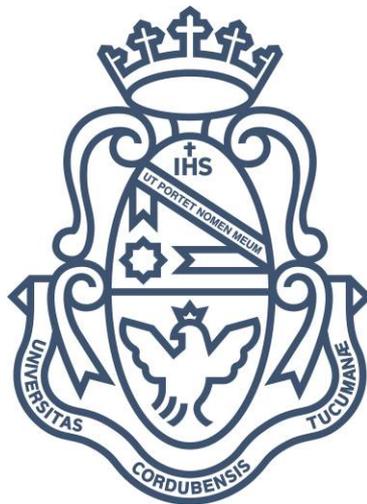


FACULTAD DE MATEMÁTICA, ASTRONOMÍA, FÍSICA Y  
COMPUTACIÓN

UNIVERSIDAD NACIONAL DE CÓRDOBA



## Aplicación de técnicas de predicción automática para operar en el mercado de criptomonedas

TESIS PARA OBTENER EL TÍTULO DE  
LICENCIADO EN CIENCIAS DE LA COMPUTACIÓN

AUTOR: AGUSTÍN MARCHI

DIRECTORES: LUIS BIEDMA · CRISTIAN CARDELLINO

CÓRDOBA, ARGENTINA 2021



Esta obra está bajo una [Licencia Creative Commons Atribución - No Comercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/).



# Agradecimientos

A toda mi familia por su apoyo incondicional durante toda la carrera. A todas mis amistades y compañeros de estudio, que me acompañaron durante este camino como estudiante. A mis directores Cristian y Luis por haberme guiado de forma constante y por haberme apoyado durante el desarrollo de la tesis. A la Universidad Nacional de Córdoba, y particularmente a la Facultad de Astronomía, Matemática, Física y Computación por la excelente calidad académica en cuanto a contenidos y profesores.



# Resumen

En este trabajo el objetivo final es la creación de un agente para operar automáticamente en el mercado de criptomonedas. Para ello se explorarán diferentes técnicas de predicción en 3 etapas de experimentos: en una primer etapa se explorarán algoritmos más clásicos para operación automática, como por ejemplo la utilización de medias móviles u otros indicadores técnicos como bandas de Bollinger, definición de soportes y resistencias, etc., en una segunda etapa se harán experimentos en el área de análisis de series temporales; finalmente, en una tercera etapa, se trabajará sobre técnicas de aprendizaje automático más avanzado, como redes neuronales recurrentes. En una cuarta etapa, se trabajará en implementar una aplicación, a modo de interfaz API, que aplique de manera automática los mejores modelos sobre un conjunto de criptomonedas para buscar predecir mejores opciones de inversión.



# Índice general

<b>1. Introducción y motivación</b>	<b>1</b>
1.1. Introducción . . . . .	1
1.2. Motivación . . . . .	2
1.3. Esquema de la tesis . . . . .	3
<b>2. Trabajo Relacionado</b>	<b>5</b>
2.1. Conceptos básicos . . . . .	5
2.2. BITCOIN: Un sistema de efectivo electrónico peer-to-peer . . . . .	6
2.3. Trading de Criptomonedas: Un Estudio en Profundidad . . . . .	7
2.4. Trading Cuantitativo de Criptomonedas . . . . .	8
<b>3. Metodología</b>	<b>11</b>
3.1. Backtesting . . . . .	11
3.2. Objetivo . . . . .	11
3.3. Indicadores técnicos . . . . .	12
3.3.1. Moving Average (MA) . . . . .	12
3.3.2. Simple Moving Average (SMA) . . . . .	12
3.3.3. Media Móvil Exponencial (EMA) . . . . .	12
3.3.4. Bollinger Bands . . . . .	14
3.3.5. Moving Average Convergence Divergence (MACD) . . . . .	16
3.3.6. Divergencias en MACD . . . . .	16
3.3.7. Crossover en MACD . . . . .	16
3.3.8. Relative Strength Index (RSI) . . . . .	17
3.4. Aprendizaje automático como señal . . . . .	18
3.4.1. Algoritmos . . . . .	18
3.4.2. Etiquetado . . . . .	19
3.4.3. Métricas . . . . .	20
3.4.4. Features . . . . .	20
3.5. Reglas de entrada o salida predefinidas . . . . .	20
3.5.1. Stop Loss (SL) . . . . .	20
3.5.2. Take Profit (TP) . . . . .	20
3.5.3. Trailing Stop . . . . .	20
3.5.4. Dollar cost averaging (DCA) . . . . .	21
3.6. Librerías de backtesting . . . . .	21
3.6.1. Zipline . . . . .	21
3.6.2. Backtrader . . . . .	22

3.7.	Métricas . . . . .	22
3.7.1.	Net Profit . . . . .	22
3.7.2.	Sharpe Ratio . . . . .	22
3.7.3.	Maximum Drawdown . . . . .	23
3.7.4.	Rendimiento Total Anual . . . . .	23
<b>4.</b>	<b>Diseño experimental</b>	<b>25</b>
4.1.	Base de los experimentos . . . . .	25
4.2.	Experimentos: Mercado en Baja (2018) . . . . .	25
4.2.1.	Experimentos basados en análisis técnico . . . . .	26
4.2.2.	Experimentos basados en aprendizaje automático . . . . .	28
4.3.	Experimentos: Mercado en Alza (2019) . . . . .	31
4.3.1.	Experimentos basados en análisis técnico . . . . .	31
4.3.2.	Experimentos basados en aprendizaje automático . . . . .	33
<b>5.</b>	<b>Análisis de resultados</b>	<b>35</b>
5.1.	Objetivo principal . . . . .	35
5.2.	Resultados: Mercado en Baja (2018) . . . . .	35
5.2.1.	Benchmark . . . . .	36
5.2.2.	Balance inicial, balance final y profit . . . . .	36
5.2.3.	Drawdown . . . . .	36
5.2.4.	Sharpe ratio . . . . .	37
5.2.5.	Mejores estrategias vs benchmark y peor estrategia . . . . .	37
5.2.6.	Conclusión mercado bajista . . . . .	38
5.3.	Resultados: Mercado en Alza (2019) . . . . .	38
5.3.1.	Benchmark . . . . .	39
5.3.2.	Balance inicial, balance final y profit . . . . .	39
5.3.3.	Drawdown . . . . .	39
5.3.4.	Sharpe ratio . . . . .	39
5.3.5.	Mejores estrategias vs benchmark y peor estrategia . . . . .	39
5.3.6.	Conclusión mercado alcista . . . . .	40
5.4.	Resultados vs objetivo final . . . . .	41
<b>6.</b>	<b>Conclusión y trabajo futuro</b>	<b>43</b>
6.1.	Conclusiones . . . . .	43
6.2.	Trabajo Futuro . . . . .	44
	<b>Bibliografía</b>	<b>45</b>

# Capítulo 1

## Introducción y motivación

### 1.1. Introducción

Las *criptomonedas* son activos digitales, cuyo propósito de creación fue ser utilizadas como divisas en transacciones digitales. Estas se diferencian de las divisas de curso legal en diferentes cuestiones, además de la ausencia física de las mismas. Algunas se pensaron con mecanismos que eviten emisión ilimitada, control por parte de un intermediario (generalmente gobiernos), privacidad, restricciones de acceso, etc.

Muchas de las criptomonedas más famosas no tienen por sí mismas un valor monetario, pero a partir de sus utilidades y la adopción que tienen en el mercado se cotizan en contra de las monedas de curso legal. Este valor intrínseco de las mismas se genera a partir de las reglas de oferta y demanda del mercado.

Dentro de las criptomonedas más conocidas, se encuentran Bitcoin (BTC), Ethereum (ETH), Tether (USDT), Ripple (XRP), entre otras.

Algunas de las ventajas conceptuales de BTC y ETH es su descentralización, esto quiere decir que no son controladas por ningún ente estatal, en cambio, están creadas para funcionar a partir de un protocolo que las genera y permite la utilización de las mismas sobre lo que se llama cadena de bloques, o más comúnmente en inglés, *blockchain*.

Un *blockchain* es un sistema de registro digital para guardar información en bloques encadenados a partir de funciones criptográficas de forma inmutable y distribuida. En este caso, cada bloque de la cadena contiene registros de transacciones, junto con un hash (i.e. un identificador único criptográfico) del bloque anterior y una marca de tiempo. Dado que cada bloque contiene la información del bloque anterior se forma una cadena entre ellos. Como cada bloque agregado se suma a los anteriores, la inmutabilidad en los datos registrados en las cadenas de bloques está garantizada por que los datos en cualquier bloque dado no se pueden alterar de manera retroactiva sin alterar todos los bloques subsiguientes. Se puede pensar a la blockchain como a un libro contable, donde en cada página quedan registrados los cálculos de las distintas operaciones financieras de una empresa, y parte del resultado es obtenido de la página anterior.

Al contrario de las anteriores, XRP y USDT no son completamente descentralizadas, ya que su emisión es controlada por una sociedad de personas, que concentran una cantidad muy significativa del total de las mismas. Aun así, no todas son desventajas, ya que algunas criptomonedas centralizadas y manejadas por entidades serias y auditadas, tienen ventajas como mayor estabilidad en su precio lo que logra que también sean muy

utilizadas por la comunidad.

Aún así, la creciente adopción de las criptomonedas se puede notar en la vida cotidiana: se están empezando a usar en gran medida para facilitar transacciones entre personas que intercambian servicios o productos, o simplemente dados los beneficios de mover dinero sin las limitaciones y restricciones de la banca tradicional, tales como la baja comisión para mover ese dinero más allá de la cantidad que sea, la velocidad y seguridad de las transacciones, mayor celeridad administrativa, entre otros. Por otro lado, además de lo anteriormente mencionado, otra gran ventaja, es la libertad a la hora de realizar transferencias, cualquier persona, de cualquier edad, en cualquier parte del mundo con conexión a internet puede ejecutarlas o recibirlas, sin mayor inconveniente.

Además de la adhesión en situaciones cotidianas, también han experimentado una amplia aceptación en el mercado y un rápido desarrollo, a pesar de ser una tecnología medianamente nueva. Muchos fondos de cobertura y administradores de activos han comenzado a incluir criptomonedas en sus carteras y estrategias comerciales de inversión (Fang et al., 2021).

El objetivo principal de esta tesis es el estudio de algoritmos y modelos para hacer operaciones automáticas de compra-venta, conocido comúnmente en inglés como *trading*, en el mercado de criptomonedas. Dichos modelos y algoritmos buscan maximizar la ganancia haciendo operaciones automatizadas de compra-venta de activos en los mercados de criptomonedas, conocido comúnmente en inglés como *exchange*. Esto se conoce como *automated trading* o también *trading automatizado*.

A partir de los distintos algoritmos y modelos se crea un “bot” de *trading automatizado*, que se encarga de comprar y vender activos a partir de ciertas reglas y estrategias de decisión que surgen del constante monitoreo de movimientos del mercado. Al ser automatizado, el modelo puede hacer operatorias de compra-venta sin intervención humana. La idea final es crear estrategias que permitan generar más ganancias que pérdidas a partir de señales captadas en el mercado, que generen operaciones automáticas de compra o venta. Estas estrategias suelen estar basadas en: indicadores técnicos, que son heurísticas basadas en patrones de movimientos de precios o volumen, calculadas utilizando herramientas estadísticas como la media y la desviación estándar; o bien mediante métodos más complejos como son los modelos de aprendizaje automático.

## 1.2. Motivación

El trading de activos (bonos, acciones, criptomonedas, etc.) es una parte importante de la macroeconomía mundial. Existen numerosas personas que dedican su vida al trading diario, intentando obtener ganancias de manera activa con su propio capital o trabajando para fondos de inversión manejando capital de terceros.

Por la naturaleza dinámica de cualquier mercado, en especial de activos financieros de mayor variabilidad (e.g. acciones o criptomonedas), el trading manual presenta serios desafíos para quien realiza las operaciones puesto que las decisiones de compra o venta que se hagan demasiado tarde o temprano afectan directamente las ganancias finales de quien está realizando las operaciones de trading. Por este motivo, es importante que una persona que hace trading de forma manual tenga la preparación psicológica para poder sobrellevar situaciones de grandes ganancias o de grandes pérdidas, sabiendo que ambos escenarios van a ocurrir eventualmente, como también, la disponibilidad de tiempo para

prestar atención constantemente a las fluctuaciones de precios de los activos que son monitoreados.

El propósito de usar trading automatizado no sólo es obtener ganancias “comprando barato” y “vendiendo caro”, si no también, abordar mejor estos desafíos anteriormente mencionados, ya que un “bot” de trading automático puede estar constantemente monitoreando el mercado, y siempre tomará las mismas decisiones basadas en las reglas o estrategias con las que fue programado, sin importar cuánta sea la ganancia o la pérdida en cuestión, es decir, se elimina el factor emocional en cada operación. A su vez, la velocidad para hacer transacciones de un bot es muy alta, pudiendo hacer miles de transacciones por minuto.

Así como hay numerosas ventajas, también hay desventajas en el trading automatizado, ya que cada algoritmo está creado para funcionar correctamente cuando el comportamiento del mercado es el esperado. Toda estrategia necesita ser constantemente supervisada evaluando que el algoritmo haga lo que se supone debe hacer, es decir, se necesita atención por parte del usuario midiendo y monitoreando la performance de la estrategia con el pasar del tiempo, dado que puede haber eventos inesperados o un comportamiento del mercado distinto al cual el algoritmo fue preparado (Kissell, 2021).

### 1.3. Esquema de la tesis

La tesis está organizada de la siguiente manera: en el Capítulo 2 se introducen los conceptos fundamentales a ver durante el resto del trabajo y se hace un resumen de algunos trabajos importantes relacionados al tema de criptomonedas en general, y de trading de criptomonedas en particular. En el Capítulo 3 se explica las herramientas y librerías utilizadas para llevar a cabo las pruebas o experimentos, junto con la descripción de las técnicas principales a la hora de evaluar y comparar estrategias de trading. En el Capítulo 4 se detallan los experimentos realizados a partir de la utilización de algoritmos de trading automatizados, frente a las distintas posibles condiciones del mercado. En el Capítulo 5 se analizan los resultados obtenidos en los experimentos, junto con una comparación analítica y cuantitativa de los retornos obtenidos y los riesgos enfrentados en cada caso. Por último, el Capítulo 6 presenta las conclusiones finales sobre el proyecto y los resultados, además de establecer algunas posibles líneas de investigación como trabajo futuro.



# Capítulo 2

## Trabajo Relacionado

En el presente capítulo se dará una breve introducción a los conceptos básicos abordados en este trabajo de tesis. Además se describen tres artículos relacionados que fueron una importante guía para encaminar el desarrollo del trabajo. El capítulo empieza con una introducción sencilla a los temas más trabajados en este documento, incluyendo conceptos relacionados a las plataformas de trading, o a las criptomonedas en general. Luego se describen los tres artículos anteriormente mencionados. El primero, relacionado al primer trabajo existente en esta área, el artículo de Bitcoin. El segundo, un trabajo relacionado a una investigación en modo estadístico acerca de las tendencias en el mundo de las criptomonedas y el trading automatizado. El último, un artículo enfocado en probar algunas técnicas de trading automatizado.

### 2.1. Conceptos básicos

**Cryptocurrency Wallet** Una billetera de criptomonedas, más conocida como *cryptocurrency wallet* (o simplemente *wallet*), es un medio (físico o digital) creado para gestionar criptomonedas de manera segura y descentralizada, utilizando direcciones privadas y públicas a partir de las cuales cada usuario puede acceder al bloque correspondiente en la blockchain en el cual se encuentran sus criptomonedas. Existen diferentes tipos de wallets, tales como las hardware wallets, aplicaciones móviles o de escritorio que varían en su usabilidad y hacia el tipo de usuario al que están dirigidas. Existen incluso las llamadas "paper wallets" que proveen un mecanismo para guardar criptomonedas de manera offline, ya que operan de forma separada de internet (Jake Frankenfield, 2021).

**Exchange** Un exchange es una plataforma que permite a los usuarios comerciar criptomonedas. El exchange cobra una comisión por cada compra o venta que se realiza y cuando se hace un retiro de alguna criptomoneda hacia una wallet.

**Orden** Las órdenes son las instrucciones que se le dan a un exchange para poder comprar o vender un activo. Las órdenes son la unidad comercial fundamental en un mercado de valores. Una vez que se coloca una orden, la misma sigue un proceso de ejecución. Existen distintos tipos de órdenes según se busque operar inmediatamente o esperar un determinado precio del activo (Cory Mitchell, 2020).

**Libro de órdenes** El término libro de órdenes se refiere a la lista electrónica de órdenes de compra y venta para un activo específico o instrumento financiero, organizada por nivel de precio, enumerando la cantidad de activos que se ofrecen en cada punto de precio o profundidad del mercado. También identifica a los participantes del mercado detrás de las órdenes de compra y venta. Estas listas ayudan a los *traders* o comerciantes de criptomonedas a tomar decisiones a la hora de comprar o vender un activo. También mejoran la transparencia del mercado porque proporcionan información comercial valiosa.

**Tipos de órdenes** Existen muchos tipos de órdenes, que varían en su constitución o en su forma de ejecución, a continuación se explican algunas de las más utilizadas.

- **Limit-order:** Indica al exchange que se quiere comprar o vender un activo a un precio específico o por debajo o encima del mismo, respectivamente. Las órdenes de límite aseguran que un comprador pague solo un precio específico para comprar un activo. Las órdenes de límite pueden permanecer en espera hasta que se ejecuten, venzan o se cancelen.
- **Market-order:** Indica al exchange que se quiere comprar o vender un activo en el momento sin importar el precio o “al precio de mercado”, es decir se toman los valores más próximos de venta y compra del libro de órdenes y se ejecuta la acción hasta que el activo haya sido completamente vendido o comprado.

**Análisis técnico** El análisis técnico en el trading de criptomonedas es el acto de utilizar patrones históricos de datos de transacciones para evaluar las condiciones actuales y futuras del mercado con el fin de hacer operaciones rentables. Los gráficos de precios y volúmenes resumen toda la actividad comercial realizada por los participantes del mercado en un exchange. Algunos experimentos demostraron que el uso de reglas técnicas específicas de negociación permite generar excelentes rendimientos, lo que es útil para los operadores de criptomonedas e inversores en la toma de decisiones comerciales y para realizar inversiones óptimas (Fang et al., 2021).

## 2.2. BITCOIN: Un sistema de efectivo electrónico peer-to-peer

En este paper Satoshi Nakamoto explica los conceptos fundamentales sobre el funcionamiento de Bitcoin, la primer criptomoneda creada.

En principio, el comercio en Internet depende exclusivamente de instituciones financieras, las cuales sirven como terceros confiables para el procesamiento de pagos electrónicos. Mientras que el sistema funciona lo suficientemente bien para la mayoría de las transacciones, aún sufre de las debilidades inherentes del modelo basado en confianza. Para solucionar esto, se planteó un sistema de pagos electrónicos basado en pruebas criptográficas en vez de confianza, permitiéndole a las partes interesadas realizar transacciones directamente sin la necesidad de un tercero confiable.

Como se menciona anteriormente, la idea de “cadena de bloques” está relacionada a cómo se van conectando las distintas transacciones que suceden a lo largo del tiempo.

Estas conexiones entre las transacciones es lo que va formando una cadena entre ellas, una cadena de firmas digitales, ya que para que se pueda transferir una criptomoneda desde un lugar a otro, cada dueño transfiere la moneda al próximo al firmar digitalmente un hash de la transacción previa junto con la clave pública del próximo dueño, agregando estos al final de la moneda (Nakamoto, 2008).

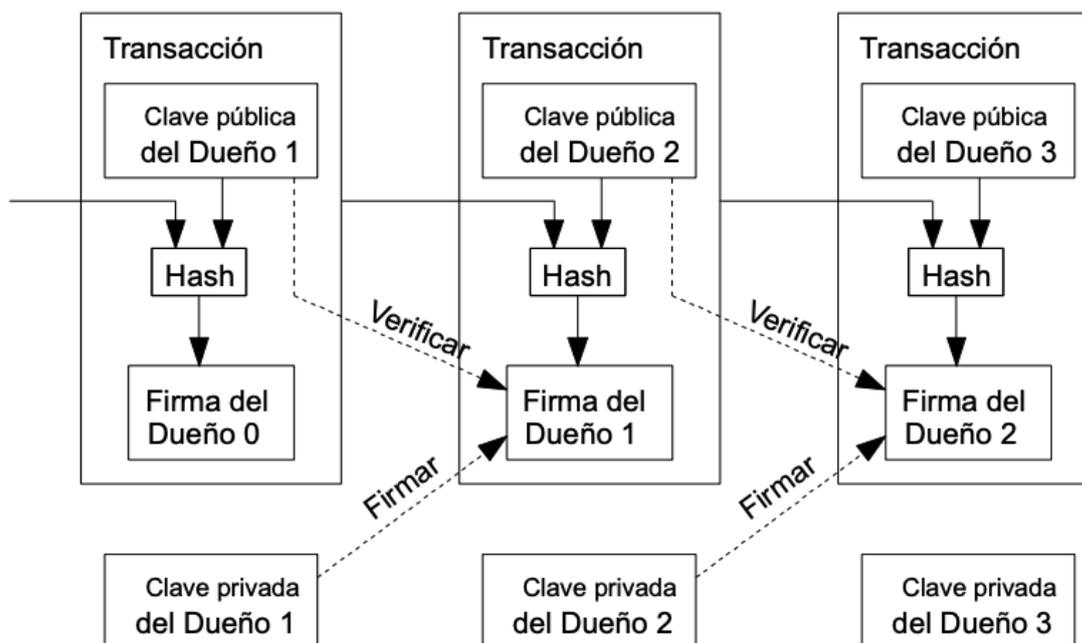


Figura 2.1: Esquema de transacciones en la red de Bitcoin (Nakamoto, 2008).

## 2.3. Trading de Criptomonedas: Un Estudio en Profundidad

Las criptomonedas han experimentado una amplia aceptación en el mercado y un rápido desarrollo a pesar de su reciente concepción.

La comunidad académica cada año dedica más esfuerzo a la investigación sobre el trading de criptomonedas. En este trabajo se busca proporcionar una encuesta completa sobre el crecimiento de investigaciones en la materia o de cualquier estudio dirigido a facilitar y construir estrategias para este propósito.

Hay muchas estrategias, que pueden ser divididas en dos categorías principales: técnica y fundamental. Son similares en el sentido de que ambas dependen de información cuantificable que pueda contrastarse con datos históricos para verificar su desempeño.

La parte técnica, esta orientada a la utilización de patrones y predicción de tendencias a partir del uso de análisis técnico, como se menciona anteriormente.

La parte fundamental, se enfoca en la obtención de todo tipo de información relacionada a la criptomoneda en cuestión. Esto incluye datos como perspectivas a futuro del

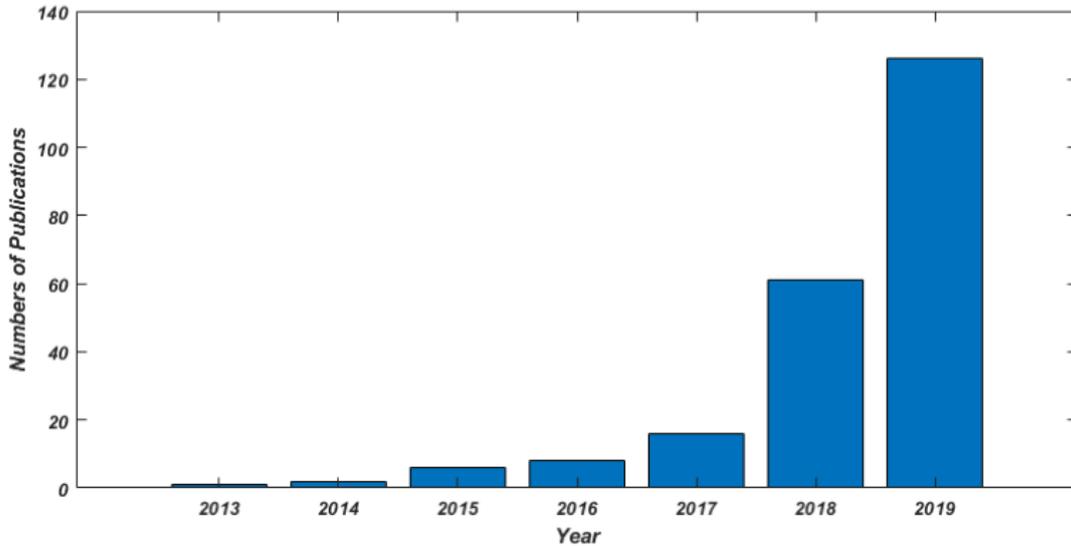


Figura 2.2: Publicaciones acumuladas sobre trading automatizado de criptomonedas entre 2013 y 2019. Fuente: (Fang et al., 2021)

activo, el equipo de trabajo, vulnerabilidades del proyecto, y opiniones o sensaciones del público en general.

En los años recientes, un tercer tipo de estrategia comercial, llamada cuantitativa, ha recibido una atención creciente. Esta es similar a una estrategia de negociación técnica porque utiliza la información de la actividad comercial en el exchange para realizar compras o decisiones de venta. Los traders cuantitativos crean estrategias comerciales con datos cuantitativos, que se derivan principalmente de precio, volumen, indicadores técnicos o ratios para aprovechar las ineficiencias del mercado.

El mercado de criptomonedas es diferente de los mercados tradicionales, ya que permite tener mayor cantidad de oportunidades debido a la gran fluctuación y volatilidad de los precios. Debido a estas características, la mayoría de los traders y analistas prefieren utilizar estrategias cuantitativas en los mercados de criptomonedas. (Fang et al., 2021).

Aplicando a esto el trading automatizado, se definen los objetivos, los controles y las reglas para manejar el riesgo.

## 2.4. Trading Cuantitativo de Criptomonedas: Explorando Técnicas de Machine Learning

En las dos últimas décadas, la comunidad de investigadores ha explorado profundamente el uso de técnicas de aprendizaje automático (por ejemplo, clasificación, regresión, pronóstico de series de tiempo) para generar automáticamente operaciones rentables basadas en señales, para los mercados tradicionales.

Sin embargo, con la llegada de la red Bitcoin en 2009, nuevas plataformas comerciales para el intercambio de criptomonedas (exchanges) fueron apareciendo. Debido a la falta de estacionalidad y la alta volatilidad del mercado de intercambio de criptomonedas, la

efectividad de la predicción de los modelos no está garantizada.

Este trabajo explora la aplicabilidad de técnicas de aprendizaje automático para predecir los precios al día siguiente de una variedad de criptomonedas. Además, presenta un sistema de trading automatizado que combina las señales generadas por varias criptomonedas y prueba su desempeño durante un período de ocho años con diferentes modelos de predicción y en condiciones de mercado heterogéneas (Attanasio et al., 2019).

La mayoría de los estudios recientes sobre el comercio cuantitativo de criptomonedas tenían como objetivo pronosticar el precio de Bitcoin, que es la principal criptomoneda dado su dominio por sobre las demás: su capitalización total está en los miles de millones de USD.

A su vez, este artículo busca enfocar la investigación de manera distinta a la mayoría de los trabajos existentes de la materia, ya que se tratan las siguientes limitaciones:

- La mayoría de los trabajos anteriores se centran en Bitcoin, sin tener en cuenta las otras criptomonedas (potencialmente rentables).
- Los enfoques que se basan en múltiples criptomonedas no han explorado las ventajas de aprovechar posiciones comerciales en múltiples criptomonedas.
- En ocasiones, el backtesting se ha realizado durante un lapso de tiempo limitado, sin tener en cuenta la heterogeneidad del mercado.

En este documento se tiene como objetivo superar las limitaciones mencionadas proponiendo una estrategia basada en el trading de múltiples criptomonedas.

La estrategia propuesta integra varios modelos de predicción, incluidas algunas de las técnicas de clasificación más establecidas, como algunos métodos populares de pronóstico de series de tiempo o modelos de clasificación.

Para validar los modelos utilizados y el rendimiento de los mismos, se considera un período de ocho años caracterizado por condiciones de mercado heterogéneas en el cual, para cada modelo de predicción, se explora la capacidad de generar automáticamente operaciones rentables.

Los pasos principales que se utilizan usualmente, a la hora de generar una estrategia, son los siguientes:

- Fase de recopilación y preparación de datos: para cada criptomoneda, se descarga y almacena los datos históricos de precios y volumen en periodo de un día y se enriquece con características adicionales.
- Fase de entrenamiento: por separado para cada criptomoneda, los modelos de predicción se entrenan sobre datos históricos utilizando un enfoque de ventana en expansión.
- Generación de señales comerciales: los modelos entrenados se aplican para predecir las variaciones del precio de la criptomoneda al día siguiente.
- Cuando las variaciones de precio esperadas son lo suficientemente grandes, se generan señales de compra o venta.

- Gestión comercial y del dinero: las señales generadas en función de los modelos de aprendizaje automático se utilizan para hacer operaciones basándose en los resultados de predicción generados en los días considerados.

# Capítulo 3

## Metodología

En este capítulo se desarrolla la metodología utilizada durante este trabajo de tesis. Las siguientes secciones expandirán sobre los métodos utilizados durante la experimentación, los problemas encontrados y las formas planteadas para solucionarlos.

### 3.1. Backtesting

El backtesting es la principal técnica utilizada como forma de medir resultados de algoritmos o estrategias junto con el impacto del mercado en los mismos utilizando datos históricos.

Su objetivo principal es probar ideas de inversión y determinar si esas ideas tienen potencial para ser rentables en diferentes condiciones de mercado.

La idea de esta técnica es simular cómo hubieran funcionado las estrategias de trading ejecutándolas sobre los datos históricos de una criptomoneda o activo financiero.

Cuando se habla de datos históricos se hace referencia a los distintos datos relacionados a un activo financiero, los más comúnmente utilizados son el precio más alto y bajo, el precio de cierre y el volumen transaccionado.

Luego de ejecutar backtesting sobre alguna estrategia de trading se obtienen métricas y estadísticas acerca de su rendimiento, permitiendo analizar algunos indicadores que llevan a entender si la estrategia funciona como se esperaba o no.

Sin embargo, el backtesting es simplemente una forma de medir que la estrategia hace lo que debería hacer según como fue implementada, pero de ningún modo eso asegura que el resultado de aplicar una estrategia exitosa en backtesting en el futuro será igual de beneficiosa que en el pasado.

### 3.2. Objetivo

En este trabajo de tesis, el objetivo principal es encontrar una o más estrategias que, combinando indicadores técnicos, reglas de compra-venta y clasificadores supervisados puedan obtener una rentabilidad haciendo trading automatizado en el mercado de criptomonedas. Para poder probar y estudiar algunas de las infinitas estrategias posibles se probaron distintos frameworks para hacer backtesting, en la sección 3.6 se profundiza

sobre algunos de los frameworks disponibles, para luego implementar cada una de las estrategias propuestas. El procedimiento para probar cada estrategia consistió en:

- Implementar la estrategia utilizando indicadores técnicos y/o machine learning.
- Ejecutar la estrategia en diferentes rangos de meses entre 2017 y 2020.
- Evaluar resultados y ajustar parámetros.

### 3.3. Indicadores técnicos

Como se menciona anteriormente, los indicadores técnicos utilizan los precios históricos de un activo para poder pronosticar lo que podría suceder en los próximos momentos si el activo se comportara como lo viene haciendo anteriormente. Existen numerosos tipos de indicadores técnicos, indicadores de tendencia, de momento, de volatilidad, de volumen, etc.

#### 3.3.1. Moving Average (MA)

En estadística, una media móvil es un cálculo que se utiliza para analizar puntos de datos creando una serie de promedios entre diferentes subconjuntos del conjunto de datos completo. En finanzas, o en los mercados de criptomonedas, un promedio móvil (MA) es un indicador que se usa comúnmente en análisis técnico (Jason Fernando, 2019).

La razón para calcular la media móvil de un activo es ayudar a suavizar los datos de precios mediante la creación de un precio promedio actualizado constantemente. Al calcular la media móvil, se mitigan los impactos de las fluctuaciones aleatorias a corto plazo en el precio de un activo durante un período de tiempo específico.

#### 3.3.2. Simple Moving Average (SMA)

La forma más simple de una media móvil, conocida como media móvil simple (SMA), se calcula tomando la media aritmética de un conjunto dado de valores. En otras palabras, un conjunto de números, o precios en el caso de los instrumentos financieros o criptomonedas, se suman y luego se dividen por el número de precios del conjunto. La fórmula para calcular la media móvil simple de un valor es la siguiente:

$$SMA = \frac{A_1 + A_2 + \dots + A_n}{n} \quad (3.1)$$

En donde  $A_i$  es el promedio en el período  $n$  y  $n$  es el número de períodos de tiempo. La Figura 3.1 muestra un ejemplo de una SMA.

#### 3.3.3. Media Móvil Exponencial (EMA)

La media móvil exponencial (*exponential moving average* o EMA, en inglés) es un tipo de media móvil que le da más peso a los precios recientes intentando priorizar la información más cercana al punto actual.



Figura 3.1: Ejemplo de una media móvil simple de 200 periodos (simple moving average).

Para calcular una EMA, primero se debe calcular la media móvil simple (SMA) durante un período de tiempo particular. A continuación, se calcula el multiplicador para ponderar la EMA (denominado "factor de suavizado"), que normalmente sigue la fórmula:

$$\frac{2}{\text{período de tiempo seleccionado} + 1}$$

Entonces, por ejemplo, si se quiere calcular una EMA de 20 periodos, el multiplicador sería  $\frac{2}{20+1} = 0,0952$ . Luego, usando el factor de suavizado combinado con la EMA anterior se obtiene el valor actual. Por lo tanto, la EMA otorga una mayor ponderación a los precios recientes, mientras que la SMA asigna la misma ponderación a todos los valores.

$$EMA_t = \left[ V_t \times \left( \frac{s}{1+d} \right) \right] + EMA_y \times \left[ 1 - \left( \frac{s}{1+d} \right) \right] \quad (3.2)$$

Donde  $EMA_t$  es el EMA de hoy,  $V_t$  es el valor de hoy,  $EMA_y$  es el valor de ayer,  $s$  es el suavizado y  $d$  es el número de periodos.

La Figura 3.2 muestra un ejemplo de media móvil exponencial de 200 periodos, sobre el año 2018.



Figura 3.2: Ejemplo de una media móvil exponencial de 200 periodos (exponential moving average).

### 3.3.4. Bollinger Bands

Las Bandas de Bollinger fueron creadas y patentadas por el famoso trader técnico John Bollinger, diseñadas principalmente para encontrar señales de compra o venta, que permite a los inversores identificar más precisamente cuando un activo está sobrevendido o sobrecomprado (Adam Hayes, 2021).

Una Bollinger Band es un indicador técnico definido por un conjunto de líneas de tendencia que trazan cierta cantidad de desviaciones estándar (positiva y negativamente) de un promedio móvil simple (SMA) del precio de un valor.

$$\text{BOLU} = \text{MA}(\text{TP}, n) + m * \sigma[\text{TP}, n]$$

$$\text{BOLD} = \text{MA}(\text{TP}, n) - m * \sigma[\text{TP}, n]$$

Donde:

BOLU = Bollinger Band alta

BOLD = Bollinger Band baja

TP (precio típico) = (Alto + Bajo + Cierre) / 3

$n$  = cantidad de periodos (generalmente 20)

$m$  = cantidad de desviaciones estándar (generalmente 2)

$\sigma[TP, n]$  = desviación estándar sobre los últimos  $n$  periodos de TP

En la Figura 3.3 las Bandas de Bollinger abarcan la SMA de 20 periodos diarios junto con la correspondiente banda superior e inferior de 2 (dos) desviaciones estándar. Debido a que la desviación estándar es una medida de volatilidad, cuando los mercados se vuelven más volátiles, las bandas se ensanchan y durante períodos menos volátiles, las bandas se contraen.

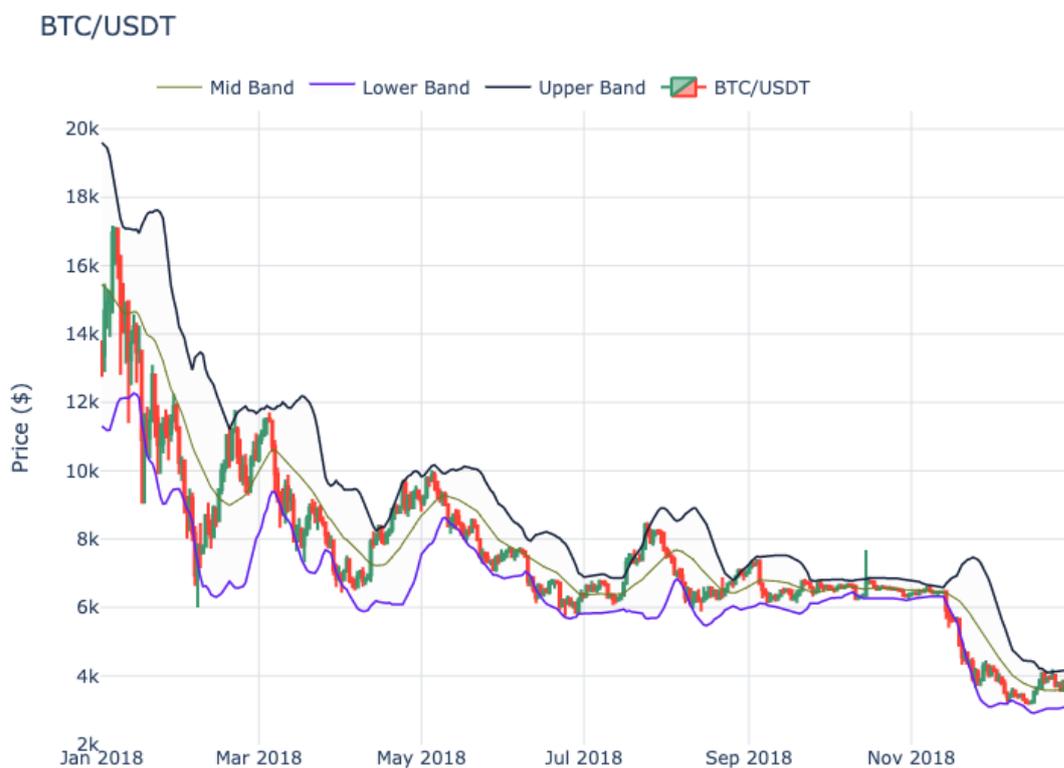


Figura 3.3: Ejemplo de bollinger bands 20 periodos y 2 desviaciones estandar.

En general, aproximadamente el 90% de la variación en el precio de un activo ocurre entre las dos bandas. Cualquier ruptura por encima o por debajo de las bandas es un evento importante. La ruptura no es una señal para iniciar o terminar una posición por sí sola, debe ser acompañada por otros indicadores para tener una mayor fiabilidad. Un error muy frecuente es creer que el precio que alcanza o supera alguna de las bandas es una señal para comprar o vender, pero esto es erróneo, ya que las rupturas no brindan ninguna pista sobre la dirección y el alcance del movimiento futuro de los precios.

### 3.3.5. Moving Average Convergence Divergence (MACD)

MACD es un indicador de impulso que sigue la tendencia y muestra la relación entre dos promedios móviles del precio de un valor. Se calcula restando la media móvil exponencial (EMA) “larga” y una EMA “corta”. En general se utilizan como EMA larga, una de 26 períodos y como EMA corta, una de 12 períodos. Por ejemplo, la fórmula en ese caso sería:

$$\text{MACD} = \text{EMA 12 periodos} - \text{EMA 26 periodos}$$

El resultado de ese cálculo es la línea MACD. A su vez, se utiliza una EMA de nueve períodos del MACD llamada “línea de señal” que se traza luego en la parte superior de la línea MACD, está puede funcionar como un disparador de señales de compra y venta. Los operadores pueden ejecutar una compra cuando el MACD cruza por encima de su línea de señal, o vender, cuando el MACD cruza por debajo de la línea de señal. Estos indicadores se pueden interpretar de varias maneras, pero los métodos más comunes son cruces, divergencias y subidas o caídas rápidas (Jason Fernando, 2021a). En la Figura 3.4 se muestra un ejemplo de MACD.

### 3.3.6. Divergencias en MACD

Cuando el MACD forma máximos o mínimos que divergen de los máximos y mínimos correspondientes en el precio, se denomina divergencia. Una divergencia alcista aparece cuando el MACD forma dos mínimos ascendentes que se corresponden con dos mínimos descendentes del precio. Esta es una señal alcista válida cuando la tendencia a largo plazo sigue siendo positiva.

Algunos traders buscarán divergencias alcistas incluso cuando la tendencia a largo plazo sea negativa porque pueden indicar un cambio en la tendencia, aunque esta técnica es menos confiable.

A su vez, cuando el MACD forma una serie de dos máximos descendentes que se corresponden con dos máximos ascendentes en el precio, se ha formado una divergencia bajista. Una divergencia bajista que aparece durante una tendencia bajista a largo plazo se considera una confirmación de que es probable que la tendencia continúe.

Hay casos en los cuales las divergencias bajistas durante las tendencias alcistas pueden ser interpretadas como una debilidad en la tendencia.

### 3.3.7. Crossover en MACD

Cuando el MACD cae por debajo de la línea de señal, es una señal bajista que indica que puede ser el momento de vender. Por el contrario, cuando el MACD sube por encima de la línea de señal, el indicador da una señal alcista, lo que sugiere que es probable que el precio del activo experimente un impulso alcista. En general se espera un cruce confirmado por encima de la línea de señal antes de entrar en una posición para reducir las posibilidades de ser “engañados” y entrar en una posición demasiado pronto.

Los crossovers son más fiables cuando se ajustan a la tendencia predominante. Si el MACD cruza por encima de su línea de señal luego de una breve corrección dentro de una tendencia alcista a más largo plazo, califica como confirmación alcista.



Figura 3.4: Ejemplo de MACD EMA 26 y 12, señal en 9.

### 3.3.8. Relative Strength Index (RSI)

El índice de fuerza relativa (RSI) es un indicador de impulso utilizado en el análisis técnico para medir la magnitud de los cambios de precios recientes y así evaluar las condiciones de sobrecompra o sobreventa en el precio de una acción u otro activo. Este indicador se muestra como un oscilador (un gráfico de líneas que se mueve entre dos extremos) y puede tener una lectura de 0 a 100.

La interpretación y el uso tradicionales del RSI son que los valores de 70 o más indican que un activo está sobrecomprado o sobrevalorado y puede ocurrir un cambio de tendencia o un retroceso correctivo en el precio. Una lectura de RSI de 30 o menos indica una condición de sobreventa (Jason Fernando, 2021b).

El RSI se calcula en dos etapas, la primera comienza con la siguiente fórmula:

$$RSI_{\text{Paso uno}} = 100 - \left[ \frac{100}{1 + \frac{\text{Ganancia promedio}}{\text{Pérdida promedio}}} \right]$$

La ganancia o pérdida promedio utilizada en el cálculo es el porcentaje de ganancia o pérdida promedio durante un período retrospectivo. La fórmula usa un valor positivo para la pérdida promedio.

El estándar es usar 14 períodos para calcular el valor RSI inicial. Por ejemplo, imagine que el mercado cerró al alza siete de los últimos 14 días con una ganancia promedio del 1%. Los siete días restantes cerraron todos a la baja con una pérdida promedio de -0,8%. El cálculo de la primera parte del RSI se vería como el siguiente cálculo:

$$55,55 = 100 - \left[ \frac{100}{1 + \frac{\left(\frac{1\%}{14}\right)}{\left(\frac{0,8\%}{14}\right)}} \right]$$

Una vez que hay 14 períodos de datos disponibles, se puede calcular la segunda parte de la fórmula RSI. El segundo paso del cálculo suaviza los resultados.

$$RSI_{\text{Paso dos}} = 100 - \left[ \frac{100}{1 + \frac{(\text{Promedio ganancia anterior} \times 13) + \text{Ganancia actual}}{(\text{Promedio perdida anterior} \times 13) + \text{Pérdida actual}}} \right]$$

En la Figura 3.5 se muestra un ejemplo de RSI.

## 3.4. Aprendizaje automático como señal

Como se ve anteriormente, una forma muy utilizada en los mercados para tomar decisiones de compra o venta sobre distintos activos es la utilización de indicadores técnicos. En este apartado se tratará otra de las opciones utilizadas en este trabajo de tesis, la cual es, utilizar un algoritmo de machine-learning entrenado a partir de indicadores técnicos, para poder obtener dichas señales de compra o venta.

### 3.4.1. Algoritmos

Los algoritmos son todos clasificadores basados en aprendizaje supervisado, es decir, además de tener suficiente cantidad de datos de entrenamiento, estos deben tener el correspondiente etiquetado para que el algoritmo pueda aprender del mismo.

Los clasificadores utilizados fueron los siguientes:

- Regresión Logística: Es un algoritmo que aplica técnicas de regresión lineal sobre la función logística (o logit) para resolver problemas de clasificación (Sammut and Webb, 2010).
- XGBoost: Es un algoritmo de ensamble basado en potenciación de gradiente, que mezcla un conjunto de modelos de predicción débiles, principalmente árboles de decisión. XGBoost está diseñado para ser escalable, eficiente y flexible (Chen and Guestrin, 2016).



Figura 3.5: Ejemplo de RSI 14 periodos.

- Light Gradient Boosting Machine (LightGBM): Es un algoritmo que utiliza el mismo mecanismo que XGBoost, pero con algunas diferencias en su implementación que le permiten una mayor libertad a la hora de elegir hiperparámetros (Ke et al., 2017).

### 3.4.2. Etiquetado

Para hacer el etiquetado se utilizaron los precios de cierre de cada período, calculando la diferencia porcentual entre un precio y el siguiente. En caso de que esta diferencia porcentual fuera mayor al 5%, entonces ese momento es etiquetado como positivo, caso contrario, como negativo. La distribución de positivos y negativos era aproximadamente un 90% de negativos y un 10% de positivos. Los umbrales fueron elegidos de esta manera ya que la distribución de cambios de precio porcentuales, estaba distribuida de forma

normal entre  $[-5\%, 5\%]$ . Además, usando estos umbrales, se asegura que cada movimiento ejecutado no se vea muy afectado por las comisiones, que rondan aproximadamente en el  $0,1\%$  de cada transacción.

### 3.4.3. Métricas

Las estrategias de análisis técnico, junto con las de aprendizaje automático que se analizarán en la sección de experimentos, están principalmente orientadas a crear buenas señales de compra. Para poder lograr esto, lo que se necesitaba predecir con mucha precisión eran los momentos positivos.

Esto lleva a elegir como métrica a maximizar la precisión, por sobre la exhaustividad, la exactitud y el puntaje F1, priorizando la precisión de las predicciones de valores positivos.

### 3.4.4. Features

Los features utilizados para entrenar los clasificadores están basados en los indicadores técnicos anteriormente mencionados, es decir, se construyeron a partir de los valores de los indicadores como RSI, Bollinger Bands, EMAs, MACD, etc.

## 3.5. Reglas de entrada o salida predefinidas

### 3.5.1. Stop Loss (SL)

El stop-loss es otro tipo de orden, la cual combina una condición de mercado junto con una market-order. Este tipo de orden se utiliza para limitar la máxima pérdida permitida si un activo baja de precio luego de haber sido adquirido por el trader. Cuando un activo cae por debajo del precio de parada (stop), se crea una orden de mercado para vender ese activo dado que su precio cayó lo máximo permitido por el trader, y ante la posibilidad de perder más, se asume la pérdida de ese porcentaje y se cierra esa posición. Por ejemplo, un trader puede comprar una acción y colocar una orden de stop-loss un  $10\%$  por debajo del precio de compra. Si esa acción cae un  $10\%$ , entonces se activará la orden de stop-loss y la acción se venderá al precio de mercado.

### 3.5.2. Take Profit (TP)

Una orden de take profit (TP) es un tipo de limit-order que especifica el precio exacto en el cual se va a cerrar una posición abierta para obtener ganancias. Si el precio del activo no alcanza el precio límite, la orden de TP no se ejecutará. Por ejemplo, un trader compra un activo a cierto precio, y coloca una limit-order de venta, a un precio  $5\%$  mayor al precio de compra.

### 3.5.3. Trailing Stop

Un trailing stop es una modificación de una orden de stop típica que se puede establecer en un porcentaje definido o en una cantidad en dólares del precio de mercado actual de un activo. Se trata de un “stop-loss” dinámico que se va actualizando en favor del trader, está

diseñado para maximizar ganancias al permitir que una operación permanezca abierta y el precio se mueva a favor del inversionista. La orden cierra la operación si el precio cambia de dirección en un porcentaje específico (Cory Mitchell, 2021).

Normalmente, se coloca un trailing stop al mismo tiempo que se realiza la operación inicial, aunque también puede colocarse después de la operación. Por ejemplo, un trader compra un activo a cierto precio, y decide utilizar trailing-stop al 3% para cerrar su posición, cuando el activo llegue a un precio 3% mayor al de su compra automáticamente se setea un nuevo objetivo de venta un 3% más arriba, si el activo sigue subiendo, esto continuará pasando y la “línea superior de venta” se seguirá actualizando. El activo finalmente será vendido una vez que cruce un segmento de 3% y luego baje el precio a un porcentaje de máxima tolerancia definido anteriormente, como podría ser 2%.

### 3.5.4. Dollar cost averaging (DCA)

El Dollar cost averaging (DCA) es una estrategia de inversión en la que un inversionista divide el monto total que se invertirá en compras periódicas de un activo objetivo con el propósito de reducir el impacto de la volatilidad en la compra final. Las compras ocurren independientemente del precio del activo y a intervalos regulares. En efecto, esta estrategia elimina gran parte del trabajo detallado de intentar calcular el tiempo del mercado para realizar compras de activos a los mejores precios.

Este mismo concepto puede utilizarse de manera automatizada como forma de disminuir la probabilidad de tener que cerrar una posición en pérdida.

En este caso, para aplicar esta estrategia como protección frente a una bajada de precio luego de haber adquirido una criptomoneda se tienen en cuenta tres factores:

1. Cantidad de recompras posibles.
2. Cantidad de criptomonedas obtenidas en cada recompra.
3. Distancia porcentual entre un precio de compra y su consecuente recompra.

## 3.6. Librerías de backtesting

### 3.6.1. Zipline

Zipline es una librería open source en Python para backtesting, creada y mantenida por la comunidad de Quantopian, una empresa que tenía como objetivo crear un fondo de cobertura de fuentes múltiples permitiendo que los analistas cuantitativos independientes desarrollaran, probaran y usaran algoritmos para comprar y vender activos. Quantopian ofrecía un servicio de backtesting en la nube. Zipline fue la primer herramienta con la que se intentó empezar a probar algunas estrategias, pero por ser un framework mantenido por la comunidad de Quantopian, el foco principal del mismo era el mercado de acciones estadounidense y no el mercado de criptomonedas, esto trajo algunos problemas de compatibilidad, como también complicaciones a la hora de configurar la librería, por lo que se decidió buscar otra alternativa (Spörer, 2020).

### 3.6.2. Backtrader

Backtrader, es un framework open source hecho en Python. La principal diferencia con Zipline y demás frameworks de backtesting, es que, Backtrader es una plataforma altamente configurable que permite más fácilmente el hecho de concentrarse en escribir estrategias, indicadores y analizadores comerciales reutilizables en lugar de tener que dedicar tiempo a la construcción de infraestructura. Por la naturaleza más sencilla de trabajo con Backtrader y las complicaciones encontradas con Zipline, es que finalmente se decidió que toda la experimentación, pruebas y mediciones realizadas sobre las distintas estrategias fueran desarrolladas usando este framework.

## 3.7. Métricas

Para poder comparar el rendimiento de las distintas estrategias, se utilizaron varias métricas, más allá de la métrica por defecto que sería puntuar mejor a la estrategia que tuviera más ganancia en un tiempo dado. El uso de más métricas permite un análisis más completo y robusto que da un mejor detalle del comportamiento de la estrategia, teniendo en cuenta que el mercado no es constante en su comportamiento y volatilidad.

### 3.7.1. Net Profit

Net-profit o ganancia neta, es la métrica básica para comparar este tipo de estrategias, el cálculo es simplemente la diferencia entre el capital final y el capital inicial. Para el análisis de cualquier estrategia se puede partir de la base que para ser considerada y analizada en profundidad debería tener un net profit mayor a cero.

### 3.7.2. Sharpe Ratio

El Sharpe Ratio se utiliza para ayudar a los inversores a comprender el rendimiento de una inversión en comparación con su riesgo. El índice es el rendimiento promedio obtenido en exceso de la tasa libre de riesgo por unidad de volatilidad o riesgo total. La volatilidad es una medida de las fluctuaciones de precios de un activo o cartera (Jason Fernando, 2021c).

Restar la tasa libre de riesgo del rendimiento medio permite al inversor aislar mejor las ganancias asociadas con las actividades de toma de riesgos. La tasa de rendimiento libre de riesgo es el rendimiento de una inversión sin riesgo, lo que significa que es el rendimiento que los inversores podrían esperar si no asumieran ningún riesgo. El rendimiento de un bono del Tesoro de los EE. UU., por ejemplo, podría utilizarse como tasa libre de riesgo. En este trabajo, la tasa libre de riesgo a utilizar será del 1 % anual.

Generalmente, cuanto mayor es el valor de esta relación, más atractivo es realizar ese trade o inversión.

$$\text{Sharpe Ratio} = \frac{R_p - R_f}{\sigma_p} \quad (3.3)$$

Donde:

$R_p$  = retorno del portfolio

$R_f$  = tasa de rendimiento libre de riesgo

$\sigma_p$  = desviación estándar del retorno

### 3.7.3. Maximum Drawdown

Se llama Maximum Drawdown a la mayor caída porcentual en el balance monetario de la estrategia. Muchos traders se darán por vencidos en periodos de una caída muy profunda y/o prolongada, incluso si las pruebas históricas han sugerido que esto es un comportamiento esperado de la estrategia. Esta métrica es muy útil, ya que permite visualizar cual hubiera sido la caída más grande que el trader tendría que haber soportado y sabiendo esto, se pueden distinguir las estrategias más riesgosas de las más conservadoras para utilizar la más adecuada para cada trader.

### 3.7.4. Rendimiento Total Anual

El rendimiento total anual es la cantidad media geométrica de dinero ganado por una inversión cada año durante un período de tiempo determinado. La fórmula de rendimiento anualizado se calcula como un promedio geométrico para mostrar lo que ganaría un inversor durante un período de tiempo si el rendimiento anual fuera compuesto. Un rendimiento total anualizado proporciona sólo un cálculo del rendimiento de una inversión y no da a los inversores ninguna indicación de su volatilidad o fluctuaciones de precios sufridos (James Chen, 2021).



# Capítulo 4

## Diseño experimental

El presente capítulo expone la metodología de trabajo que se utilizó durante el desarrollo de los experimentos. Las siguientes secciones expandirán sobre los métodos utilizados durante la experimentación, los problemas encontrados y las formas que fueron abarcados para solucionarlos. Como se mencionó anteriormente, esta tesis se basa principalmente en la aplicación de técnicas de backtesting utilizando indicadores técnicos y/o algoritmos de machine learning para clasificación.

**Notación** En el presente capítulo se utilizará la siguiente notación:

**DCA** Dollar cost averaging: Regla de recompra (ver Sección 3.5.4).

**TP** Take profit: Regla de venta para tomar ganancias en cierto porcentaje predefinido (ver Sección 3.5.2).

**SL** Stop loss: Regla de venta para dejar de perder en cierto porcentaje predefinido (ver Sección 3.5.1).

### 4.1. Base de los experimentos

La idea como estrategia principal dentro de cada experimento, como se menciona anteriormente, es buscar buenas señales de compra, por sobre las de venta, ya que, para realizar o no una venta se utilizan únicamente las reglas porcentuales de stop loss, take profit o trailing stop.

Todos los experimentos de backtesting fueron realizados utilizando el par BTC/USDT sobre una temporalidad de 1 día, y utilizando los años 2018 y 2019, ya que 2018 fue un año bajista para el mercado, es decir, el precio de BTC tendió a bajar y 2019 fue un mercado alcista, o sea, el precio de BTC tuvo una tendencia a subir.

Todos los experimentos cuentan con un balance inicial de 2000 USDT.

### 4.2. Experimentos: Mercado en Baja (2018)

El benchmark para este periodo es de 568,29 USDT, es decir, si se hubiera comprado BTC por 2000 USDT el 1ero de enero de 2018 y cerrado esta posición el 31 de diciembre de 2018, 568,29 USDT sería nuestro balance final.

### 4.2.1. Experimentos basados en análisis técnico

En esta sección se detallan algunos experimentos basados en los indicadores técnicos mencionados anteriormente

#### Experimento 1: Bollinger Bands

La estrategia consiste en comprar cuando el precio está por debajo de la línea inferior de las bollinger bands de 20 períodos y 2 desviaciones estándar. Hay dos experimentos, el Experimento 4.1 es con DCA y el Experimento 4.2 es con Stop Loss y sin DCA.

##### Experimento 4.1.

**Estrategia de compra** Bollinger Bands

**Estrategia de venta** TP a 5 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2080,38 USDT

**Profit** 4,02 %

##### Experimento 4.2.

**Estrategia de compra** Bollinger Bands

**Estrategia de venta** TP a 5 % o SL a 10 %

**Estrategia de recompra** Ninguna

**Balance final** 1404,93 USDT

**Profit** -29,75 %

#### Experimento 2: MACD y EMA 200

La estrategia consiste en comprar cuando la línea de MACD cruza por encima de la línea de señal y además el precio está sobre la EMA de 200 períodos. La configuración del MACD es de 12 y 26 periodos y 9 para la línea de señal. Hay dos experimentos, el Experimento 4.3 es con DCA a niveles de 8 %, 10 %, 15 % y 20 %. Por otro lado, el Experimento 4.4 es con Stop Loss y sin DCA.

##### Experimento 4.3.

**Estrategia de compra** EMA - MACD

**Estrategia de venta** TP a 5 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2211,53 USDT

**Profit** 10,58 %

**Experimento 4.4.**

**Estrategia de compra** EMA - MACD

**Estrategia de venta** Take profit a 5 % o SL a 10 %

**Estrategia de recompra** Ninguna

**Balance final** 1542,73 USDT

**Profit** -22,86 %

**Experimento 3: Bollinger Bands y RSI**

La estrategia consiste en comprar cuando el precio está por debajo de la línea inferior de las bollinger bands de 20 periodos y 2 desviaciones estándar. Y también cuando el indicador RSI está por debajo de los 30 puntos. Hay dos experimentos, el Experimento 4.5 es con DCA a niveles de 8 %, 10 %, 15 % y 20 %. Por otro lado, el Experimento 4.6 es con Stop Loss y sin DCA.

**Experimento 4.5.**

**Estrategia de compra** Bollinger Bands - RSI

**Estrategia de venta** TP a 5 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 1948,90 USDT

**Profit** -2,56 %

**Experimento 4.6.**

**Estrategia de compra** Bollinger Bands - RSI

**Estrategia de venta** TP a 5 % o SL a 10 %

**Estrategia de recompra** Ninguna

**Balance final** 1634.35 USDT

**Profit** -18,28 %

### 4.2.2. Experimentos basados en aprendizaje automático

Como se dijo anteriormente, las estrategias basadas en clasificadores consisten principalmente en conseguir una buena señal de compra, es decir, buena precisión en cada oportunidad de compra, las formas de salir de una posición son por take profit o stop loss únicamente.

Los hiperparámetros utilizados en cada clasificador, a lo largo de todos los experimentos, fueron determinados empíricamente a base de numerosas pruebas y utilizando técnicas como GridSearch o RandomSearch.

#### Extreme Gradient Boosting Trees (XGBoost)

Los hiperparámetros del clasificador XGBoost (Chen and Guestrin, 2016) se listan a continuación:

```
n_estimators 100
reg_alpha 0
reg_lambda 1
scale_pos_weight 1
colsample_bytree 1,
gamma 0
learning_rate 0.300000012
base_score 0.5
booster gbtree
colsample_bylevel 1,
gamma 0
```

El experimento 4.7 es XGBoost con DCA. Por otro lado el experimento 4.8 es XGBoost con Stop Loss y sin DCA.

#### Experimento 4.7.

```
Estrategia de compra Clasificador XGBoost
Estrategia de venta TP a 1 %
Estrategia de recompra DCA al 8 %, 10 %, 15 % y 20 %
Balance final 2185,15 USDT
Profit 9,26 %
```

#### Experimento 4.8.

**Estrategia de compra** Clasificador XGBoost

**Estrategia de venta** TP al 1 % o SL a 20 %

**Estrategia de recompra** Ninguna

**Balance final** 780,16 USDT

**Profit** -60,99 %

### Light Gradient Boosting Machine (LGBM)

Los hiperparámetros del clasificador LGBM (Ke et al., 2017) se listan a continuación:

**objective** binary:logistic

**use\_label\_encoder** True

**base\_score** 0.5

**booster** gbtree

**colsample\_bylevel** 1

**colsample\_bynode** 1

**colsample\_bytree** 1

**gamma** 0

**importance\_type** gain

**learning\_rate** 0.300000012

**max\_delta\_step** 0

**max\_depth** 6

**min\_child\_weight** 1

El experimento 4.9 es LGBM con DCA. Por otro lado el experimento 4.10 es LGBM con Stop Loss y sin DCA.

#### Experimento 4.9.

**Estrategia de compra** Clasificador LGBM

**Estrategia de venta** TP a 1 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2161,36 USDT

**Profit** 8,07 %

#### **Experimento 4.10.**

**Estrategia de compra** Clasificador LGBM

**Estrategia de venta** TP al 1 % o SL a 20 %

**Estrategia de recompra** Ninguna

**Balance final** 1328,16 USDT

**Profit** -33,59 %

#### **Logistic Regression**

Los hiperparámetros del clasificador Logistic Regression (Sammut and Webb, 2010) se listan a continuación:

**C** 8

**class\_weight** 0: 0.2, 1: 0.8

El experimento 4.11 es Logistic Regression con DCA. Por otro lado el experimento 4.12 es Logistic Regression con Stop Loss y sin DCA.

#### **Experimento 4.11.**

**Estrategia de compra** Clasificador Logistic Regression

**Estrategia de venta** TP a 1 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2148,07 USDT

**Profit** 7,40 %

#### **Experimento 4.12.**

**Estrategia de compra** Clasificador Logistic Regression

**Estrategia de venta** TP al 1 % o SL a 20 %

**Estrategia de recompra** Ninguna

**Balance final** 946,72 USDT

**Profit** -52,66 %

### 4.3. Experimentos: Mercado en Alza (2019)

El benchmark para este periodo es de 3816,56 USDT, es decir, si se hubiera comprado BTC por 2000 USDT el 1ero de enero de 2019 y cerrado esta posición el 31 de diciembre de 2019, 3816,56 USDT sería nuestro balance final.

#### 4.3.1. Experimentos basados en análisis técnico

En esta sección se detallan algunos experimentos basados en los indicadores técnicos mencionados anteriormente

##### Experimento 1: Bollinger Bands

La estrategia consiste en comprar cuando el precio está por debajo de la línea inferior de las bollinger bands de 20 períodos y 2 desviaciones estándar. Hay dos experimentos, el Experimento 4.13 con DCA y el Experimento 4.14 es con Stop Loss y sin DCA.

##### Experimento 4.13.

**Estrategia de compra** Bollinger Bands

**Estrategia de venta** TP a 5 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2104,89 USDT

**Profit** 5,25 %

##### Experimento 4.14.

**Estrategia de compra** Bollinger Bands

**Estrategia de venta** TP a 5 % o SL a 10 %

**Estrategia de recompra** Ninguna

**Balance final** 2019,03 USDT

**Profit** 0,95 %

##### Experimento 2: MACD y EMA 200

La estrategia consiste en comprar cuando la línea de MACD cruza por encima de la línea de señal y además el precio está sobre la EMA de 200 períodos. La configuración del MACD es de 12 y 26 periodos y 9 para la línea de señal. Hay dos experimentos, el Experimento 4.15 es con DCA y el Experimento 4.16 es con Stop Loss y sin DCA.

##### Experimento 4.15.

**Estrategia de compra** EMA - MACD

**Estrategia de venta** TP a 5 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2065,00 USDT

**Profit** 3,25 %

#### **Experimento 4.16.**

**Estrategia de compra** EMA - MACD

**Estrategia de venta** TP a 5 % o SL a 10 %

**Estrategia de recompra** Ninguna

**Balance final** 1966,11 USDT

**Profit** -1,69 %

#### **Experimento 3: Bollinger Bands y RSI**

La estrategia consiste en comprar cuando el precio está por debajo de la línea inferior de las bollinger bands de 20 periodos y 2 desviaciones estándar. Y también cuando el indicador RSI está por debajo de los 30 puntos. Hay dos experimentos, el Experimento 4.17 es con DCA y el Experimento 4.18 es con Stop Loss y sin DCA.

#### **Experimento 4.17.**

**Estrategia de compra** Bollinger Bands - RSI

**Estrategia de venta** TP a 5 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2072,53 USDT

**Profit** 3,63 %

#### **Experimento 4.18.**

**Estrategia de compra** Bollinger Bands - RSI

**Estrategia de venta** TP a 5 % o SL a 10 %

**Estrategia de recompra** Ninguna

**Balance final** 2193,80 USDT

**Profit** 9,69 %

### 4.3.2. Experimentos basados en aprendizaje automático

Todos los hiperparámetros de cada uno de los clasificadores, son los mismos que para los experimentos en el mercado bajista.

#### Extreme Gradient Boosting Trees (XGBoost)

El experimento 4.19 es XGBoost con DCA. Por otro lado el experimento 4.20 es XGBoost con Stop Loss y sin DCA.

##### Experimento 4.19.

**Estrategia de compra** Clasificador XGBoost

**Estrategia de venta** TP a 1 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2096,85 USDT

**Profit** 4,84 %

##### Experimento 4.20.

**Estrategia de compra** Clasificador XGBoost

**Estrategia de venta** TP al 1 % o SL a 20 %

**Estrategia de recompra** Ninguna

**Balance final** 3981,80 USDT

**Profit** 99,09 %

#### Light Gradient Boosting Machine (LGBM)

El experimento 4.21 es LGBM con DCA. Por otro lado el experimento 4.22 es LGBM con Stop Loss y sin DCA.

##### Experimento 4.21.

**Estrategia de compra** Clasificador LGBM

**Estrategia de venta** TP a 1 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 1974,23 USDT

**Profit** -1,29 %

##### Experimento 4.22.

**Estrategia de compra** Clasificador LGBM

**Estrategia de venta** TP al 1 % o SL a 20 %

**Estrategia de recompra** Ninguna

**Balance final** 3631,46 USDT

**Profit** 81,57 %

### **Logistic Regression**

El experimento 4.23 es Logistic Regression con DCA. Por otro lado el experimento 4.24 es Logistic Regression con Stop Loss y sin DCA.

#### **Experimento 4.23.**

**Estrategia de compra** Clasificador Logistic Regression

**Estrategia de venta** TP a 1 %

**Estrategia de recompra** DCA al 8 %, 10 %, 15 % y 20 %

**Balance final** 2140,42 USDT

**Profit** 7,02 %

#### **Experimento 4.24.**

**Estrategia de compra** Clasificador Logistic Regression

**Estrategia de venta** TP al 1 % o SL a 20 %

**Estrategia de recompra** Ninguna

**Balance final** 4845,40 USDT

**Profit** 142,27 %

# Capítulo 5

## Análisis de resultados

En este capítulo se realiza un análisis de los resultados obtenidos en los experimentos de la sección anterior.

### 5.1. Objetivo principal

Para poder darle una medición más objetiva a los resultados, se necesita definir bien cuál es el objetivo principal de las distintas estrategias, se pueden definir varios objetivos según cual sea nuestro perfil de riesgo, a mayor posibles ganancias, mayor riesgo de sufrir caídas grandes en nuestro balance. Algunos posibles objetivos:

- Duplicar mi capital inicial.
- Cerrar cada año con un balance superior al benchmark.
- Cerrar cada año con un balance superior al inicial.
- Cerrar cada año con un balance superior al inicial y al benchmark.

A los fines comparativos de esta tesis, se tomará como objetivo cerrar cada año con un balance superior al inicial, más allá de estar en un año alcista o bajista.

### 5.2. Resultados: Mercado en Baja (2018)

Como se mencionó anteriormente, si se comenzaba el año 2018 con un balance de 2000 USDT en BTC, al finalizar el año se hubiera obtenido un balance de 568.29 USDT, lo que significa un profit negativo, del -71,58 %.

La Tabla 5.1 muestra los resultados experimentales finales para el mercado en baja del 2018 de manera que sea más fácil comparar. Los resultados están ordenados de mayor a menor por la columna "Profit". Las columnas que se muestran son el Balance, la Ganancia, el Sharpe Ratio (S.R.), el Max Drawdown (M.D.) y la Volatilidad (Vol.).

Experimento	Balance	Profit	S.R.	M.D.	Vol.
MACD + EMA 200 + DCA	2211,53	10,58 %	0,39	-14.697 %	28,17 %
XGB + DCA	2185,15	9,26 %	0,42	-18.941 %	18,62 %
LGBM + DCA	2161,36	8,07 %	0,36	-22.723 %	21,67 %
LogisticRegression + DCA	2148,07	7,40 %	0,33	-24.55 %	21,80 %
Bollinger Bands + DCA	2080,38	4,02 %	0,24	-16.71 %	18,42 %
Bollinger Bands RSI + DCA	1948,90	-2,56 %	-0,01	-17.796 %	17,89 %
Bollinger Bands RSI + Stop Loss	1634,35	-18,28 %	-0,65	-28.294 %	18,72 %
MACD + EMA 200 + Stop Loss	1542,73	-22,86 %	-0,97	-24.963 %	12,62 %
Bollinger Bands + Stop Loss	1404,93	-29,75 %	-0,79	-32.199 %	26,32 %
LGBM + Stop Loss	1328,16	-33,59 %	-0,23	-57.989 %	55,83 %
LogisticRegression + Stop Loss	946,72	-52,66 %	-0,76	-63.685 %	50,76 %
XGB + Stop Loss	780,16	-60,99 %	-1,29	-64.882 %	43,06 %

Cuadro 5.1: Tabla de resultados experimentales para el mercado en baja de 2018

### 5.2.1. Benchmark

Para el año 2018 la comparación contra el benchmark es fácil de ver, ya que todas las estrategias terminan con un profit mayor al benchmark, es decir, que habiendo usado cualquiera de las estrategias, el balance final sería mayor al obtenido con el benchmark.

### 5.2.2. Balance inicial, balance final y profit

En comparación al balance inicial, en este año bajista se tienen varios algoritmos que terminaron con un balance negativo, es decir, con un balance final menor al inicial. Todas las estrategias con Stop Loss resultaron en pérdida, esto permite ver que el uso de Stop Loss en este tipo de estrategias, cuando el mercado está bajista, es una mala decisión.

Por el contrario, el uso de DCA parece ser una mejor decisión, ya que la mayoría de las estrategias con DCA terminaron con un balance final mayor al inicial, por lo tanto con profit positivo. El uso de DCA es una forma de “defensa” al momento de enfrentar una baja en el mercado, el uso de DCA es una forma de disminuir el riesgo de nuestra estrategia sacrificando así la posibilidad de tener mayores ganancias.

### 5.2.3. Drawdown

Es esperable que en un año bajista la caída máxima de nuestro balance sea un porcentaje importante del mismo. En un mercado bajista y utilizando estrategias con Stop Loss, el drawdown puede llegar a ser un porcentaje grande de nuestro balance, ya que con las configuraciones utilizadas, por cada Stop Loss ejecutado nuestro balance cayó entre 10 % y 20 %. Esto dificulta la recuperación de la estrategia, es por eso que todas las estrategias con Stop Loss, no solo terminaron con un balance negativo, si no que, tuvieron caídas más pronunciadas que las estrategias con DCA.

Esto último es también esperable, ya que la esencia del DCA en estas estrategias es disminuir el impacto de las bajas del mercado.

### 5.2.4. Sharpe ratio

El propósito de utilizar la métrica sharpe ratio es concentrar en un único número el análisis de varias métricas que están correlacionadas, como la volatilidad, el profit y el drawdown.

En este caso, a simple vista, el sharpe ratio acompaña bastante al profit, es decir, siempre que hubo pérdida, hubo sharpe ratio negativo, como también sucede que cuando hay profit positivo, el sharpe ratio es mayor a 0, esto significa que siempre que hubo ganancia fue mayor a la tasa libre de riesgo y por esto el ratio es positivo.

Esto no siempre será así, ya que esta métrica también es influenciada por las otras dos mencionadas, por lo cual siempre es mejor utilizar el sharpe ratio junto con las demás métricas, ya que, lo importante al utilizar esta métrica es entender si nuestra estrategia tiene un buen retorno por tener un riesgo alto o por haber tomado buenas decisiones de inversión.

### 5.2.5. Mejores estrategias vs benchmark y peor estrategia

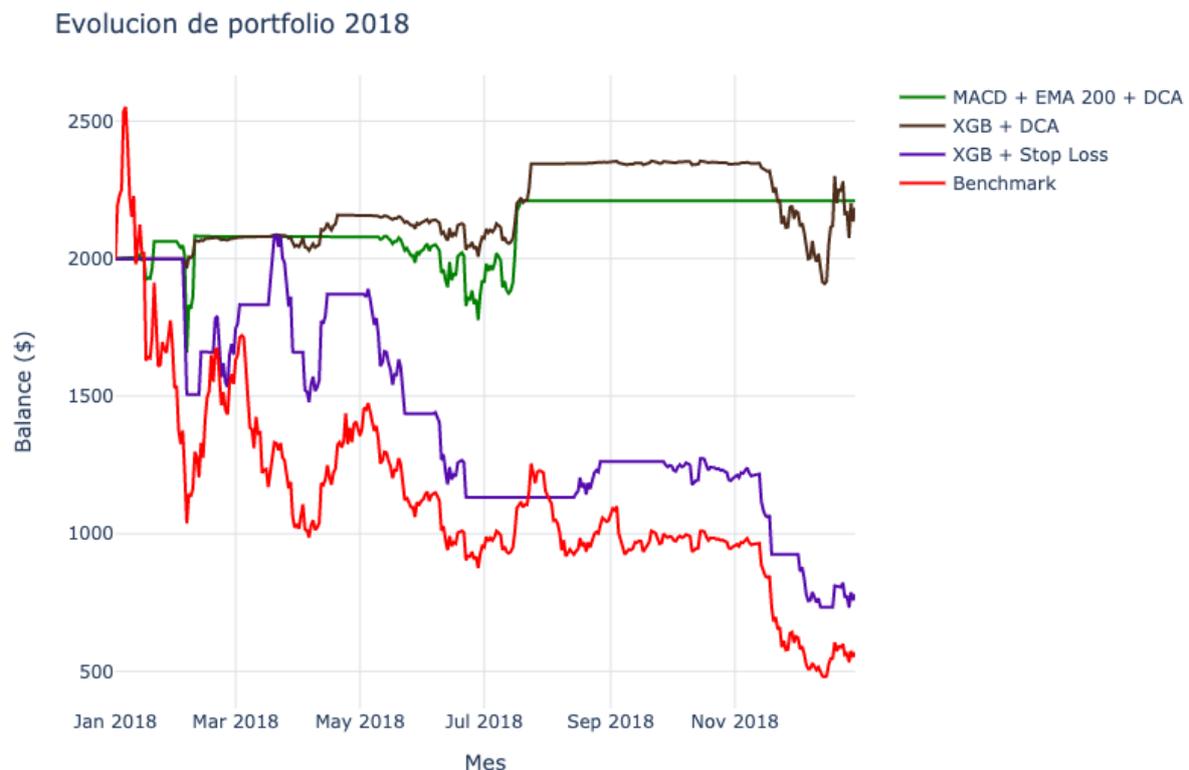


Figura 5.1: Variación de portfolio mercado bajista.

En la Figura 5.1 se muestra la evolución del portfolio, a partir de las distintas estrategias utilizadas en el periodo de mercado bajista. El eje horizontal representa el balance actual de la cuenta en USDT. El eje vertical representa las distintas fechas del año. En

este caso, mientras más alto sea el balance mejor. Las distintas líneas representan algunas de las estrategias analizadas.

La evolución del portfolio en el mercado bajista en las estrategias ganadoras tiene una clara tendencia a la idea de mantener el portfolio positivo, lo cual es un indicio del perfil de riesgo de estas estrategias (y en general, todas las que usen DCA), como se ve en el gráfico, la mayoría del tiempo el balance fue superior al inicial, excepto en algunos meses puntuales, pero luego de esas caídas por debajo del balance se tiene una rápida recuperación.

En cuanto a la peor estrategia, se ven movimientos similares al comportamiento del benchmark, aunque casi siempre se mantuvo por encima del mismo, lo que transforma a todas las estrategias en mejores opciones que tomar el camino del benchmark.

### 5.2.6. Conclusión mercado bajista

En cuanto a nuestro objetivo principal planteado anteriormente, tener un balance final mayor al inicial en el mercado bajista fue complicado, aunque, el uso de la estrategia DCA permitió finalizar el año a la mayoría de las estrategias con un balance final positivo, en el año 2018 las estrategias con profit también pudieron ganarle al benchmark. La diferencia entre clasificadores y estrategias de análisis técnico no fue tan marcada.

## 5.3. Resultados: Mercado en Alza (2019)

Si al iniciar el año 2019 se tenía un balance de 2000 USDT en BTC, al finalizar el año el balance hubiera sido de 3816,56 USDT, lo que significa un profit del 90,82 %.

Experimento	Balance	Profit	S.R.	M.D.	Vol.
LogisticRegression + Stop Loss	4845,40	142,27 %	1,54	-31.984 %	46,63 %
XGB + Stop Loss	3981,80	99,09 %	1,65	-14.417 %	31,93 %
LGBM + Stop Loss	3631,46	81,57 %	1,06	-49.905 %	50,92 %
Bollinger Bands RSI + Stop Loss	2193,80	9,69 %	0,42	-12.824 %	19,45 %
LogisticRegression + DCA	2140,42	7,02 %	1,26	-3.226 %	3,79 %
Bollinger Bands + DCA	2104,89	5,25 %	0,50	-3.444 %	7,60 %
XGB + DCA	2096,85	4,84 %	1,76	-0.48 %	1,88 %
Bollinger Bands RSI + DCA	2072,53	3,63 %	0,89	-0.962 %	2,81 %
MACD + EMA 200 + DCA	2065,00	3,25 %	0,22	-5.992 %	5,86 %
Bollinger Bands + Stop Loss	2019,03	0,95 %	0,16	-29.411 %	27,23 %
LGBM + DCA	1974,23	-1,29 %	-0,03	-13.656 %	10,76 %
MACD + EMA 200 + Stop Loss	1966,11	-1,69 %	-0,07	-27.905 %	12,23 %

Cuadro 5.2: Tabla de resultados experimentales para el mercado en alza de 2019

La Tabla 5.2 muestra los resultados experimentales finales para el mercado en alza de 2019, para facilitar la comparación, los resultados están ordenados de mayor a menor por la columna de profit. Las columnas que se muestran son el Balance, la Ganancia, el Sharpe Ratio (S.R.), el Max Drawdown (M.D.) y la Volatilidad (Vol.).

### 5.3.1. Benchmark

Para el año 2019 nuestro benchmark es de 3816,56 USDT, esto significa un desafío mayor al del año bajista, ya que, de haber comprado BTC al principio del año manteniéndolo hasta fin de año, hubiera resultado en una ganancia muy interesante de casi el 91 %.

En este caso se tienen únicamente dos estrategias que pudieron superar el benchmark, y estas dos estrategias son los clasificadores, habiendo una clara ventaja de la Logistic Regression por sobre los demás.

### 5.3.2. Balance inicial, balance final y profit

El balance final de la mayoría de las estrategias fue superior al balance inicial, esto claramente fue influido por el alza del mercado, lo cual simplificó las cosas a la hora de cumplir nuestro objetivo.

Este año, las estrategias más ganadoras y que más profit positivo generaron fueron las que utilizaron Stop Loss en lugar de DCA, lo cual es esperable, ya que al ser un mercado alcista, como la tendencia de los precios es ir hacia arriba, es más difícil “comprar mal” por lo cual, la utilización de DCA para cubrirnos en esos casos, termina resultando en un balance negativo como relación de costo-beneficio.

### 5.3.3. Drawdown

Como se dijo anteriormente, es esperable que en un mercado bajista la caída máxima de nuestro balance sea un porcentaje importante del mismo, pero esta caída en un mercado alcista también puede ser importante.

Las estrategias que más drawdown tuvieron fueron las de Logistic Regression + Stop Loss y LGBM + Stop Loss, sufriendo importantes caídas del 30 % y del 50 % respectivamente. Esto deja en claro que, más allá de la época del mercado, sea alcista o bajista, el uso de Stop Loss siempre puede venir acompañado de una importante caída en nuestro balance.

### 5.3.4. Sharpe ratio

El sharpe ratio en este caso deja en clara evidencia cuáles estrategias son las más interesantes de analizar. Se puede ver que la estrategia con mayor sharpe ratio es XGB + DCA, la cual tiene un profit bajo al lado de las estrategias más ganadoras, pero aun así es un balance final positivo, pero, lo que hace a esta estrategia tener el sharpe ratio más alto es tener un drawdown y una volatilidad bajas, de menos de 1 % y 2 % respectivamente.

Las otras dos estrategias con mayor sharpe ratio son las dos primeras, y esto se debe al gran porcentaje de ganancias obtenidas.

### 5.3.5. Mejores estrategias vs benchmark y peor estrategia

En la Figura 5.1 se muestra la evolución del portfolio, a partir de las distintas estrategias utilizadas en el periodo de mercado alcista. El eje horizontal representa el balance actual de la cuenta en USDT. El eje vertical representa las distintas fechas del año. En

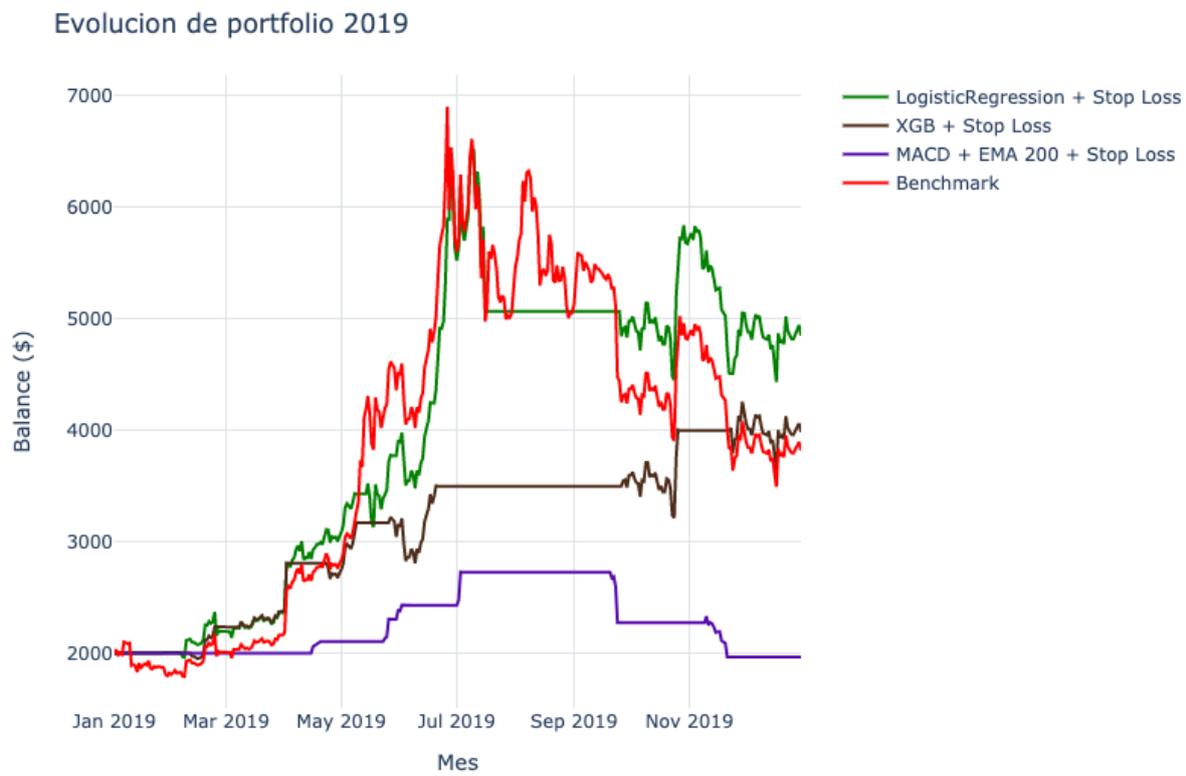


Figura 5.2: Variación de portfolio mercado alcista.

este caso, mientras más alto sea el balance mejor. Las distintas líneas representan alguna de las estrategias analizadas.

La evolución del portfolio para el mercado alcista fue de una gran mejora del balance en la mayoría de los casos, incluyendo el benchmark, y para el caso de la peor estrategia se tiene una variación pequeña en el balance terminando el año con un pequeño porcentaje de pérdida.

Analizando las estrategias ganadoras, ambas le ganaron al benchmark y tienen movimientos similares, pero se puede ver claramente como la estrategia de XGB + Stop Loss fue más estable, con caídas más leves y menos volatilidad que la Logistic Regression, es por eso que en la métrica Sharpe Ratio XGB tiene mayor puntaje que la Logistic Regression, más allá de que esta tuvo un mejor profit, la relación riesgo-beneficio demuestra que hubiera sido mejor elección tomar la estrategia de XGB + Stop Loss en este caso.

### 5.3.6. Conclusión mercado alcista

En cuanto a nuestro objetivo principal planteado anteriormente, tener un balance final mayor al inicial en el mercado alcista se vió facilitado por la condición del mercado, aún así en estos casos es donde más se resalta la diferencia entre un perfil moderado y un perfil agresivo, las estrategias más ganadoras son las que utilizaron Stop Loss en lugar de

DCA, pero también son las estrategias más arriesgadas.

## 5.4. Resultados vs objetivo final

En ambos tipos de mercados, alcista y bajista se analizaron estrategias que pudieron cumplir con el objetivo de finalizar el año con profit positivo, y algunas de ellas incluso generaron un retorno mayor al que se hubiera obtenido por benchmark.

La mejor estrategia dependerá del perfil de riesgo del usuario que la utilice. Un perfil de riesgo agresivo, haciendo una previa investigación de mercado y confirmando que el mercado no está bajista podría utilizar Logistic Regression + Stop Loss, obteniendo las mayores ganancias pero bajo el riesgo de un repentino cambio en la dirección del mercado que podría resultar en grandes pérdidas, como se puede ver en los resultados de esta estrategia en 2018.

Teniendo un perfil más moderado, el primer punto a tener en cuenta es utilizar DCA en lugar de Stop Loss, cualquiera sea la etapa del mercado, y ayudándonos con los resultados obtenidos, la estrategia más interesante para un perfil moderado es la de XGB + DCA, la cual en ambos tipos de mercados obtuvo un balance final positivo y el sharpe ratio más alto, confirmando que la relación de riesgo-beneficio entregada es la mejor.



# Capítulo 6

## Conclusión y trabajo futuro

### 6.1. Conclusiones

En este trabajo de tesis se experimentó y analizó el resultado de diversas estrategias sobre el mercado de criptomonedas. Para mejorar la proyección, se decidió llevar a cabo un análisis con dos tipos de mercado: bajista y alcista.

Las estrategias estuvieron basadas en análisis técnico o clasificadores supervisados. Las estrategias de análisis técnico permiten un seguimiento claro y conciso frente a las estrategias que utilizan clasificadores, ya que en las de análisis técnico se sabe claramente en qué momentos el algoritmo debería hacer una compra, no así con los clasificadores.

En cuanto a las señales de venta, en este trabajo de tesis se utilizaron únicamente dos opciones: take profit o stop loss, cuando se alcanza un nivel de ganancia o pérdida determinado previamente.

Las estrategias más conservadoras son las que utilizan DCA como técnica de cobertura frente a bajas repentinas del mercado, logrando así que la volatilidad sufrida para la estrategia sea menor que si no utilizara DCA, esto también se debe a que cuando se inicia un trade con este tipo de técnicas no se utiliza la totalidad del balance, como sí pasa en otros casos. Este tipo de estrategias son más estables frente a las demás, permitiendo obtener ganancias entre bajas y moderadas, pero una mejor cobertura en caso de enfrentarnos a un mercado bajista. Demostraron poder obtener un profit en ambos tipos de mercado, manteniendo una ganancia anual entre el 5 % y 12 %.

Las estrategias más agresivas son las que utilizan Stop Loss, debido a que utilizan la totalidad del balance al iniciar un trade, consecuentemente las ganancias en los casos exitosos son mucho mayores, como también lo son las pérdidas en los casos de una mala compra. En épocas donde el mercado está bajista ninguna de las estrategias con Stop Loss pudo conseguir un profit positivo, pero en época alcista fueron las que más profit consiguieron, llegando a obtener ganancias anuales del 140 %.

La utilización de estrategias de trading automatizado es una interesante opción de inversión ya que se puede adaptar a las distintas condiciones del mercado, como también al perfil de riesgo del usuario que la utiliza.

El hecho de ser un algoritmo que se ejecuta continuamente y sin pausa, sin la necesidad de supervisión por parte del usuario, hace que este tipo de inversión se asemeje a una inversión pasiva, ya que mientras se haya elegido una estrategia que se adecue correctamente al perfil de riesgo del usuario, no deberá estar activamente modificando o participando

en la inversión. Esto también incluye la eliminación del factor psicológico humano a la hora de tomar decisiones para entrar o salir del mercado, lo que permite llevar a cabo la inversión de forma planificada y constante, ya que la estrategia está preparada para enfrentar determinísticamente los distintos escenarios posibles.

La volatilidad del mercado de criptomonedas es un punto a tener en cuenta a la hora de decidir utilizar este tipo de algoritmos, siendo que esta volatilidad puede causar variaciones muy grandes en el balance del usuario y en muy poco tiempo.

Si bien los rendimientos pasados no garantizan rendimientos futuros, la utilización de técnicas de backtesting permite al usuario tener una noción de cómo sería el comportamiento de las distintas estrategias, en los distintos tipos de mercados, permitiendo así elegir la que más le guste.

## 6.2. Trabajo Futuro

En el trabajo futuro a realizar, una de las primeras etapas sería trabajar más en la obtención de los mejores hiperparámetros para cada uno de los clasificadores, ya que estos probaron ser una buena opción frente a las estrategias de análisis técnico.

Otro enfoque en el cual podría ser interesante trabajar, es utilizar algoritmos de series de tiempo como predictores de tendencia o modelos autorregresivos, para poder tomar decisiones basadas en ellos.

Este trabajo de tesis estuvo centrado en el par BTC/USDT, que es el par más conocido, pero al tener estrategias respaldadas por backtesting se podrían testear las mismas frente a otros pares y ver si los resultados son similares o si varían mucho dependiendo del par en cuestión.

Todas las estrategias en este trabajo estuvieron orientadas a encontrar buenas señales de compra, dejando de lado las posibles señales de venta que otorgarían las distintas estrategias, ya que a los momentos de finalizar un trade solo se utilizó stop loss o take profit. Sería interesante investigar otras opciones, como por ejemplo, en el caso de los indicadores técnicos, si un activo está empezando a ser sobrecomprado, es un buen momento para cerrar nuestra posición, o en el caso de los clasificadores, entrenarlos teniendo en cuenta que ahora no solo se quiere comprar bien, si no también vender bien.

Para realizar los experimentos de backtesting se utilizan los datos históricos y los precios de cierre de cada día, pero dada la volatilidad del mercado, si el algoritmo se ejecutara en tiempo real, no necesariamente tendría que esperar al cierre de cada día para tomar o cerrar una posición, ya que estaría monitoreando segundo a segundo el mercado. Sería interesante tener una estrategia capaz de realizar un backtesting en tiempo real y analizar el impacto que tiene esta diferencia en las estrategias.

Finalmente, la precisión de las estrategias está únicamente basada en análisis de indicadores y variaciones de precio, pero el mercado de criptomonedas también está muy influido por sucesos externos, como por ejemplo, cuando alguna moneda sufre algún problema o un hack, que termine afectando el precio del activo. Otro ejemplo es cuando una moneda anuncia una actualización muy importante que resuelve alguno de sus defectos o agrega una funcionalidad interesante, toda esta información influye también en el mercado. Otro punto de investigación futura sería complementar las estrategias de análisis técnico con alguna herramienta que, a partir de procesamiento de lenguaje natural, pudiera agregar este tipo de información a partir de redes sociales como Twitter o Reddit.

# Bibliografía

Adam Hayes (2021). Bollinger band<sup>®</sup> definition.

Attanasio, G., Cagliero, L., Garza, P., and Baralis, E. (2019). Quantitative cryptocurrency trading: exploring the use of machine learning techniques. In *Proceedings of the 5th Workshop on Data Science for Macro-modeling with Financial and Economic Datasets*, pages 1–6.

Chen, T. and Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, pages 785–794, New York, NY, USA. ACM.

Cory Mitchell (2020). What is an order?

Cory Mitchell (2021). Trailing stop definition and uses.

Fang, F., Ventre, C., Basios, M., Kong, H., Kanthan, L., Li, L., Martinez-Regoband, D., and Wu, F. (2021). Cryptocurrency trading: A comprehensive survey.

Jake Frankenfield (2021). Paper wallet.

James Chen (2021). Annualized total return.

Jason Fernando (2019). Moving average (ma).

Jason Fernando (2021a). Moving average convergence divergence (macd).

Jason Fernando (2021b). Relative strength index (rsi).

Jason Fernando (2021c). Sharpe ratio.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. In Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R., editors, *Advances in Neural Information Processing Systems*, volume 30. Curran Associates, Inc.

Kissell, R. (2021). *Algorithmic trading methods: Applications using advanced statistics, optimization, and machine learning techniques*. Academic Press.

Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized Business Review*, page 21260.

Sammut, C. and Webb, G. I., editors (2010). *Logistic Regression*, pages 631–631. Springer US, Boston, MA.

Spörer, J. (2020). Backtesting of algorithmic cryptocurrency trading strategies. *Available at SSRN 3620154*.