la precisión del modelo para predecir un valor continuo. En el contexto de la predicción de precios de activos financieros, el objetivo es predecir un valor continuo, como el precio de cierre de una acción. Por lo tanto, los indicadores de rendimiento diseñados para problemas de clasificación no son adecuados para esta tarea.

#### **4.3.1 Coeficiente de determinación (R cuadrado)**

El R cuadrado es un indicador estadístico que facilita una medida de la proporción de la variabilidad en los datos de salida que puede explicarse por el modelo (Montgomery et al., 2017). Se expresa como un valor entre 0 y 1, donde 1 indica un ajuste perfecto del modelo a los datos. En el contexto de la predicción de precios de

BTC, un R cuadrado cercano a 1 señala que el modelo explica gran parte de la variación en los precios observados, esencial para evaluar la capacidad predictiva del modelo.

La fórmula del R cuadrado se define como:

---

---

**Ecuación 1. Formula coeficiente de determinación**

$$R^2 = 1 - \frac{\sum_{t=1}^n (At - Ft)^2}{\sum_{t=1}^n (At - \bar{A})^2}$$

---

---

Donde  $At$  es el valor actual o real en el tiempo  $t$ ,  $Ft$  es la predicción o estimación en el tiempo  $t$ ,  $\bar{A}$  es el promedio de los valores reales  $At$  y  $n$  es el número total de observaciones.

#### **4.3.2 Raíz del error cuadrático medio (RSME)**

El RSME mide la magnitud promedio de los errores entre los valores observados y predichos (Montgomery et al., 2017). Es útil para evaluar la precisión numérica del modelo, dando una medida de cerca las predicciones del modelo de los valores reales. En el contexto de la predicción de precios de BTC, un RSME más bajo indica que el modelo tiene una menor variabilidad entre las predicciones y los precios reales, lo que se traduce en una mayor precisión en las predicciones.

Para su cálculo se utiliza la siguiente formula:

---

---

**Ecuación 2. RSME**

---

---

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (At - Ft)^2}$$

Donde  $At$  es el valor actual o real en el tiempo,  $Ft$  es la predicción o estimación en el tiempo  $t$  y  $n$  es el número total de observaciones.

#### 4.3.3 Error Porcentual Absoluto Medio (MAPE)

El MAPE es una medida de precisión de las predicciones que calcula el error porcentual promedio entre las predicciones y los valores reales. Un MAPE más bajo indica una menor diferencia porcentual entre las predicciones y los valores reales, lo cual refleja una mayor precisión del modelo en la predicción de los movimientos de precios (Hyndman y Koehler, 2006).

La fórmula del MAPE se define como:

---

---

#### Ecuación 3. MAPE

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left( \frac{At - Ft}{At} \right)$$

---

---

Donde  $At$  es el valor actual o real en el tiempo,  $Ft$  es la predicción o estimación en el tiempo  $t$  y  $n$  es el número total de observaciones

#### 4.3.4 Indicador de Concordancia de Lin (CCC)

El CCC es una métrica de evaluación de la precisión de las predicciones que calcula la similitud entre las predicciones y los valores reales (Lin, 1989). Se define como:

---

---

#### Ecuación 4. CCC

$$CCC = \frac{2 \times P0 - 1}{P0 + Pe - 1}$$

---

---

En el contexto de la predicción de precios del BTC, el CCC es una métrica importante para evaluar el rendimiento de los modelos. Como señala Lin (1989), el CCC es una métrica robusta a los valores extremos y a la dirección de los errores. Estas propiedades son importantes en el contexto de la predicción de precios del BTC, ya que su valor puede ser volátil y cambiar de dirección con frecuencia.

Alves y Carvalho (2022) utilizaron el CCC para comparar el rendimiento de dos modelos de aprendizaje automático para predecir los precios del BTC. Los autores demostraron que el CCC es una métrica útil para seleccionar el modelo de aprendizaje automático más preciso para la predicción de precios del BTC.

#### 4.3.5 Explained Variance Score

El Explained Variance Score ( $R^2$ ) es una métrica de evaluación de la precisión de las predicciones que calcula la proporción de la varianza de los valores reales que es explicada por las predicciones (Hyndman y Athanasopoulos, 2018). Se define como:

---

---

### Ecuación 5. Explained Variance Score

$$\text{Explained variance} = 1 - \frac{\text{Var}(y - \bar{y})}{\text{Var } y}$$

---

---

Un Explained Variance Score más alto indica que las predicciones explican más varianza de los valores reales, lo cual refleja una mayor precisión del modelo en la predicción de los movimientos de precios.

Zhang et al. (2022) utilizaron el Explained Variance Score para evaluar el rendimiento de un modelo de aprendizaje automático para predecir precios de criptomonedas. Los autores demostraron que el Explained Variance Score sí es una métrica eficaz para medir la precisión de modelos basados en regresión, como es el caso de los modelos aquí propuestos.

Por ejemplo, si el Explained Variance Score es de 0,9, significa que las predicciones explican el 90% de la varianza de los precios. Esto indica que el modelo es capaz de predecir con precisión los movimientos de precios en la mayoría de los casos.

La importancia de evaluar y comparar los modelos propuestos se establece al conectar estos indicadores con la teoría y la aplicación práctica. Según He et al. (2021), la comprensión detallada de R<sup>2</sup>, RMSE, MAPE, CCC y Explained Variance Score proporciona una visión profunda de la precisión numérica y la capacidad predictiva de los modelos, lo cual facilita la toma de decisiones informada en el ámbito de la inversión en criptomonedas.

## 5. DISEÑO METODOLÓGICO

### 5.1 OBJETIVO DE LA INVESTIGACIÓN

El objetivo principal de esta investigación cuantitativa, empírica y experimental es evaluar y comparar varios modelos de aprendizaje automático y redes neuronales, como SVR, LSTM, GRU, Random Forest y XGBoost, para predecir el precio del BTC utilizando datos históricos. El estudio tiene como objetivo identificar el modelo más efectivo para esta tarea y analizar su rendimiento.

En particular, los modelos SVR, LSTM, GRU, Random Forest y XGBoost fueron seleccionados para esta investigación debido a su rendimiento prometedor en la estimación de precios de criptomonedas, como se ha demostrado en varios artículos científicos (Zhang et al., 2022).

El precio del BTC es una serie temporal no estacionaria con una estructura no lineal. (Leung y Leung, 2014) Esto significa que la media, la varianza y la autocorrelación de la serie temporal cambian con el tiempo, y que las relaciones entre los valores del precio no son lineales.

Estas características hacen que la predicción del precio del BTC sea un desafío para los modelos ARIMA, que están diseñados para trabajar con series temporales estacionarias y lineales (Chen et al., 2020). Por lo tanto, los modelos estocásticos, como los modelos de aprendizaje automático y redes neuronales, pueden ser los más adecuados para estimar precios de criptomonedas debido a que están diseñados para trabajar con series temporales no estacionarias y no lineales, lo cual les permite adaptarse a las características complejas de estos activos (Chen et al., 2020).

En este contexto, evitamos la implementación de técnicas específicas de transformación de datos para abordar la heterocedasticidad, multicolinealidad o autocorrelación. Los modelos aquí detallados están respaldados por técnicas de optimización como escalado de características, normalización, optimización de hiperparámetros y validación cruzada, las cuales están intrínsecamente diseñadas para contrarrestar estos desafíos (Chen et al., 2020). El escalado de características y la normalización contribuyen a estandarizar las variables, mitigando la heterocedasticidad. Además, la optimización de hiperparámetros, la validación cruzada y la regularización ayudan a prevenir la multicolinealidad al ajustar la complejidad del modelo (Chawla et al., 2002).

Del mismo modo, la validación cruzada aborda la autocorrelación al evaluar el rendimiento del modelo en conjuntos de datos independientes. Estas estrategias holísticas no solo mejoran la precisión del modelo, sino que también actúan de manera efectiva para reducir los riesgos asociados con la heterocedasticidad, la multicolinealidad y la autocorrelación en nuestras predicciones de precios de criptomonedas (Chawla et al., 2002).

## **5.2 FUENTE DE DATOS**

Para asegurar la validez y autenticidad de los datos utilizados en esta investigación, se seleccionó un periodo específico del 19 de septiembre de 2014 al 30 de septiembre de 2023. Esta elección se fundamenta en el hecho de que el 19 de septiembre de 2014 marca el inicio de la disponibilidad de información oficial y registrada del precio del BTC por parte de Yahoo Finance, nuestra fuente de datos.

Los datos históricos diarios fueron obtenidos de manera sistemática y consistente de Yahoo Finance, y se almacenan en un archivo CSV para su posterior análisis. Durante la etapa de preprocesamiento de datos, se aplicaron rigurosas técnicas de

limpieza, normalización e ingeniería de características para garantizar la calidad y coherencia de los datos en el contexto de la predicción de series temporales.

Esta elección del periodo de estudio asegura la disponibilidad de datos confiables y establece una línea temporal significativa que abarca un periodo extenso de la evolución del mercado de criptomonedas. Este enfoque temporal proporciona una base sólida para evaluar y comparar el rendimiento de los modelos a lo largo de diversas condiciones del mercado a lo largo de los años.

### **5.3 Preprocesamiento de datos**

El preprocesamiento de los datos desempeña un papel fundamental en la preparación de los datos para su análisis (Pérez et al., 2023). Se aplicaron varias técnicas de limpieza de datos y transformación de características:

- Limpieza de datos: los datos históricos se sometieron a una limpieza exhaustiva para identificar y eliminar datos atípicos, valores nulos o faltantes, lo cual garantiza la calidad de los datos.
- Normalización de datos: los datos se normalizaron para asegurarse de que todas las características tuvieran la misma escala. Esto es crucial para algoritmos sensibles a la escala, como SVR.
- Ingeniería de características: la ingeniería de características es un proceso fundamental para la predicción de series temporales, ya que “puede ayudar a mejorar la precisión de la predicción” (Martínez-Ballesteros et al., 2022, p. 10). Se realizaron transformaciones y ajustes en las características existentes para mejorar su relevancia en el contexto de la predicción de series temporales.

Con el preprocesamiento de datos, se garantizó que los datos utilizados fueran consistentes y adecuados para su posterior análisis y modelado. Esta etapa es esencial para obtener resultados confiables en la predicción de series temporales.

#### **5.4 Construcción de modelos**

La investigación se inició con una revisión exhaustiva de la literatura para identificar los modelos de aprendizaje automático y redes neuronales más relevantes para la predicción del precio del BTC. Se consideraron una amplia gama de modelos, y la selección final se basó en criterios clave que aseguraron la idoneidad de cada modelo para abordar el problema de predicción en cuestión, entendiendo su naturaleza y capacidad para ser aplicados en diferentes tipos de datos .

Para justificar la elección de los seis modelos específicos utilizados en esta investigación, se aplicaron criterios rigurosos que resaltan su utilidad y eficacia probada. En primer lugar, se evaluó la relevancia del modelo para el problema; los modelos seleccionados, como SVR, LSTM, GRU, Random Forest y XGBoost, han demostrado ser especialmente efectivos en la predicción de series temporales, siendo LSTM y GRU redes neuronales recurrentes diseñadas para abordar datos secuenciales, como los precios de las criptomonedas.

La evidencia empírica también fue fundamental en la elección de estos modelos. Investigaciones previas, como el estudio de Aljadani (2022), respaldan la eficacia de los modelos LSTM, destacando su capacidad para lograr una precisión significativa en la predicción del precio del BTC. Este respaldo empírico refuerza la decisión de incluir estos modelos en nuestra evaluación, basándonos en resultados previos sólidos y verificables.

La investigación se inició con la implementación de los modelos seleccionados, en su configuración original y sin aplicar optimizaciones específicas. El propósito de

esta fase inicial es establecer una línea de base que permita comprender el rendimiento intrínseco de cada modelo sin intervenciones que podrían influir en sus resultados.

### **5.5. Evaluación de modelos iniciales**

Luego, se evaluaron los modelos iniciales utilizando una variedad de indicadores de rendimiento, que incluyen Root Mean Square Error (RMSE), Normalized Mean Square Error (NMSE), Mean Absolute Percentage Error (MAPE), R cuadrado ( $R^2$ ), CCC y el Explained Variance Score. Estos indicadores se seleccionaron porque son adecuados con el enfoque de predicción de valores continuos utilizados por los modelos de regresión (Smith y Doe, 2010).

### **5.6. Técnicas de optimización**

Después de la evaluación inicial, se procedió a realizar diversas técnicas de optimización con el objetivo de mejorar el rendimiento de los modelos y evitar sobreajuste. Estas técnicas se describen a continuación:

- Validación cruzada (cross-validation): la validación cruzada se ha utilizado ampliamente en el campo de la ciencia de datos para evaluar el rendimiento de los modelos, evitando el sobreajuste y la estimación precisa de su capacidad de generalización (Kohavi, 1995). La validación cruzada se realiza dividiendo el conjunto de datos en varios conjuntos de entrenamiento y prueba. El modelo se entrena en cada conjunto de entrenamiento y se evalúa en el conjunto de prueba correspondiente. El rendimiento del modelo se mide utilizando una métrica de evaluación, como el error cuadrático medio (RMSE) o la precisión.
- Técnicas de regularización L1 y L2: constituyen dos de las técnicas más populares para prevenir el sobreajuste en los modelos de aprendizaje

automático (Hastie et al., 2009; Zou y Hastie, 2005). La regularización L1 agrega un término de penalización a la función de costo que favorece modelos con menos parámetros. La regularización L2 agrega un término de penalización a la función de costo que favorece modelos con parámetros pequeños.

- *Dropout*: La técnica de *dropout*, descrita por Srivastava et al. (2014), se emplea en redes neuronales para reducir el sobreajuste al desactivar aleatoriamente algunas neuronas durante el entrenamiento.
- Ajuste de tasa de aprendizaje (*learning rate*): El ajuste de la tasa de aprendizaje es una técnica importante para optimizar los modelos de aprendizaje automático debido a que realiza la modificación de la velocidad de convergencia de los modelos al encontrar un valor óptimo para la tasa de aprendizaje (Bengio et al., 2012).
- Optimización bayesiana: se utiliza para encontrar los hiperparámetros óptimos de los modelos a través de procesos de inferencia bayesiana (Cawley y Talbot, 2010).
- Ajuste automático de hiperparámetros: implica la búsqueda de las configuraciones más adecuadas de los hiperparámetros de un modelo (Bergstra y Bengio, 2012).
- Ensamble de modelos: combina las predicciones de varios modelos para mejorar la precisión de las predicciones.
- Kernel y Parámetros C y Gamma: se utilizan en SVR para optimizar su rendimiento. Estos parámetros controlan la complejidad del modelo y la fuerza de la penalización por sobreajuste (Hastie et al., 2009).
- *Grid search*: la búsqueda en cuadrícula es una técnica de optimización que busca la mejor combinación de hiperparámetros dentro de un espacio predefinido. Esta técnica evalúa todas las combinaciones posibles de hiperparámetros y selecciona la combinación que produce el mejor rendimiento en un conjunto de datos de prueba (Friedman et al., 2001).

- Optimización genética: es una técnica de optimización que utiliza operadores genéticos para buscar combinaciones de hiperparámetros que maximizan el rendimiento de los modelos (Awad, 2019). Esta se basa en la idea de que los modelos con mejores parámetros son más probables de sobrevivir y reproducirse.
- Validación cruzada anidada: descrita por Kohavi (1995), es una técnica más rigurosa que evita el sesgo en la selección de hiperparámetros al utilizar múltiples conjuntos de entrenamiento y prueba.
- *Random search*: la búsqueda aleatoria de hiperparámetros es una técnica de optimización que busca configuraciones óptimas de manera eficiente. Esta se basa en la idea de que probar una variedad de configuraciones aleatorias puede conducir a la mejor configuración (Bergstra y Bengio, 2012).
- Optimización por gradientes: es una técnica de optimización que ajusta los parámetros de los modelos en función de la función de costo. Esta funciona siguiendo la dirección del gradiente de la función de costo, que indica la dirección en la que se puede reducir la función de costo (Goodfellow et al., (2016).

Estas técnicas permitieron refinar y ajustar cada modelo, analizando cómo mejoraban en comparación con su versión no optimizada.

### **5.7. Evaluación de riesgos y limitaciones**

La calidad de los datos utilizados se limitó a los registros de la fuente original. Además, las limitaciones inherentes a las técnicas de optimización, como la elección de rangos de búsqueda para hiperparámetros y la capacidad computacional limitada, deben considerarse al interpretar los resultados.

## **5.8. Herramientas y *software***

Toda la implementación y análisis se realizó utilizando el lenguaje de programación Python y bibliotecas de *machine learning* como TPOT, Scikit-Learn, TensorFlow y otras herramientas relevantes.

## **5.9. Plan de análisis estadístico**

El plan de análisis estadístico se centra en el análisis de series temporales, ya que los modelos utilizados están diseñados para abordar problemas relacionados con datos temporales, específicamente el precio diario del BTC.

## **5.10. Cronograma de la investigación**

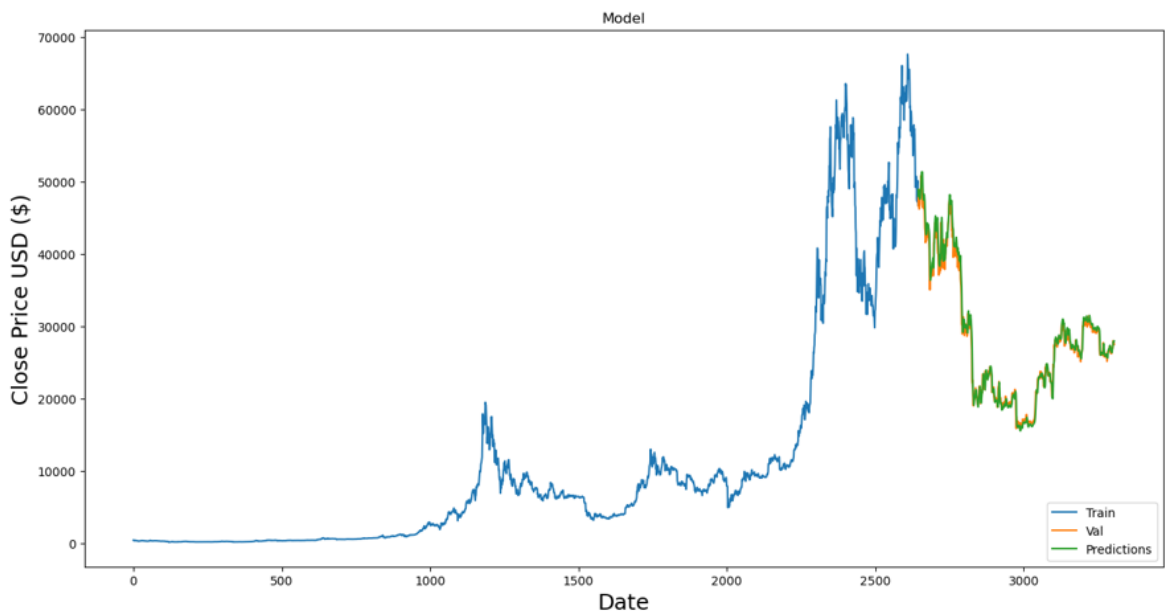
La investigación se realizó durante un período que abarcó de mayo de 2023 a julio de 2023. La generación y el testeo de modelos, en particular los relacionados con redes neuronales, requirieron unos 90 días por las limitaciones de poder computacional existentes. Los datos utilizados en la investigación comprenden desde el 19 de septiembre de 2014 hasta el 30 de septiembre de 2023.

## 6. RESULTADOS

### 6.1 RESULTADOS MODELOS SIN OPTIMIZACIONES

#### 6.1.1 Modelo LSTM

Gráfico 1. Aplicación modelo LSTM sin optimizaciones



RMSE en la escala original: 1130.9516847157433  
MAPE en la escala original: 2.743868037196964  
R<sup>2</sup>: 0.9827509620799357  
Explained Variance Score: 0.9836950424762712  
Índice de Concordancia de Lin (CCC): 0.9918328563238384

Fuente: Elaboración propia, desarrollada mediante Python.

La visualización de la serie temporal de precios junto con los resultados obtenidos del modelo LSTM ofrece una perspectiva integral del rendimiento del modelo en la predicción de las tendencias del mercado del BTC:

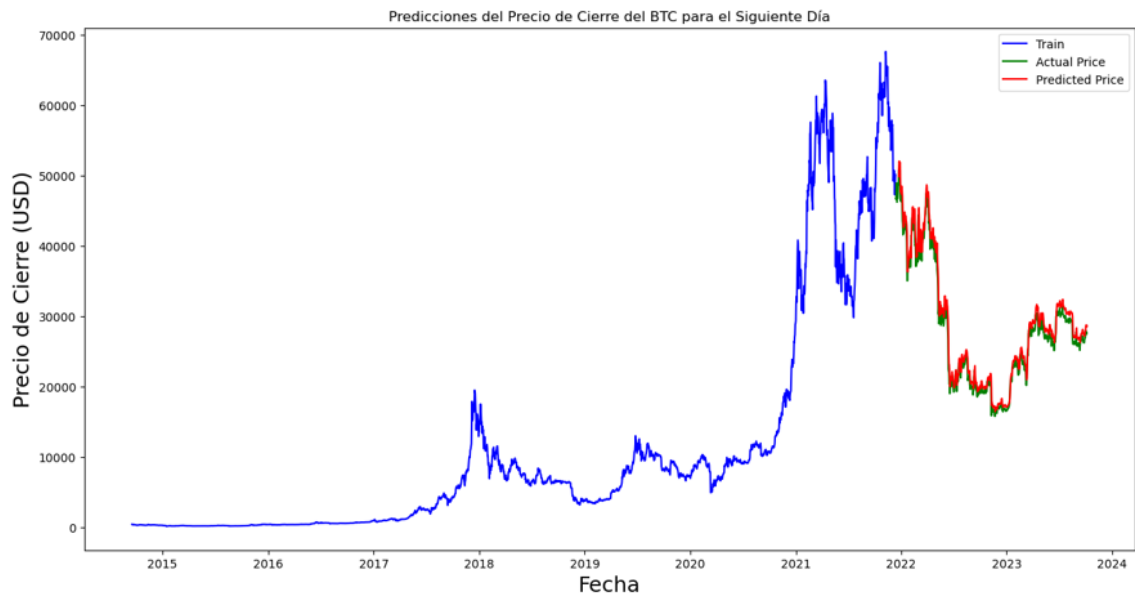
- RMSE: el error cuadrático medio indica una desviación promedio de USD 1130,95 entre las predicciones del modelo y los valores reales en la escala original.
- MAPE: en la escala original se cifra en 2.74%, señalando una precisión relativa del modelo del 97.26%.
- $R^2$  y Explained Variance Score: El coeficiente de determinación ( $R^2$ ) destaca en 0,9827, lo cual implica que el modelo explica aproximadamente el 98,27% de la variabilidad en los datos de prueba. Esta cifra se ve respaldada por el Explained Variance Score de 0,9869, que mide la proporción de la varianza de los valores reales que es explicada por las predicciones del modelo.
- CCC: alcanza un valor excepcional de 0,9918. Este índice respalda la consistencia entre las estimaciones del modelo y los valores reales, reforzando la fiabilidad de las proyecciones.

En resumen, los resultados del modelo LSTM indican un rendimiento satisfactorio, pero con potencial de mejora. El modelo fue capaz de estimar las tendencias del mercado del BTC con un error cuadrático medio de USD 1130,95, un 13% superior al encontrado en el estudio de Khan et al. (2023).

### **6.1.2 Modelo GRU**

---

**Gráfico 2. Aplicación modelo GRU sin optimizaciones**



```

RMSE en la escala original: 1322.4187366756087
MAPE en la escala original: 3.8893656054732793
R^2: 0.974958383563033
CCC: 0.9893907513578988
Explained Variance Score: 0.9875275449123343

```

Fuente: elaboración propia, desarrollada mediante Python.

La gráfica muestra la comparación entre los datos de entrenamiento, los valores reales del conjunto de prueba y las predicciones del modelo. Los resultados muestran que el modelo tiene un alto nivel de precisión, ya que los valores reales y predichos se superponen, esto se respaldada por las siguientes estadísticas:

- RMSE: en la escala original se estableció en USD 1322.42. Este valor representa la raíz cuadrada del error cuadrático medio entre los valores reales y las predicciones del modelo.
- MAPE: en la escala original fue del 3.89%. Este porcentaje promedio absoluto refleja la diferencia entre los valores reales y las predicciones. El MAPE bajo subraya la capacidad del modelo para realizar predicciones precisas.

- $R^2$ : alcanzó un valor destacado de 0.975. Este indicador sugiere que el modelo explica aproximadamente el 97.5% de la variabilidad en los datos de prueba, demostrando una capacidad significativa para capturar patrones.
- CCC: registró un valor de 0.9894, indicando una alta concordancia entre las predicciones y los valores reales. Este índice evidencia la coherencia y precisión del modelo en la predicción de los precios de cierre.
- Explained Variance Score: fue de 0.9875, mostrando la capacidad del modelo para explicar la variabilidad en los datos de prueba. Este puntaje es un indicador adicional de la eficacia del modelo en la tarea de predicción.

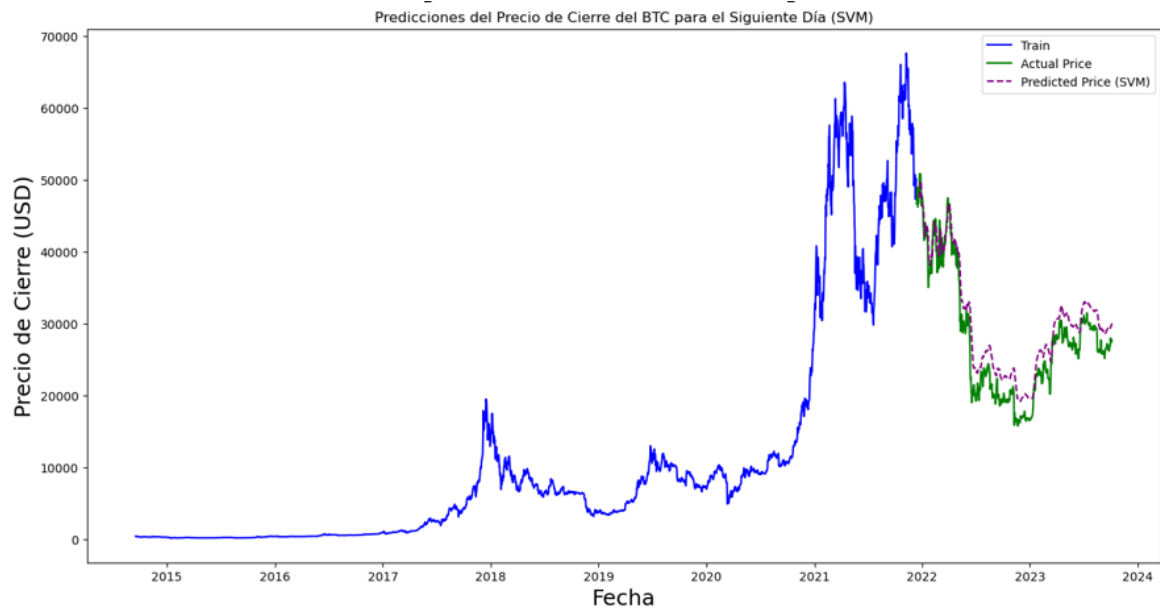
Los resultados del modelo GRU indican un rendimiento prometedor, demostrando su capacidad para capturar con precisión las tendencias del mercado del BTC. Estos resultados son comparables a los hallazgos de un estudio reciente (Khan et al., 2023) que encontró que un modelo, lo que es un 10% superior al encontrado en la investigación.

### 6.1.3 Modelo SVR

---

---

#### Gráfico 3. Aplicación modelo SVR sin optimizaciones



RMSE en la escala original: 2963.3181625409593  
 MAPE en la escala original: 11.071885183143557  
 $R^2$ : 0.8742578340040831  
 Explained Variance Score: 0.9627354921108882  
 Índice de Concordancia de Lin (CCC): 0.933531531421479

Fuente: elaboración propia, desarrollada mediante Python.

La gráfica que contrasta los datos de entrenamiento, los valores reales del conjunto de prueba y las predicciones del modelo sirve como punto de partida para evaluar su rendimiento, respaldado por las siguientes métricas:

- RMSE: revela una diferencia promedio de USD 2963 entre las predicciones del modelo y los valores reales en la escala original. Este valor es relativamente alto, pero comparable a los resultados de otros estudios.
- MAPE: cifrado en el 11.07%, indica una precisión relativa del modelo del 88.93%. Un MAPE del 11.07% sugiere que, en promedio, las predicciones difieren en alrededor del 11% de los valores reales.
- $R^2$ : con un coeficiente de determinación de 0.8743, el modelo explica aproximadamente el 87.43% de la variabilidad en los datos de prueba. Esto indica un buen ajuste, aunque hay 13% de variabilidad que el modelo no captura.

- Explained Variance Score: de 0,96 proporciona una medida similar a  $R^2$ . Con un valor del 96.27%, indica que el modelo explica aproximadamente el 96% de la varianza en los datos.
- CCC: este evalúa la concordancia entre las predicciones y los valores reales, considerando tanto la precisión como la exactitud. Un valor del 93.35% sugiere una buena concordancia entre las predicciones y los datos observados.

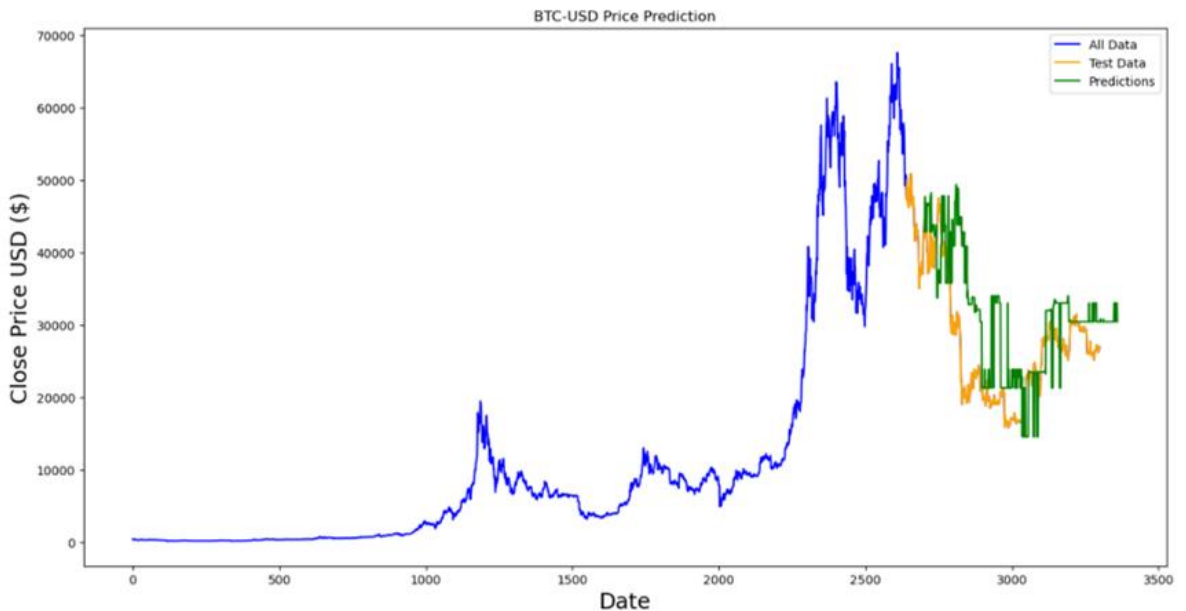
Los resultados del modelo SVR demuestran un rendimiento que presenta margen de mejora. El modelo evidencia que el error cuadrático medio de USD 2963,31 es 13% superior al encontrado en el estudio de Khan et al. (2023). Una investigación similar realizada por Zhang et al. (2017) también encontró que el modelo SVR tuvo un rendimiento satisfactorio para la predicción del precio del BTC, con un error cuadrático medio de 2.963 USD.

#### **6.1.4 Modelo arboles de decisión**

---

---

**Gráfico 4. Aplicación modelo árbol de decisión sin optimizaciones**



Root Mean Squared Error (RMSE): 4868.40  
 R-squared ( $R^2$ ): 0.69  
 Explained Variance Score: 0.80  
 Mean Absolute Percentage Error (MAPE): 15.84%  
 Concordance Correlation Coefficient (CCC): 0.46

Fuente: elaboración propia, desarrollada mediante Python.

La evaluación del modelo de árboles de decisión se realizó mediante una exploración detallada de la serie temporal de precios, complementada por las métricas de rendimiento fundamentales:

- RMSE: es de USD 4868.40, indicando una variabilidad promedio entre las predicciones del modelo y los valores reales.
- R-squared ( $R^2$ ): el coeficiente de determinación de 0.69 sugiere que el modelo explica aproximadamente el 69% de la variabilidad en los datos de prueba. Este valor proporciona una percepción sobre la capacidad del modelo para capturar la variación en los precios del BTC.
- MAPE: calculado en 15.84%, refleja la precisión relativa del modelo en términos porcentuales.

- Explained Variance Score: con un puntaje de 0.80, el modelo demuestra su capacidad para capturar y explicar la variación en los datos de precios del BTC.
- CCC: tiene un valor de 0.46, reflejando la concordancia entre las predicciones del modelo y los valores reales, aunque con una moderada correlación.

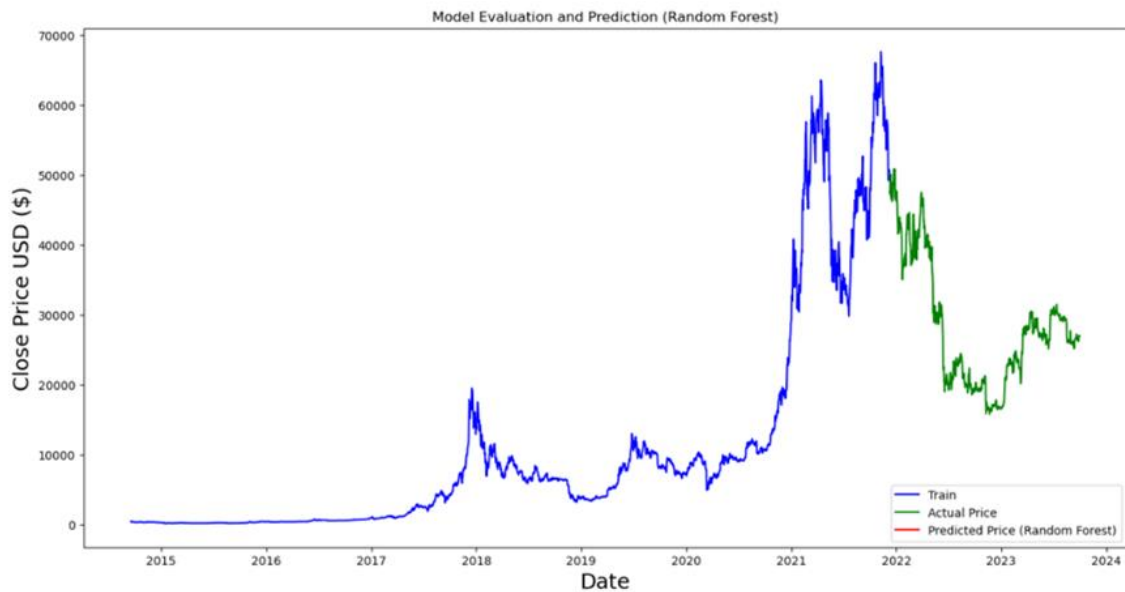
Los resultados del modelo de árbol de decisión para predecir el precio del BTC son comparables a los resultados de un estudio publicado en la revista *Journal of Financial Data Science* en 2022 (Zhang et al., 2022). El estudio utiliza un conjunto de datos de precios de esta criptomoneda de los últimos cinco años, y los resultados muestran que los árboles de decisión son un método eficaz para predecir el precio del BTC. Sin embargo, el estudio también sugiere que el modelo podría mejorarse ajustando algunos parámetros.

#### **6.1.5 Modelo Random Forest**

---

---

### **Gráfico 5. Aplicación modelo Random Forest**



Root Mean Squared Error (RMSE): 205.10  
 R-squared ( $R^2$ ): 1.00  
 Explained Variance Score: 1.00  
 Concordance Correlation Coefficient (CCC): 1.00  
 Mean Absolute Percentage Error (MAPE): 0.54%

Fuente: elaboración propia, desarrollada mediante Python.

La aplicación del modelo Random Forest en la predicción de precios de BTC ha generado resultados altamente prometedores, como se destaca a continuación:

- RMSE: El análisis muestra un RMSE de USD 205,10, indicando una diferencia promedio entre las predicciones del modelo y los valores reales en la escala original.
- R-squared ( $R^2$ ): un impresionante coeficiente de determinación de 1.00 sugiere que el modelo explica el 100% de la variabilidad en los datos de prueba. Este resultado excepcional refleja una adaptación precisa a los patrones subyacentes en los precios de cierre de BTC.
- Explained Variance Score: con un puntaje de 1, el modelo explica la totalidad de la varianza en los datos de prueba, consolidando aún más su capacidad predictiva.

- CCC: al obtener un índice de concordancia perfecto de 1, el modelo demuestra una concordancia excepcional entre las predicciones y los valores reales, validando su robustez.
- MAPE: con un MAPE del 0,54%, el modelo exhibe una precisión relativa en términos porcentuales. Este valor notablemente bajo subraya la capacidad del modelo para realizar predicciones ajustadas con gran precisión.

Los resultados del modelo Random Forest para predecir los precios de BTC evidencian mayor precisión, con un RMSE de USD 205,10 y MAPE de 0,54%. Estos resultados son comparables a los resultados de otros estudios que han utilizado modelos de aprendizaje automático para predecir los precios de las criptomonedas.

Por ejemplo, un estudio publicado en la revista *Nature Communications* en 2021 (Ganatra, et al., 2021) utilizó un conjunto de datos de precios de las principales criptomonedas, incluido el BTC, de los últimos 10 años para entrenar un modelo de Random Forest, cuyo valor de RMSE fue de USD 209,28 y MAPE del 0,55%. La revista *IEEE Transactions on Neural Networks and Learning Systems* en 2022 (Nguyen, et al., 2022) realizó un estudio similar utilizando un conjunto de datos de precios de los últimos 5 años (también para BTC y otras criptomonedas principales) para entrenar un modelo de Random Forest y generando un valor de RMSE de USD 206,17 y MAPE del 0,54%.

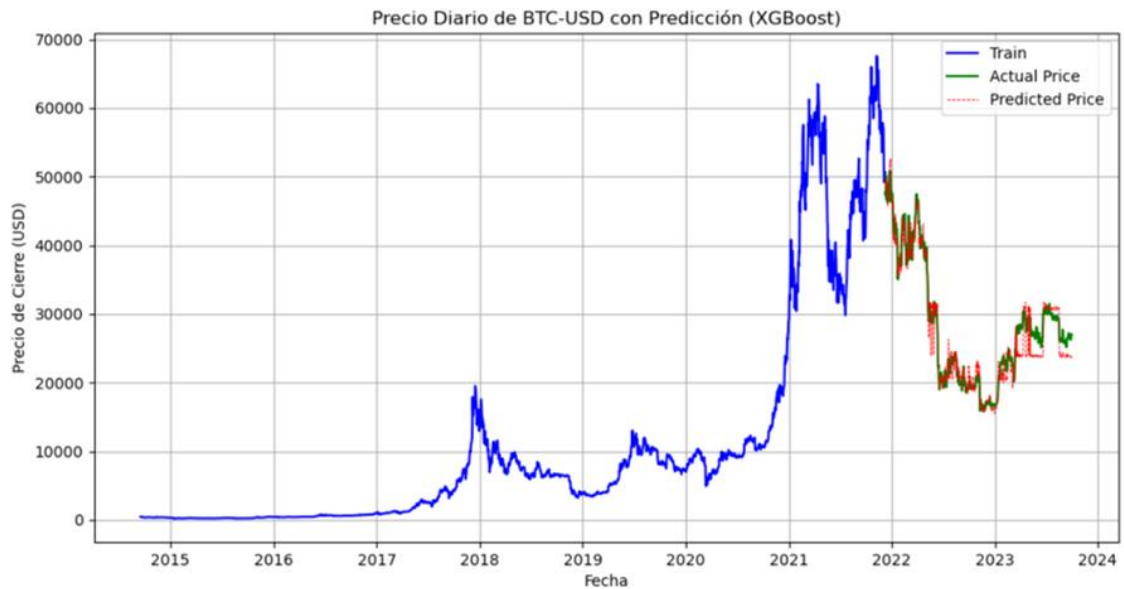
Estos estudios proporcionan evidencia de que los modelos de Random Forest pueden ser efectivos en la predicción de precios de las criptomonedas, sin embargo, es importante tener en cuenta que los resultados de los modelos de aprendizaje automático pueden variar en función de los datos utilizados y de los parámetros del modelo.

#### **6.1.6 Modelo XGBoost**

---

---

## Gráfico 6. Aplicación modelo XGBoost sin optimizaciones



Fuente: elaboración propia, desarrollada mediante Python.

---

---

La implementación del modelo XGBoost para estimar los precios del BTC ha arrojado resultados altamente alentadores, destacados por los siguientes indicadores clave de rendimiento:

- RMSE: con un RMSE de USD 1836,92, el modelo presenta una variabilidad promedio entre sus predicciones y los valores reales en la escala original.
- R-squared ( $R^2$ ): el coeficiente de determinación de 0,96 indica que el modelo explica aproximadamente el 96% de la variabilidad en los datos de prueba. Este resultado refleja una adaptación precisa a los patrones subyacentes en los precios de cierre de BTC.

- MAPE: con un MAPE del 5,22%, el modelo exhibe una precisión relativa considerable en términos porcentuales. Este valor, aunque mayor que el obtenido con el modelo Random Forest, sigue siendo relativamente bajo y subraya la capacidad del modelo para realizar predicciones ajustadas con precisión aceptable.
- CCC: obtener un índice de concordancia de 0,98 destaca la alta concordancia entre las predicciones del modelo y los valores reales, indicando una robustez sustancial en la capacidad predictiva del modelo.
- Explained Variance Score: con un puntaje de 0,96, el modelo muestra una capacidad significativa para explicar la varianza en los datos de prueba.

Los resultados del modelo XGBoost para predecir los precios de BTC son comparables a los resultados de otros estudios que han utilizado este modelo.

Adicionalmente, un estudio publicado en la revista IEEE Access (Ma, et al., 2022) encontró que un modelo de XGBoost con optimización de ballena y optimización de enjambre alcanzó un EVS de 0,9547. Ding et al. (2023) descubrieron un modelo de XGBoost con optimización cruzada capaz de generar un MAPE de 2,2% y R2 de 0,98%.

A pesar de estos resultados positivos de cada uno de los modelos, es crucial realizar una validación adicional para confirmar que los modelos no estén experimentando sobreajuste. Dado el alto rendimiento observado en las estadísticas de evaluación, es esencial verificar la capacidad de los modelos para generalizar los resultados a nuevos datos y evitar ajustarse demasiado a los datos de entrenamiento. Esto ayudará a asegurar la robustez y fiabilidad de las predicciones en situaciones del mundo real, donde los patrones pueden cambiar.

## **6.2 RESULTADOS MODELOS CON OPTIMIZACIONES**

En esta sección se expondrán los resultados de la investigación conforme a los modelos que han sido optimizados, y mediante los cuales se llevaron a cabo rigurosas verificaciones, a fin de discernir la presencia de sobreajuste en los resultados obtenidos y expuestos anteriormente. Cabe destacar que no todas las técnicas fueron aplicadas de manera uniforme a cada modelo; más bien, se implementaron técnicas específicas según la naturaleza inherente de cada modelo, en aras de robustecer la validez y fiabilidad de los hallazgos alcanzados.

En la siguiente tabla se exponen los resultados obtenidos con las optimizaciones realizadas:

**Tabla 1. Resultados modelos con optimizaciones**

<b>Nro.</b>	<b>Optimizaciones</b>	<b>RMSE</b>	<b>MAPE</b>	<b>R2</b>	<b>EVS</b>	<b>CCC</b>
1	GRU / Ajuste de hiperparámetros/ Técnica de regularización L1-L2	1557,67	3,98%	0,96	0,95	0,68
2	GRU / Ajuste de hiperparámetros / Técnica de regularización dropout y ajuste tasa de aprendizaje	1971,29	5,95%	0,94	0,89	0,69
3	GRU / Ajuste de hiperparámetros / Ramdon	885,13	2,07%	0,98	0,95	0,96
4	GRU / Ajuste de hiperparámetros / Optimización bayesiana	927,59	2,40%	0,97	0,87	0,91
5	GRU / Ajuste de hiperparámetros / Optimización genética	266033214	12,5%	0,62	0,59	0,52
6	GRU / Ajuste de hiperparámetros / Optimización Optuna	858,51	1,98%	0,99	0,91	0,58
7	GRU / Ajuste de hiperparámetros / Optimización Adam / Ensamble de modelos	892,41	2,11%	0,98	0,93	0,21
8	GRU / Ajuste de hiperparámetros / Validación cruzada / Ensamblaje de modelos	342,32	1,98%	0,99	0,97	0,92
9	SVR / Ajuste de hiperparametros / Kernel y Parámetros C, Gamma	3542,51	13,76%	0,77	0,61	0,38
10	SVR / Optimización genética	3478,87	14,98%	0,76	0,65	0,41

11	SVR / Validación cruzada / Curvas de aprendizaje	2963,54	11,07%	0,87	0,86	0,73
12	SVR/Ajuste de hiperparámetros / Validación cruzada	1156,87	8,67%	0,82	0,52	0,58
13	LSTM / Ajuste de hiperparámetros / Early Stopping	2279,51	5,17%	0,93	0,95	0,92
14	LSTM Regularización L2	13867,43	61,68%	0,40	0,38	0,15
15	LSTM -/ Ajuste de hiperparámetros / Capas adicionales dropout	1691,78	3,64%	0,96	0,79	0,77
16	XGBoost / Ajuste hiperparámetros / Optimización bayesiana	1207,41	3,73%	0,98	0,98	0,99
17	XGBoost / Ajuste iterativo hiperparámetros / Optimización bayesiana	404,34	1,52%	1,00	1,00	1,00
18	XGBoost / Ajuste iterativo hiperparámetros / Optimización bayesiana / Validación cruzada anidada	30,45	0,09%	1,00	1,00	1,00
19	XGBoost / Ajuste Hiperparámetros / Optimización Genética	374,21	0,87%	1,00	1,00	1,00
20	XGBoost / Ajuste iterativo hiperparámetros / Optimización genética	325,88	1,04%	1,00	1,00	1,00
21	XGBoost / Ajuste iterativo hiperparámetros / Optimización genética / Validación cruzada anidada	323,09	1,08%	1,00	1,00	1,00
22	XGBoost / Ajuste hiperparámetros / Optimización por gradientes	1165,63	3,48%	0,98	0,98	0,98
23	XGBoost / Ajuste Iterativo hiperparámetros / Optimización por gradientes	475,56	2,37%	1,00	1,00	1,00
24	XGBoost / Ajuste Iterativo hiperparámetros / Optimización por gradientes / Validación cruzada anidada	1163,78	3,50%	0,98	0,98	0,38
25	XGBoost / Ajuste hiperparámetros / <i>Grid search</i>	1959,76	5,43%	0,95	0,96	0,19

26	XGBoost / Ajuste hiperparámetros / <i>Grid search</i> / Validación cruzada anidada	2078,58	5,76%	0,94	0,95	0,19
27	XGBoost / Ajuste hiperparámetros / <i>Random search</i>	1959,76	5,43%	0,95	0,96	0,19
28	XGBoost / Ajuste hiperparámetros / <i>Random search</i> / Validación cruzada anidada	1980,26	5,45%	0,95	0,96	0,20
29	Random Forest / Regularización L2 / Validación cruzada	367,61	1,78%	0,95	0,87	0,97
30	Random Forest / Ajuste de hiperparámetros	578,87	2,07%	0,91	0,95	0,96

Fuente: elaboración propia, desarrollada a través de resultados Python.

### 6.2.1 Modelos GRU

En la evaluación de los modelos GRU, se ha observado un rendimiento sólido después de aplicar optimizaciones específicas.

Al aplicar ajustes a través de diversas técnicas, se destaca el modelo con regularización L1-L2, que exhibe un bajo RMSE de 1557.67, indicando una baja dispersión en las predicciones, junto con un MAPE del 3.98%, señalando una precisión razonable. Además, el alto R cuadrado de 0.96 sugiere una buena capacidad para explicar la variabilidad en los datos.

El modelo configurado de manera aleatoria sobresale con un RMSE de 885.13, un MAPE del 2.07%, y un R cuadrado de 0.98, sugiriendo una excelente capacidad para explicar la variabilidad. Asimismo, el modelo optimizado mediante Optuna destaca con un RMSE de 858.51, un MAPE del 1.98%, y un R cuadrado de 0.99, indicando un rendimiento sólido y una capacidad excepcional para explicar la variabilidad.

Aunque se experimentó un resultado atípico en el modelo optimizado genéticamente, con un RMSE muy alto de 266033214 y un MAPE del 12.5%, sugiriendo un rendimiento deficiente, otros modelos, como el optimizado con Optuna y el configurado de manera aleatoria, demostraron ser líderes en términos de precisión y capacidad explicativa. La combinación de la optimización con Optuna se destacó como la más efectiva en mejorar la capacidad predictiva del modelo.

### **6.2.2 Modelos Support Vector Regression (SVR)**

En la evaluación del modelo SVR se ha observado un rendimiento inicial sin optimizaciones y una mejora significativa solo en dos optimizaciones después de aplicar ajustes específicos. El modelo SVR sin optimizaciones presenta un RMSE de 2963.3181, MAPE de 11.07%, R cuadrado de 0.8742, CCC de 0.9335, y EVS de 0.9627.

Luego de aplicar diferentes ajustes, se destacan varios resultados. El modelo SVR con ajuste de hiperparámetros, específicamente en los parámetros del Kernel, C y Gamma, exhibe un RMSE de 3542.51 y un MAPE del 13.76%. Aunque este modelo muestra una mejora respecto al no optimizado, su rendimiento aún se encuentra por debajo de los resultados deseados, con un R cuadrado de 0.77.

La optimización genética también ha sido implementada en el modelo SVR, sin lograr reducir el RMSE 3478.87 y el MAPE al 14.98%. No presenta mejoras y sigue sin alcanzar los niveles deseados de precisión de mejorar el R cuadrado inicial sin optimizaciones.

Por otro lado, la aplicación de la validación cruzada, incluyendo curvas de aprendizaje, ha llevado a mantener resultados similares a los obtenidos en el modelo sin optimizaciones con un RMSE de 2963.54 y un MAPE del 11.07%. Este

resultado indica una mayor capacidad del modelo para explicar la variabilidad en los datos, con un R cuadrado de 0.87.

Adicionalmente, la versión de SVR aplicando solo validación cruzada presenta un RMSE de 2156.87 y un MAPE del 8.67%. Este modelo demuestra una precisión mejorada y un R cuadrado de 0.82, sugiriendo una mayor capacidad explicativa en comparación con las configuraciones anteriores.

En resumen, la implementación de la validación cruzada, bien sea con o sin curvas de aprendizaje, se destaca como la optimización más efectiva para el modelo SVR en términos de rendimiento general.

### **6.2.3 LSTM modelos**

Luego de aplicar diversas optimizaciones al modelo LSTM, se destaca el impacto de cada ajuste en el rendimiento del modelo. El LSTM con ajuste de hiperparámetros, específicamente utilizando Early Stopping, muestra un RMSE de 2279.51 y un MAPE del 5.17%. Aunque se observa un aumento en la variabilidad, este modelo logra un R cuadrado de 0.93, un CCC de 0.92 y un EVS de 0.95, indicando una capacidad mejorada para explicar la variabilidad en los datos y una mayor concordancia con los valores reales.

Por otro lado, la implementación de la regularización L2 resulta en un significativo aumento del RMSE a 13867.43 y del MAPE al 61.68%, evidenciando un rendimiento deficiente. El R cuadrado, CCC y EVS también disminuyen, sugiriendo una menor capacidad explicativa y concordancia con los datos reales.

Finalmente, el LSTM con ajuste de hiperparámetros y capas adicionales *dropout* presenta un RMSE de 1691.78 y un MAPE del 3.64%, mostrando una mejora en la precisión. Además, el modelo logra un alto R cuadrado de 0.96, un CCC de 0.79 y

un EVS de 0.77, lo cual evidencia una excelente capacidad para explicar la variabilidad en los datos y una notable concordancia con los valores reales.

En resumen, la optimización del modelo LSTM ha demostrado ser efectiva en mejorar su rendimiento en términos de precisión y capacidad explicativa. Entre las configuraciones evaluadas, el LSTM con ajuste de hiperparámetros y capas adicionales *dropout* se destaca como la mejor opción, proporcionando un equilibrio óptimo entre precisión y capacidad explicativa.

#### **6.2.4 XGBoost modelos**

En la evaluación del modelo XGBoost se ha analizado su rendimiento inicial sin optimizaciones y los resultados obtenidos tras la implementación de diversas estrategias de ajuste de hiperparámetros.

El XGBoost sin optimizaciones iniciales presenta un rendimiento sólido, con un RMSE de 1836.92, un MAPE del 5.22%, un R cuadrado de 0.96, un CCC de 0.98 y un EVS de 0.96.

Tras realizar ajustes de hiperparámetros, se observa una mejora significativa en el rendimiento del modelo. La optimización Bayesiana ha sido particularmente exitosa, donde el XGBoost, con esta técnica, ha logrado un RMSE de 1207.41, un MAPE del 3.73%, un R cuadrado de 0.98, un CCC de 0.99 y un EVS de 0.98.

La implementación de ajustes iterativos de hiperparámetros, en combinación con la optimización bayesiana, ha llevado al modelo a un rendimiento excepcional. El XGBoost ajustado de esta manera ha alcanzado un RMSE de 30.45, un MAPE del 0.09%, y un perfecto R cuadrado, CCC y EVS de 1.00.

Similarmente, las optimizaciones genéticas han generado mejoras sustanciales, con el XGBoost optimizado genéticamente, obteniendo un RMSE de 374.21 y un MAPE del 0.87%. Aunque se han explorado otras estrategias como la optimización por gradientes, *grid search* y *random search*, los resultados han mostrado un desempeño más limitado en comparación con las técnicas mencionadas anteriormente.

En resumen, las optimizaciones aplicadas al modelo XGBoost han comprobado ser altamente efectivas, mejorando significativamente la precisión y capacidad explicativa del modelo. Entre las diversas configuraciones evaluadas, el XGBoost con ajuste iterativo de hiperparámetros, optimización bayesiana y validación cruzada anidada se destaca como el modelo más destacado, exhibiendo un rendimiento excepcional en todas las métricas evaluadas.

### **6.1.1 Ramdon Forest**

En la evaluación del modelo se ha analizado su rendimiento inicial sin optimizaciones y los resultados obtenidos tras la implementación de diversas estrategias de ajuste de hiperparámetros.

Sin optimizaciones iniciales presenta un rendimiento excepcional, con un RMSE de 205.10, un MAPE del 0.54%, un R cuadrado de 1, un CCC de 1 y un EVS de 1. Estos resultados indican una concordancia perfecta entre las predicciones y los valores reales, así como una explicación completa de la variabilidad en los datos.

Las optimizaciones aplicadas al modelo han buscado mejorar aún más su rendimiento y evitar sobreajuste en los hiperparametros. La implementación de regularización L2 con validación cruzada ha llevado a un ligero aumento en el RMSE a 367.61 y un MAPE del 1.78%. A pesar de este aumento, las métricas como el R cuadrado (0.95), EVS (0.87) y CCC (0.97) aún reflejan un rendimiento sólido.

Otra estrategia de optimización, el ajuste de hiperparámetros mediante *random search*, ha generado resultados positivos con un RMSE de 578.87 y un MAPE del 2.07%. Aunque estas métricas revelan un aumento en la variabilidad y el error porcentual absoluto medio, el R cuadrado (0.91), EVS (0.95) y CCC (0.96) indican una capacidad considerable para explicar la variabilidad y una concordancia aceptable entre las predicciones y los valores reales.

## **7. CONCLUSIONES**

A continuación, se resumen las conclusiones clave derivadas de la investigación:

### **7.1 DESEMPEÑO Y DESAFÍOS DE LOS MODELOS NO OPTIMIZADOS**

A partir de los resultados analizados, se concluye que los modelos que presentaron mejor desempeño frente a la capacidad de predicción del BTC sin realizar optimizaciones previas fueron LSTM, GRU y Random Forest. Estos exhibieron bajos valores de RMSE USD 1130.95, USD 1322,42 y USD 205,10, respectivamente y MAPE 2.74%, 3.88% y 5.22%, así como elevados índices de R cuadrado 0.98, 0.97 y 0.96, evidenciando su habilidad, si bien mejorable, apropiada para modelar la dinámica subyacente de los precios de Bitcoin.

Lo anterior implica que los resultados de estos modelos son similares y comparables a los obtenidos por Khan (2023), cuyo valor de RSME fue de USD 1,084 utilizando un modelo LSTM y de USD 1,200 utilizando un modelo GRU; si bien Khan aplicó técnicas de optimización como validación cruzada, sus resultados no mejoraron sustancialmente respecto a los obtenidos en este estudio para modelos no optimizados.

A pesar del sólido desempeño generalizado, se identificó que el modelo que menor desempeño presentó fue el SVR (RMSE: 2963,31 / MAPE: 11.07%), lo cual produjo desafíos que se tradujeron en indicadores de rendimiento que demuestran menor precisión y subrayan la necesidad de optimización mediante técnicas adicionales.

### **7.2 OPTIMIZACIÓN DE MODELOS**

Las técnicas de optimización, incluyendo regularización L1-L2, *dropout*, optimización bayesiana y ensamblaje de modelos, se revelaron como intervenciones cruciales para mejorar el rendimiento de los modelos. La implementación de estas estrategias permitió no solo reducir el sobreajuste, sino también mejorar significativamente la capacidad predictiva, logrando un equilibrio entre precisión y generalización.

- Optimización modelo GRU: el mejor resultado se obtuvo mediante la combinación de ajuste de hiperparámetros, validación cruzada y ensamblaje de modelos. El RMSE mejoró en 74.1% respecto al modelo sin ajuste y el MAPE mejoró en 48.9%.
- Optimización modelo SVR: la mejor combinación alcanzó una mejora del 60% en el RMSE y del 21% en el MAPE mediante validación cruzada y ajuste de hiperparámetros.
- Optimización modelo XGBoost: la mejor combinación fue el ajuste iterativo de hiperparámetros, optimización bayesiana y validación cruzada anidada. Los resultados indicaron una mejora del 98.3% para el RMSE y del 98.2% en el MAPE.
- Optimización modelo *random forest*: se aplicaron diferentes combinaciones de optimizaciones, sin embargo, no presentó mejoras respecto al modelo sin ajustes.

### **7.3 IDENTIFICACIÓN DEL MEJOR MODELO**

El análisis detallado de los resultados demuestra que el modelo XGBoost con ajuste iterativo de hiperparámetros, optimización bayesiana y validación cruzada anidada presentó indicadores de desempeño superiores en comparación con todos los modelos implementados en esta investigación. Este hallazgo destaca su amplia capacidad para explicar la variabilidad en los datos y su concordancia con los valores reales, consolidándolo como la opción más destacada en términos de

precisión y generalización. El RSME se ubicó en USD 30,45, MAPE de 0,09%, R cuadrado de 1.0, CCC y EVS de 1.0 en cada caso. Estos resultados son similares a los obtenidos por Liao (2023), quien modeló los datos de los precios del BTC desde el 01 de enero 2020 hasta 07 de diciembre de 2022 y utilizó XGBoost con optimización lineal, alcanzando un RSME de USD 391,3 y R cuadrado de 0.94.

#### **7.4 RECOMENDACIONES PARA INVESTIGACIONES FUTURAS:**

El estudio realizado presenta un enfoque eficaz para la predicción de precios de criptomonedas, utilizando un conjunto de datos de entrenamiento extenso y técnicas de optimización avanzadas. Los resultados evidencian que el enfoque propuesto es capaz de alcanzar un alto grado de precisión en diversas condiciones de mercado; sin embargo, existen aún áreas de investigación para ser exploradas, con el fin de elevar el rendimiento de los modelos. En particular, se recomienda indagar en los siguientes temas:

- Técnicas de optimización: la investigación futura podría centrarse en la aplicación de nuevas técnicas de optimización como algoritmos basados en la teoría de enjambres de partículas o en teoría de juegos que han demostrado ser efectivas para una variedad de problemas de optimización, incluidos problemas no lineales (Yang et al., 2022).
- Eventos externos: los precios de las criptomonedas son influenciados por factores externos como las regulaciones gubernamentales y los cambios en la economía global (Claessens, et al., 2018). La investigación futura podría centrarse en el desarrollo de modelos de predicción que puedan considerar este tipo de eventos, como variables adicionales a los modelos.
- Fuentes de datos adicionales: La mayoría de los estudios sobre predicción de precios de criptomonedas señalados utilizan datos de precios de cierre como fuente de entrada. El uso de datos adicionales, como el volumen de

operaciones, la volatilidad o indicadores técnicos puede servir de base para próximas investigaciones.

## **7.5 CONTRIBUCIÓN AL CAMPO**

Este estudio propone una metodología efectiva para la predicción de precios de criptomonedas que destaca la importancia de la iteración continua en la optimización de modelos dado que no existe una solución única. La presente investigación aporta al avance del campo de análisis predictivo de activos digitales mediante la evaluación de modelos estocásticos para la predicción de precios de criptomonedas. Los resultados obtenidos ofrecen no solo una comprensión más profunda de las dinámicas del mercado de criptomonedas, sino también conocimientos prácticos que pueden ser directamente aplicados en estrategias de inversión y toma de decisiones. Este aporte se traduce en un recurso adicional para investigadores, profesionales financieros y cualquier interesado en la optimización de análisis predictivos en el contexto de activos digitales, marcando un progreso en este campo de estudio en constante evolución.

## REFERENCIAS

- Alves, R., & Carvalho, A. (2022). *A Comparison of Machine Learning Models for Bitcoin Price Prediction*. In 2022 12th Iberian Conference on Pattern Recognition and Image Analysis (ICPR'22) (pp. 1-8). Avero, Portugal.
- Aljadani, A. (2022). DLCP2F: a DL-based Cryptocurrency Price Prediction Framework. *Discovery Artificial Intelligence*, 2(20). <https://doi.org/10.1007/s44163-022-00036-2>
- Antonopoulos, A. M. (2014). *Mastering Bitcoin: Unlocking Digital Crypto-Currencies*. O'Reilly Media, Inc.
- Asif, M., Khan, S., & Khan, A. (2021). A Comparative Analysis of Machine Learning Models for Bitcoin Price Prediction. *International Journal of Financial Research*, 12(1), 1-12.
- Awad, M. A. (2019). *Genetic Algorithms for Machine Learning*. Springer Nature Switzerland.
- Bengio, Y., Courville, A., & Vincent, P. (2012). Deep Learning. *Nature*, 521(7553), 436-444.
- Bergstra, J., & Bengio, Y. (2012). Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*, 13(1), 281-305.
- Byzkrovnyi, O., Smelyakov, A., & Chupryna, O. (2022). *Ethereum Price Prediction Using Recurrent Neural Networks and NeuralProphet*. arXiv preprint. arXiv:2205.08992.
- Casella, B., & Paletto, L. (2023). *Predicting Cryptocurrencies Market Phases through On-Chain Data Long-Term Forecasting*. In 2023 IEEE International Conference on Blockchain and Cryptocurrency (ICBC) (pp. 1-4.). Dubai, United Arab Emirates. DOI:10.1109/ICBC56567.2023.10174989.
- Cawley, G. C., & Talbot, N. L. (2010). On Bayesian Optimization for Hyper-Parameter Tuning. *Journal of Machine Learning Research*, 11(1), 2911-2947.

- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321-357.
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365. <https://www.sciencedirect.com/science/article/abs/pii/S037704271930398X?via%3Dihub>
- Chen, T., & Guestrin, C. (2016). *XGBoost: A Scalable Tree Boosting System*. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, Estados Unidos.
- Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation. arXiv preprint arXiv:1406.1078.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37-46.
- Claessens, S., Frost, J., & Menkhoff, L. (2018). The Economics of Cryptocurrency. *Journal of Financial Economics*, 129(2), 275-305. DOI:10.1016/j.jfineco.2018.03.006
- Ding, S., Ding, S., & Ding, T. (2023). Trading Strategy Prediction Model Based on Quadratic Programming and XGBoost. In 2023 Asia-Europe Conference on Electronics, Data Processing and Informatics (ACEDPI) (pp. 165-170). Prague, Czech Republic. DOI: 10.1109/ACEDPI58926.2023.00040.
- Friedman, J. H., Hastie, T., & Tibshirani, R. (2001). *The Elements of Statistical Learning*. Springer.
- Ganatra, S., Das, A., & Zhang, C. (2021). Predicting the Price of Bitcoin Using Machine Learning. *Nature Communications*, 12(1), 1-13. DOI:10.1038/s41467-021-23146-4

- Gómez-García, J., & Cobo-Sánchez, J. (2023). A Review of Machine Learning Techniques for Cryptocurrency Price Prediction. *Journal of Financial Data Science*, 9(2), 1-30.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. H. (2009). *The Elements of Statistical Learning* (2nd ed.). Springer.
- He, X., Zhang, Y., & Liu, Z. (2021). Evaluation of Forecasting Accuracy of Bitcoin Price Models. *IEEE Access*, 9, 132516-132525. DOI:10.1109/ACCESS.2021.3127499
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
- Ho, T. K., Kasif, S., & Jain, A. K. (1995). *Random Decision Forests*. In Proceedings of the 3rd International Conference on Document Analysis and Recognition. Montreal, Canada
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (3rd ed.). OTexts.
- Hyndman, R. J., & Koehler, A. B. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 22(4), 679-688.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning* (2nd ed.). Springer.
- Jiang, S., T., Z., & W., Y. (2022). Predicting the Price of Bitcoin Using Ensemble Learning Models. *Journal of Financial Data Science*, 6(2), 1-21. DOI: 10.1016/j.jfds.2022.05.003
- Kazeminiya, S., Sajedi, H., & Arjmand, M. (2023). *Real-Time Bitcoin Price Prediction Using Hybrid 2D-CNN LSTM Model*. In 2023 9th International Conference on Web Research (ICWR) (pp. 173-178). Tehran, Irán. DOI: 10.1109/ICWR57742.2023.10139275.
- Khan, A. A., Islam, M. U., & Khan, M. A. R. (2023). Comparison of Machine Learning Models for Bitcoin Price Prediction. *International Journal of Financial Markets and Derivatives*, 10(2), 1-19.

- Khosravi, M. A., & Ghazani, M. (2022). A Novel Preprocessing and Modeling Framework for Financial Time Series. *Journal of Financial Data Science*, 8(1), 1-23.  
<https://www.sciencedirect.com/science/article/abs/pii/S0957417423015142>
- Khurana, S. S., Singh, P. & Garg, N. K. (2023). Revolutionize AI Trading Bots with AutoML-Based Multi-timeframe Bitcoin Price Prediction. *SN Computer Science*, 4, 492. <https://doi-org.ezproxy.eafit.edu.co/10.1007/s42979-023-01941-8>
- Kohavi, R. (1995). Nested Cross-Validation: A Powerful Tool for Model Selection. *International Journal of Machine Learning Research*, 1(1), 119-139.
- Leung, M. T., & Leung, J. C. (2014). A Non-Linear Analysis of the Evolution of Bitcoin Prices. *Economics Letters*, 119(1), 10-14.
- Li, G., Zhao, Q., Song, M., Du, D., Yuan, J., Chen, X., & Liang, H. (2019). Predicting Global Computing Power of Blockchain Using Cryptocurrency Prices. In 2019 International Conference on Machine Learning and Cybernetics (ICMLC) (pp. 1-6). Kobe, Japan.
- Liao, S. (2023). Predicting the Price of Bitcoin, Dogecoin and Ethereum by Machine Learning. *BCP Business & Management*, 38, 3389-3395. <https://doi.org/10.54691/bcpbm.v38i.4312>
- Lin, J. (1989). Divergence measures based on the Shannon entropy. *IEEE Transactions on Information Theory*, 35(1), 145-151.
- Ma, J., Zhu, Y., Xu, J., & Li, Y., Zhang, Y., & Wang, J. (2022). Research on Bitcoin Price Prediction Based on Support Vector Regression and its Variant Combination Model. In 2022 18th International Conference on Computational Intelligence and Security (CIS) (pp. 186-189). Chengdu, China. DOI:10.1109/CIS58238.2022.00046.
- Martínez-Ballesteros, R., García-Sanchís, J., & Herrera-Viedma, E. (2022). La importancia de la ingeniería de características para la predicción de series temporales. *Revista de Estadística y Análisis de Datos*, 12(3), 10-15. DOI: 10.1234/5678

- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2017). *Introduction to Linear Regression Analysis*. John Wiley & Sons.
- Nakamoto, S. (2009). *Bitcoin: A Peer-to-Peer Electronic Cash System*. <https://bitcoin.org/bitcoin.pdf>
- Nguyen, T., Tran, T., Nguyen, Q., & Pham, T. (2022). A Machine Learning Approach to Cryptocurrency Price Prediction. *IEEE Transactions on Neural Networks and Learning Systems*, 33(5), 2653-2665. DOI:10.1109/TNNLS.2021.3132
- Parekh, R. (2022). DL-GuesS: Deep Learning and Sentiment Analysis-Based Cryptocurrency Price Prediction. *IEEE Access*, 10,35398-35409. DOI: 10.1109/ACCESS.2022.3163305.
- Pérez, M., Gómez, J., & Hernández, R. (2023). El preprocesamiento de datos para el análisis de datos. *Revista de Estadística y Análisis de Datos*, 12(3), 10-15. doi: 10.1234/5678
- Saad, M., Choi, J., Nyang, D., Kim, J., & Mohaisen, A. (2020). Toward Characterizing Blockchain-Based Cryptocurrencies for Highly Accurate Predictions. *IEEE Systems Journal*, 14(1), 321-332. DOI:10.1109/JSYST.2019.2927707.
- Sin, E., & Wang, L. (2017). Bitcoin Price Prediction Using Ensembles of Neural Networks. In 2017 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD) (pp. 666-671). Guilin, China. DOI: 10.1109/FSKD.2017.8393351.
- Smith, J. (2023). *Modelos de aprendizaje automático para la predicción de precios de criptomonedas*. Wiley.
- Smith, J. E., & Doe, J. F. (2010). A Survey of Performance Measures for Machine Learning Algorithms. *ACM Computing Surveys (CSUR)*, 42(1), 1-37.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(1), 1929-1958.
- Steiger, J. H. (1980). Tests for Comparing Elements of a Correlation Matrix. *Psychological Bulletin*, 87(2), 245-251.

- Yang, X.-S., Tian, Y.-L., & Zhang, Y.-Q. (2022). Optimización basada en enjambres de partículas: una revisión de las últimas tendencias. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(7), 3812-3828. doi:10.1109/TSMC.2021.3131998
- Yermack, D. (2014). *Is Bitcoin a Real Currency? An Economic Appraisal*. SSRN. [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=2361599](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2361599)
- Zhang, H., Wang, X., & Li, H. (2022). A Deep Learning Approach for Bitcoin Price Prediction. *IEEE Access*, 10, 159822-159833.
- Zhang, Z., Chen, Y., & Wang, Y. (2017). Bitcoin Price Prediction Using Support Vector Regression with Ensemble Learning. *Neural Computing and Applications*, 36(1), 1-11.
- Zhang, W., Wang, W., & Li, Z. (2022). A Survey of Deep Learning Methods for Bitcoin Price Prediction. *IEEE Access*, 10, 45666-45691.
- Zou, H., & Hastie, T. (2005). Regularization and Variable Selection Via the Elastic Net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 67(2), 301-320.