



Universidad Pontificia de Comillas

¿Podemos comerciar Bitcoin usando análisis de sentimiento sobre Twitter?

Autor: Jaime Badiola Ramos
Director: Carlos Martínez Ibarra

RESUMEN

En este artículo estudiamos la posibilidad de predecir el precio de Bitcoin utilizando únicamente datos de Twitter. Twitter es la principal plataforma de conversación y divulgación de información financiera sobre criptomonedas. Por este motivo, entender el efecto de un tweet sobre el precio de Bitcoin puede ofrecer ventajas a los inversores. El proyecto presentado en este artículo descarga y analiza 17.737.519 tweets sobre bitcoin entre agosto de 2017 hasta enero de 2019. La investigación encuentra que el sentimiento medio de los mensajes no es un buen predictor del precio de Bitcoin mientras que el volumen de los mensajes sí lo es. Utilizando algoritmos de aprendizaje supervisado, la investigación ha creado varios modelos predictivos capaces de predecir los movimientos del precio de bitcoin de forma precisa. La utilización de este tipo de modelos puede ayudar a los inversores a tomar mejores decisiones.

Palabras clave:

Twitter, análisis de sentimiento, criptomonedas, Bitcoin, minería de datos, Machine learning

ABSTRACT

In this article we study the possibility of predicting the price of Bitcoin using only Twitter data. Twitter is the main platform for conversation and disclosure of financial information on cryptocurrencies. For this reason, understanding the effect of a tweet on the price of Bitcoin can offer advantages to investors. The project presented in this article downloads and analyzes 17,737,519 tweets about bitcoin between August 2017 and January 2019. The research finds that the average sentiment of the messages is not a good predictor of the price of Bitcoin while the volume of the messages is. Using supervised learning algorithms, the research has created several predictive models able to accurately predict the price movements of bitcoin. The use of this type of models can help investors make better decisions.

Keywords:

Twitter, sentiment analysis, cryptocurrency, Bitcoin, data mining, Machine learning

ÍNDICE

1. Índice	I
2. Índice de figuras y tablas	II
3. Introducción	1
4. Capítulo 1: Marco teórico	5
4.1 Bitcoin	5
4.2 Twitter	8
4.3 Análisis de sentimiento.....	9
4.4 Machine Learning.....	13
4.4.1 Modelos de aprendizaje supervisado.....	14
4.4.2 Modelos de aprendizaje no supervisado.....	15
4.5 Estudios relacionados	16
5. Capítulo 2: Metodología.....	18
5.1 Descarga de datos	18
5.1.1 Datos financieros de Bitcoin	18
5.1.2 Datos de Twitter	19
5.2 Análisis de sentimiento.....	20
5.2.1 Vader	20
5.2.1.1 Modificaciones de VADER.....	21
5.2.1.2 Clasificación de polaridad	23
5.2.2 Reducción de ruido.....	24
5.3 Modelo de predicción	25
6 Capítulo 3: Resultados	28
6.2 Análisis exploratorio del sentimiento	29
6.3 Análisis exploratorio del volumen.....	32
6.4 Resultados.....	33
7 Capítulo 4: Discusión	36
7.1 Problemas éticos y debilidades técnicas.....	36
7.1.1 Falta de datos	36
7.1.2 Falta de robustez en el análisis de sentimiento.....	37
7.1.3 Cuestiones éticas	37
7.2 Trabajo futuro	39
7.2.1 Aplicar teoría de grafos	39
7.2.2 Análisis polígloto y multiplataforma.....	40
7.3 Conclusión.....	41
8 Bibliografía.....	42

ÍNDICE DE FIGURAS

Figura 1: Comparación de Red Peer to Peer (P2P) con un sistema Cliente Servidor	6
Figura 2: Extracto de código en Python para extraer los mensajes de Twitter.	20
Figura 3: Extracto de código en Python para realizar análisis de sentimiento.....	23
Figura 4: Variables finales del estudio.....	27
Figura 5: Gráfica del precio de bitcoin durante el periodo del estudio.	29
Figura 6: Histograma del sentimiento.	30
Figura 7: Relación entre precio de Bitcoin y sentimiento 1.	31
Figura 8: Relación entre precio de Bitcoin y sentimiento 2.....	32
Figura 9: Gráfica de dispersión entre el sentimiento medio y el cambio de precio	32
Figura 10: Autocorrelación entre el sentimiento y el cambio de precio.	33
Figura 11: Relación entre volumen de mensajes y el precio de Bitcoin.	34
Figura 12: Autocorrelación entre el volumen y el cambio de precio según el tiempo...35	
Figura 13: Distribución del periodo de entrenamiento y de pruebas	36
Figura 14: Predicciones de todos los modelos con el precio real 1.....	37
Figura 15: Regresión lineal de los precios estimados y los reales	37
Figura 16: Predicciones de todos los modelos con el precio real 2.....	38

ÍNDICE DE TABLAS

Tabla 1: Selección de léxicos añadidos al diccionario de VADER.....	22
Tabla 2: Ejemplos de mensajes clasificados como positivos, neutros y negativos.....	26
Tabla 3: Ejemplos de mensajes que no han pasado el filtro establecido.....	27
Tabla 4: Rendimiento de todos los modelos.....	38

Introducción

En 2019 ya hay 4.3 billones de usuarios activos en línea (Statista, 2019). Internet se ha convertido en la herramienta de comunicación más popular del mundo y los usuarios interactúan constantemente dejando opiniones, comentarios e información que representa sentimiento. Estos sentimientos pueden ser opiniones sobre productos, lugares, libros, fotos en Instagram o discusiones en Twitter. Junto con la democratización de internet, el interés por las redes sociales se ha incrementado enormemente y hoy en día las personas las consideran como un requisito para la vida (Hany Mohamed, 2015). Se estima que en 2020 las redes sociales llegaran a 3 billones de usuarios, ~40% de la población mundial (Statista, 2017).

Twitter, entre otras plataformas de redes sociales (Facebook, YouTube, Instagram, Pinterest, LinkedIn), es una de las más populares de internet. En marzo de 2019, Twitter tiene 321 millones de usuarios activos que envían de media 500 millones de mensajes al día (Aslam, 2019). Por sus evidentes ventajas sobre los medios de comunicación tradicional (Inmediatez, Frecuencia, Alcance y Atención) más y más industrias hacen uso de las redes sociales como canal principal de comunicación. Numerosos inversores y analistas profesionales y aficionados han comenzado a utilizar Twitter para publicar artículos de noticias y opiniones, a menudo con más frecuencia que los medios de noticias profesionales.

Normalmente la información financiera compartida por los medios tradicionales o las redes sociales son noticias, hechos u opiniones. Aunque la premisa de cualquier decisión financiera es hacerla de forma completamente racional partiendo de la información pública, gran parte de las decisiones de los actores del mercado vienen influenciadas profundamente por sentimientos. Los sentimientos son uno de los factores más importantes que aportan información implícita o explícita para la toma de rápidas decisiones. En este mismo problema se centran muchas investigaciones recientes. Tetlock (2007) argumentó que una simple medida del sentimiento, el número de palabras negativas en la columna “*Abreast of the market*” del Wall Street Journal, ayudaba a predecir los rendimientos económicos de las acciones del Mercado bursátil con una frecuencia diaria entre 1984 hasta 1999. García and Flagler (2010) llegaron a la

conclusión de que el sentimiento podía ayudar a predecir el valor solo durante épocas de crisis financieras después de estudiar el efecto del sentimiento sobre los activos del Mercado bursátil durante la primera mitad del siglo XX.

Con la llegada del nuevo siglo y la adopción masiva de internet la información se ha digitalizado y ahora una gran parte de la población consume noticias e información a través de las redes sociales (Zantal-Wiener, 2018). Twitter proporciona un entorno muy bueno para compartir sentimiento. El tamaño de cada tweet está restringido a tan solo 140 caracteres. Esta limitación anima a los usuarios a expresar tan solo un tipo de sentimiento en cada tweet. Twitter también permite las relaciones bidireccionales o unidireccionales. Un usuario puede decidir “seguir” a cualquier otro usuario, y así recibir notificaciones continuas de todos los mensajes que publica. Este tipo de flexibilidad que aporta Twitter permite que se creen estructuras sociales muy complejas. Twitter también concentra en un mismo sitio la opinión de millones de personas sobre cualquier temática posible convirtiéndose en una plataforma muy atractiva para muchos investigadores. Keel sul, Dennis y Yuan analizaron el sentimiento de todos los tweets que contenían un *Ticker* de cualquier valor que comerciaba en el S&P500 demostrando que había un efecto significativo en los retornos del S&P500 del mismo día y de los retornos de 10 días después.

Aunque existe un gran interés sobre cómo afecta la información de los medios de comunicación tradicionales o las redes sociales a los mercados bursátiles tradicionales, se ha estudiado mucho menos como afecta el sentimiento a las criptomonedas. Lönnö y Stenquist (2017) estudiaron la relación entre sentimiento de Twitter y la variación de las criptomonedas durante junio de 2017 concluyendo que si existe una relación entre ambas. Sin embargo, Abraham, Higdon, Nelson y Ibarra investigaron la misma relación entre marzo y mayo de 2018 y concluyeron que no existía una relación entre sentimiento y precio.

Este TFG contribuye a la literatura del campo de investigación de *opinion mining* estudiando el efecto del sentimiento que los inversores exponen públicamente en Twitter con la variación del precio de Bitcoin entre junio 2017 y enero 2019. El TFG tiene como objetivo corroborar los hallazgos de las investigaciones mencionadas anteriormente. Dadas las limitaciones de la extracción de datos, la mayoría de los estudios previos han

realizado el análisis en una franja de tiempo muy pequeña. La ventaja de este TFG es poder estudiar un periodo más grande. El periodo de estudio ha sido seleccionado porque 1) contiene la expansión de la burbuja de la criptomoneda pasando de valer \$3.000 a \$20.000 entre junio 2017 hasta diciembre 2017 y la contracción del mercado pasando de valer \$20.000 a \$4.000 entre enero de 2018 hasta enero de 2019 2) las criptomonedas son completamente digitales y al igual que la comercialización se hace a través de internet, la información y comunicación se trasfiere casi únicamente a través de redes sociales 3) en las criptomonedas, como en cualquier otra moneda, adquieren valor únicamente a través de la confianza del inversor y, al haber sido creadas hace relativamente muy poco tiempo, la especulación domina el mercado.

Las criptomonedas son completamente digitales, están globalizadas, y una gran parte de los actores del mercado provienen de países asiáticos. Es por esto por lo que este problema de investigación es increíblemente difícil de resolver porque gran parte de la conversación e intercambio de opiniones se realiza en muchos idiomas diferentes. Puesto que buscar una fuente de datos que represente de forma más uniforme la comunidad inversora en criptomonedas sería casi imposible, debido a la variedad de idiomas y a que la conversación es multiplataforma, esta investigación se centra en estudiar el sentimiento de la comunidad inversora de habla inglesa.

Dentro de la comunidad inglesa, la mayor parte de la conversación sobre bitcoin existe en dos plataformas. Twitter y Reddit (Price, 2018). La utilización de la plataforma de Reddit plantea algunos inconvenientes a la hora de la descarga de datos históricos, por lo que este estudio se ha centrado en la plataforma de Twitter.

Para ello se plantea estudiar la relación entre los mensajes públicos de Twitter en inglés con la variación del precio de Bitcoin entre junio 2017 y enero 2019. Con este objetivo, el proyecto parte de GetOldTweets, una herramienta de extracción de datos en Twitter, y de una versión modificada de VADER, un clasificador de polaridad y sentimiento desarrollado por Hutto, C.J. y Gilbert, E.E. en 2014. Se han escogido estas dos herramientas porque GetOldTweets es la única que permitía descargar todos los datos históricos de Twitter, y VADER ha sido creado específicamente para ser utilizado en las redes sociales.

Por último, la investigación planteara un modelo de predicción basado en técnicas de *Machine Learning* para predecir el precio con el objetivo de demostrar que los datos públicos de Twitter pueden proporcionar ventajas en la compraventa de Bitcoin.

El resto del documento se estructura de la siguiente forma. El capítulo 1 contiene el marco teórico de la investigación, la clasificación de sentimiento y la creación del modelo de predicción. El capítulo 2 presenta la metodología utilizada y todas las modificaciones hechas a las diferentes herramientas. En el capítulo 3 se analizan los resultados obtenidos. En el capítulo 4 discutiremos los méritos del análisis sentimiento y de los problemas éticos.

Capítulo 1: Marco teórico

Este capítulo establece la posibilidad teórica de realizar la investigación propuesta. Para ello, el capítulo se centra en los 4 conceptos más importantes de la investigación e intenta responder a una serie de preguntas. Los 4 conceptos y las preguntas son las siguientes:

- **Bitcoin:** ¿Qué es Bitcoin y por qué estudiar la relación del sentimiento hacia Bitcoin y no a cualquier otro valor?
- **Twitter:** ¿Por qué Twitter es la mejor plataforma para extraer los datos?, ¿Cuáles son los inconvenientes teóricos de utilizar solo una plataforma y no varias?
- **Análisis de sentimiento:** ¿Qué es Análisis de sentimiento? ¿Cuáles son las limitaciones del análisis de sentimiento?, ¿Cómo lo han utilizado otros investigadores?
- **Machine learning:** ¿Qué es Machine learning? ¿Qué tipos existen? ¿Porque tiene sentido utilizarlo en esta investigación?

Una vez establecida la posibilidad teórica de realizar el proyecto, dentro del mismo capítulo también se expondrá las investigaciones relacionadas más relevantes.

4.1 Bitcoin

Para responder a las preguntas expuestas anteriormente, es necesario definir Bitcoin y explicar la tecnología Blockchain.

Bitcoin es la moneda digital criptográfica más popular y establecida. A diferencia de las monedas "normales", el valor de Bitcoin no está en una mercancía física, sino en la complejidad computacional. Se considera el primer sistema monetario descentralizado que funciona a escala global. En el sentido más básico, Bitcoin es un programa de software de código abierto, que se ejecuta en muchas computadoras (nodos) que forman una red (*Peer to peer network*). Juntos, estos nodos comparten una base de datos distribuida (*Distributed Ledger*), la cadena de bloques (*Blockchain*), que sirve como la única fuente de verdad para todas las transacciones en la red. Todo este sistema pretende ser descentralizado lo que conlleva a la búsqueda de consenso entre los actores que participan (nodos). En Bitcoin se llega al consenso cuando más de la mitad de la red está de acuerdo. (Bitcoin, s.f.)

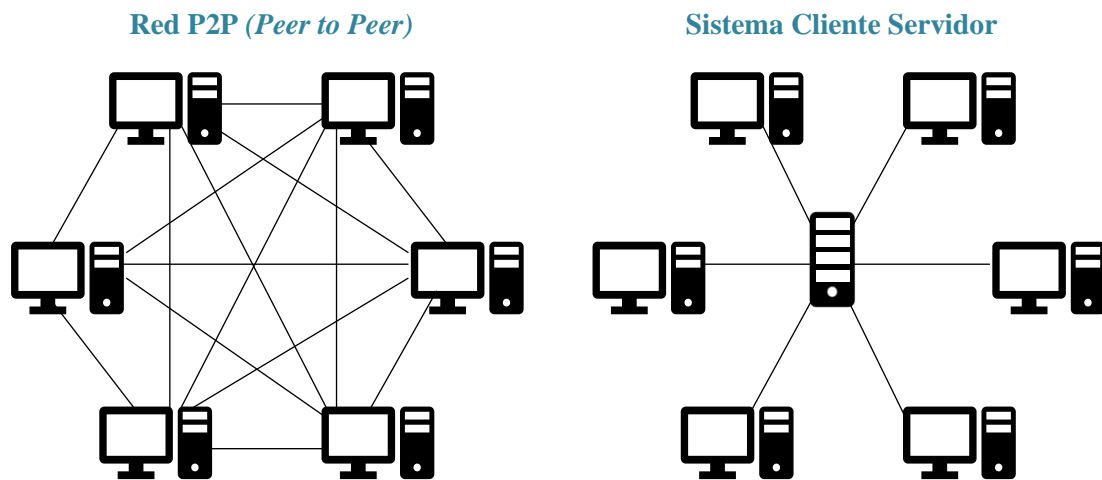


Figura 1: Comparación de Red Peer to Peer (P2P) con un sistema Cliente Servidor

Si bien la moneda de Bitcoin es la aplicación más conocida de la cadena de bloques, la cadena de bloques en sí misma se puede usar para cualquier sistema en el que uno intercambiaría valor o información, ya que tiene grandes ventajas. Blockchain no permite la duplicación de un activo, por lo que se elimina la falsificación. Blockchain es más seguro, porque la información no está centralizada y sería extremadamente complicado comprometer a más del 50% de los nodos que forman parte de la base de datos distribuida. Por último, la tecnología Blockchain aporta muchísima más transparencia porque tiene la trazabilidad total de cualquier interacción sucedida en la red. Algunas de las otras aplicaciones que se están realizando sobre la base de Blockchain tratan temas como la votación, el mantenimiento de registros, contratos. Como ejemplo, una Blockchain aplicada a la votación prevendría fraude electoral, complicaría la manipulación por parte de entidades externas (Rusia y las elecciones de EEUU en 2016) y aumentaría la transparencia.

Además de poder transferir valor entre cualquier usuario de la red, han surgido lo que se denominan contratos inteligentes o *Smart contracts* (Bitcoin Foundation, s.f.). Estos contratos permiten poner “condiciones” al intercambio de valor. Al codificar “condiciones” a una transferencia se elimina la posibilidad de fraude porque el *Smart contract* puede manejar sus ejecuciones automáticamente junto con el arbitraje de disputas, lo que reduce los costos y proporciona más transparencia. En los sistemas Blockchain, se elimina la necesidad de tener una entidad intermediaria que aporta

confianza. Como ejemplo, en un sistema social en el que todos los contratos son contratos inteligentes, se eliminarían todas las disputas porque las excepciones ya estarían codificadas y aceptadas previamente.

La mayoría de las monedas en el mundo son emitidas y reguladas por un gobierno, ya sea directa o indirectamente (es decir, a través de un banco central). En ambos casos, las políticas y los objetivos de un gobierno son las que guían y regulan su moneda (Simon Barber, 2013). El trabajo de los bancos centrales es lograr los objetivos establecidos por su instituto de gobierno en áreas que incluyen la estabilidad económica, el crecimiento económico y la estabilidad del valor de la moneda (Simon Barber, 2013). El valor de una moneda depende de varios factores, el más notable es; Confianza pública, utilidad, aceptación y expectativa social de valor (Simon Barber, 2013). Las monedas gobernadas por un gobierno o un instituto centralizado seguramente habían comenzado con garantías reales de valor físico normalmente oro, en el clima financiero actual rara vez es el caso en el que las monedas sigan ligadas al valor físico (Joshua A. Kroll, 2013).

Dado que las monedas Fiat están controladas, existen vulnerabilidades en la forma en que la agencia central decide influir en una moneda. Las políticas monetarias irresponsables pueden conducir a una deflexión artificial a largo plazo mediante el uso de métodos diseñados para el corto plazo como imprimir dinero, es decir, aumentar la oferta monetaria, y disminuir el valor para resolver problemas o crisis (Joshua A. Kroll, 2013). Bitcoin, por otro lado, no tiene autoridad central ni forma directa de influir en el valor de Bitcoin o en el suministro de Bitcoins (Bitcoin Foundation, s.f.). Por diseño, esto elimina al intermediario con el que se crean la mayoría de los sistemas monetarios, es decir, el Banco central (Simon Barber, 2013). La única forma de aumentar el suministro de Bitcoins es participar en los cálculos de transacciones, lo que lleva a un crecimiento predecible del suministro de Bitcoin y paga la infraestructura (Bitcoin Foundation, s.f.). Al mismo tiempo, el valor monetario de la moneda se ve influido por las mismas variables que en una moneda en fiat.

Aunque se espera que Bitcoin sea utilizado masivamente como moneda, la gran volatilidad del valor impide una adopción masiva por parte de las empresas como

método de pago. Algunas investigaciones han buscado la relación entre sentimiento y los valores del mercado bursátil.

Como respuesta a la pregunta inicial, para esta investigación se ha elegido Bitcoin y no cualquier otro valor del mercado bursátil porque se parte de la hipótesis de que el sentimiento afectara más al valor de bitcoin por su naturaleza y la naturaleza de los inversores. En muy pocos establecimientos alrededor del mundo se puede utilizar bitcoins como método de pago por lo que actualmente la gran parte del valor de Bitcoin viene de inversores financieros en búsqueda de una rentabilidad. Puesto que el valor de bitcoin se rige mayoritariamente por la confianza de los inversores y los inversores solo compran en búsqueda de una rentabilidad económica hace que el valor de Bitcoin aumente o disminuya únicamente por las expectativas de los inversores. Si los inversores expresan sus expectativas de crecimiento en las redes sociales se espera que exista una relación positiva con el sentimiento de esos mensajes.

4.2 Twitter

En esta sección se detallan algunas de las características de Twitter y explicaremos porque consideramos que Twitter es la mejor plataforma actualmente para adquirir todos los datos necesarios para la investigación.

Twitter es una plataforma social de *Microblogging* que empezó en el año 2006. Ahora es una de las plataformas más grandes y tiene 321 millones de usuarios activos mensuales (Statista, 2019). Casi como la población de Estados Unidos. Por lo tanto, Twitter es una de las fuentes de datos más ricas para la extracción de opiniones y el análisis de sentimientos. Como caracteriza a los servicios de *Microblogging*, Twitter permite a sus usuarios publicar mensajes cortos. Estos mensajes cortos se llaman Tweets y son de 140 caracteres como máximo. Dentro de los tweets también se puede incluir metadatos. Los metadatos más comunes son tres, el *Hashtag* ('#'), el arroba ('@') y los hipervínculos, aunque muchos tweets también incluyen localizaciones geográficas y fotos. (Castelló, 2015)

1. El *Hashtag* se usa como una etiqueta o *Tag* para dar un contexto al tweet. Twitter utiliza los hashtags para unir los tweets que hablan del mismo tema, creando una

red de opiniones de muchos usuarios diferentes. Además, Twitter te permite buscar en tiempo real diferentes temas de conversación usando estos Hashtags.

2. El arroba se usa para mencionar a otro usuario de la red, y se utiliza comúnmente para mantener conversaciones.
3. El hipervínculo adquiere un papel muy importante en Twitter, al permitir la interacción de todos los usuarios con información externa a la plataforma. Normalmente, esta información cobra la forma de noticias.

En Twitter existen diferentes formas en las que los usuarios interactúan entre ellos. Los usuarios pueden ‘seguir’ a otros usuarios cuyo contenido les parece interesante. Esto sirve para recibir notificaciones de los nuevos mensajes que publican. Además, los usuarios tienen varias formas de interactuar con el contenido. Existe el favorito, retweet y las respuestas al mismo hilo de conversación. De estas tres formas de interactuar, probablemente el retweet es uno de los más importantes ya que cuando un usuario hace retweet a un mensaje que le gusta, todas las personas que le siguen recibirán una notificación de ese mensaje y lo podrán ver en su *feed*. Los tweets y retweets de personas que tiene muchos seguidores aparecerán en el *feed* de muchas personas y a su vez las personas que hagan retweet a ese mensaje lo compartirán con todos sus seguidores.

Uno de los factores más importantes de la red es que todas estas interacciones son públicas y cualquiera puede acceder y consumir este contenido. Twitter es increíblemente atractivo para una gran variedad de investigadores. Takeshi Sakak, Makoto Okazaki y Yutaka Matsuo han construido un sistema que avisa de los terremotos ocurriendo al instante en Japón mucho antes que la Agencia de Meteorología de Japón únicamente monitoreando la actividad de Twitter (Takeshi Sakaki, 2016). Tumasjan demostró que en Alemania Twitter se utilizaba extensamente para debatir cuestiones políticas, y eran capaces de predecir las elecciones simplemente con el número de mensajes que mencionaban a cada partido político (Andranik Tumasjan, 2010).

4.3 Análisis de Sentimiento

Como se indica en la introducción de este capítulo, esta sección tiene el objetivo de explicar que es el análisis de sentimiento, cuáles son sus beneficios y limitaciones

teóricas, como se desarrollan las aplicaciones de análisis de sentimiento y como lo utilizan otros investigadores.

La cantidad de datos creados en internet cada año es altísima. En 2013 IBM estimó que se creaban 2.5 quintillones de bytes al día (IBM, 2013). Hoy ese número se ha fácilmente duplicado. La mayoría de estos datos adquieren la forma de texto, como en comentarios, mensajes en Facebook, emails, artículos de prensa... A este tipo de datos se les denomina datos no estructurados porque, en grandes cantidades, no siguen ningún patrón lógico.

Esta grandísima cantidad de datos no estructurados han provocado el desarrollo de una nueva área de estudio, llamada Procesamiento de Lenguajes Naturales (PLN o NLP del inglés *Natural Language Processing*). PLN es una importante área de estudio de la inteligencia artificial que busca entender la relación entre los ordenadores y el lenguaje natural de los humanos. Tiene como objetivo desarrollar herramientas eficaces computacionalmente para automatizar el análisis de la comunicación entre individuos o entre individuos y máquinas. Estas herramientas ayudaran a que los ordenadores analicen y clasifiquen grandes cantidades de texto para extraer y reducir información. La necesidad de crear este tipo de herramientas surge con el crecimiento de internet y de los contenidos creados por la población.

Antes incluso de que apareciese el término “inteligencia artificial”, en 1940, se comenzó a investigar la traducción automática, una de las primeras aplicaciones de lo que luego se denominó PLN. Debido a la poca capacidad computacional de los ordenadores, estos primeros intentos fracasaron. Fue a partir de 1980 se empiezan a perfeccionar las técnicas de traducción automática.

Existen muchas complicaciones lingüísticas que hacen muy complicado el desarrollo de estas herramientas. Algunas de estas complicaciones son:

- Detección de la separación entre palabras: En el lenguaje hablado en muchos idiomas, no se hacen pausas marcadas entre palabra y palabra, lo que complica muchísimo el reconocimiento de las palabras por voz. En el lenguaje escrito, hay muchos idiomas como el chino en el que no hay ninguna separación entre palabras, y esto complica muchísimo los sistemas de detección.

- Ambigüedad en el lenguaje: Muchas palabras pueden tener significados diferentes, y hay que tener en cuenta el contexto de la oración para saber a qué se refiere. También las figuras retóricas como la ironía y el sarcasmo complican el proceso porque no significan literalmente lo que ponen.
- La calidad de los datos: Los datos que tienen que analizar las máquinas pueden tener baja calidad y reducir muchísimo la precisión de las herramientas. En las herramientas de reconocimiento de voz, el ruido de fondo confunde a la herramienta muchísimo. También, los datos escritos en blogs o redes sociales muchas veces usan argot, expresiones únicas, abreviaciones o incluso errores en la formulación de la frase, que evidentemente afectan a la precisión de las herramientas y complican la tarea.

Todas estas dificultades, junto con la cantidad de idiomas diferentes utilizados en el mundo y las expresiones locales son las complicaciones que los investigadores intentan sortear para obtener buenos resultados. Los métodos utilizados para crear estas herramientas se pueden reunir en dos grandes grupos.

- Mediante el uso de modelos estadísticos (*Machine learning*) creados a partir de grandes cantidades de frases o grupos de palabras que han sido etiquetados previamente. Este método normalmente funciona muy bien para casos específicos y permite una mejor generalización en los análisis. Algunos de los inconvenientes es que se necesita clasificar y etiquetar todos los datos manualmente, normalmente por un equipo grande de expertos lingüísticos, y para que el modelo sea medianamente efectivo, se necesitan en grandes cantidades.
- Mediante el estudio gramatical y lingüístico de los datos con el objetivo de crear una serie de normas fijas (*Rule-Based Approach*). Este método suele obtener mejor precisión en la tarea concreta, pero al enfrentarlos a ambientes diferentes suele generalizar peor. Crear estas normas fijas también requiere de un equipo grande de expertos, y suele utilizar los datos de forma menos extensiva.

PLN se divide en 4 subáreas de investigación.

- La primera área se concentra en el análisis de la sintaxis del texto, con investigaciones enfocadas desde la clasificación gramatical hasta el análisis sintáctico de las frases entre otras.
- La segunda área se concentra en el análisis semántico con la búsqueda de herramientas como la traducción, reconocimiento visual de caracteres o la desambiguación del sentido de las palabras.
- La tercera área se concentra en el análisis de textos más grandes, con herramientas para crear resúmenes automáticamente o analizar el texto.
- Y la última se concentra en el análisis de voz, con herramientas de reconocimiento de voz o transformar texto a voz.

Para el estudio realizado en este trabajo de fin de grado se realizará un análisis de sentimiento en los mensajes extraídos. El análisis de sentimiento forma parte de la rama del análisis semántico. En términos generales, el análisis de sentimiento consiste en sustraer y medir las emociones u opiniones subjetivas que están expresadas en un texto. Los seres humanos podemos expresar una gran cantidad de sentimientos, pero son bastante difíciles de identificar, por lo que los modelos más fiables se basan en una clasificación de polaridad. La clasificación de polaridad busca clasificar fragmentos de texto en sentimiento negativo, sentimiento positivo o neutral. Existen dos métodos establecidos para crear un programa de análisis de sentimiento.

1. El primer método está basado en léxicos. Un léxico es una combinación de palabras con su clasificación de sentimiento. El método basado en léxicos utiliza un diccionario de palabras con el sentimiento clasificado por humanos (léxicos) para compararlo a un texto al que se le atribuye un sentimiento general.

2. El segundo método está basado en algoritmos de aprendizaje supervisados (*Machine Learning*). En estos métodos se utilizan miles de frases y textos a los que previamente se les ha atribuido un sentimiento por humanos para crear modelos estadísticos mediante técnicas de *Machine Learning*.

Los investigadores han usado análisis de sentimiento en una gran variedad de plataformas en línea. Redes sociales, blogs, reseñas en Google, reseñas en Yelp y en cualquier otro lugar donde se expongan las opiniones de los clientes. En cuanto a su uso en las redes sociales se ha investigado una gran variedad de temas. Temas como la polarización política de los usuarios, identificación de personas en depresión o en riesgo de suicidio a través de sus mensajes, identificación de terremotos, opiniones de productos o empresas y opiniones sobre activos bursátiles.

Aunque hay muchas herramientas que pueden realizar análisis de sentimiento, para esta investigación, se usara *Valence Aware Dictionary and sEntiment Reasoner (VADER)*. Investigaciones similares también utilizaron VADER para realizar el análisis de sentimiento por sus beneficios que serán detallados en la sección de Metodología.

4.4 Machine Learning

Para responder a las preguntas de la introducción al capítulo, en esta sección explicaremos al detalle que es *machine learning*, que tipos de *machine learning* hay y porque tiene sentido utilizar estas técnicas de predicción en esta investigación.

Machine Learning es el área de estudio que busca dar a los ordenadores la capacidad de aprender sin haber sido programados. *Machine Learning* comenzó en 1952 con el primer científico que creo el primer programa que aprendía y mejoraba en el juego de las damas según iba adquiriendo más experiencia (Strachey, 1952). Comúnmente se define como la investigación y el estudio de algoritmos que los ordenadores pueden usar para identificar patrones y crear modelos estadísticos para realizar tareas específicas. En 1967 el primer programa de reconocimiento de patrones fue creado y reconocía patrones en datos comparando datos desconocidos con datos conocidos y encontrando similitudes entre ellos. Hasta la década de los 90, la investigación de *machine learning* ha sido limitada sobre todo por los inconvenientes tecnológicos y técnicos, pero desde 1990 estas técnicas

se usan en áreas de minería de datos, creación de softwares adaptativos y en el reconocimiento de texto y lenguaje.

Una manera sencilla para entender *Machine Learning* es compararlo con el aprendizaje de los seres humanos. Los seres humanos aprenden con la experiencia, realizando una actividad muchas veces, identificando patrones o estrategias para realizarla más rápido y evitando errores cometidos en el pasado. En el ser humano, a esto le podemos llamar intuición. *Machine Learning*, aunque todavía no tiene la misma capacidad que un ser humano, aprende de una forma muy similar. Los algoritmos de *Machine Learning* utilizan datos del pasado, es decir experiencia, de los cuales aprenden, identificando patrones. Esto luego se transforma en un modelo que se usa para tomar decisiones basándose en la similitud de una situación nueva (datos nuevos) comparada a su experiencia (datos antiguos). Evidentemente, cuanto más completos sean los datos antiguos que van a formar parte de la experiencia del modelo, mejores resultados darán tal modelo. *Machine Learning* se divide en aprendizaje supervisado y aprendizaje no supervisado.

4.4.1 Aprendizaje supervisado

La rama de aprendizaje supervisado se utiliza para crear modelos de predicción. Estos algoritmos utilizan unos datos *input* para predecir un resultado deseado *output*. Lo más importante son los datos, y estos van a determinar la efectividad y precisión del modelo. Es por esto por lo que la mayor parte del tiempo se utiliza para limpiar los datos y así mejorar la calidad del conjunto. Dentro del proceso de limpiar los datos hay dos objetivos, el primero es identificar datos erróneos o datos que faltan, para eliminarlos o sustituirlos y el segundo objetivo es reducir la dimensionalidad del conjunto de datos eliminando las variables que estén altamente correlacionados o que a priori no son importantes para la predicción. El proceso de la reducción de dimensionalidad es importante ya que el tiempo necesario para entrenar un modelo aumenta exponencialmente con las variables *input*. Para entrenar a estos modelos generalmente se dividen el conjunto de datos en *training* y *testing*. Comúnmente el 70-80% de los datos se utilizan para entrenar un modelo y el 30-20% se utilizan para enfrentar al modelo a datos nuevos y comprobar su precisión. Uno de los problemas mas comunes es el *Overfitting*, y sucede cuando ajustas el modelo mucho a los datos que se utilizan como prueba para comprobar la precisión. Esto es un problema porque al comprobar la precisión te saldrá una precisión muy buena, pero al aplicarlo en la vida real no podrá obtener tanta precisión. La mayoría de los investigadores

tienen esto en cuenta y buscan modelos que sepan generalizar y obtengan buenas precisiones en la vida real.

Existen muchísimos algoritmos matemáticos diferentes que se pueden usar para entrenar modelos, pero todos los algoritmos se pueden clasificar en dos tipos. Algoritmos de regresión y los algoritmos de clasificación. La única diferencia entre ambos es el *output*. Si el *output* deseado es una decisión binaria, en formato sí o no, entonces se utilizan algoritmos de clasificación. Mientras que, si se busca una predicción numérica, se utilizan algoritmos de regresión.

No existe un solo algoritmo que sea eficaz en todos los problemas de aprendizaje supervisado. Dependiendo de la complejidad del problema, de la cantidad y calidad de los datos, se usarán diferentes algoritmos. Es muy común elegir varios y seleccionar el que mejor precisión adquiera.

Ej: Securitas está intentando reducir el número de incidentes falsos, porque obligan a desplazar a las autoridades correspondientes, y son un gasto de recursos innecesarios. Se puede aplicar un algoritmo de aprendizaje supervisado a los datos históricos, para crear un modelo capaz de predecir cuales incidentes son falsos con un grado de error aceptable.

4.4.2 Aprendizaje no supervisado

La rama de aprendizaje no supervisado tiene como objetivo identificar puntos en común en los datos que no se han etiquetado, clasificado o categorizado y reacciona en función de la presencia o ausencia de dichos puntos en común en cada nueva pieza de datos. Las técnicas usadas en el aprendizaje no supervisado tienen como objetivo la segmentación, etiquetando conjuntos de datos que “se parecen”. Esto se hace con técnicas de clusterización.

Dentro de las técnicas de clusterización hay muchas variantes, pero la mayoría se basan en el mismo principio que busca agrupar todos los datos según distancia hasta llegar a una cantidad de grupos deseada. Este tipo de técnicas son especialmente útiles cuando los datos tienen más de 3 dimensiones puesto que son imposibles de representar gráficamente y las personas no son capaces de segmentarlas correctamente. Además de las técnicas de

clusterización también se intenta reducir la dimensionalidad del conjunto de datos, cuando hay una gran cantidad de variables.

Ej: Telefónica recoge miles de variables diferentes de todos sus clientes y quiere segmentarlos en 6 grupos para ver cuáles son las diferencias claves y poder crear experiencias y campañas de marketing ajustada a cada grupo.

Para este problema se puede aplicar técnicas de aprendizaje no supervisado y segmentar a todos sus clientes en 6 grupos. Los clientes nuevos serán clasificados en esos grupos automáticamente.

4.5 Estudios relacionados

Los autores del artículo *Trading on twitter: using social media sentiment to predict stock returns*, Keel sul, Dennis y Yuan, profesores en Indiana University, utilizaron todos los tweets relevantes que contenían un **ticker** del Standard and Poors 500 y el clasificador de polaridad de Harvard-IV para determinar el valor emocional (negativo, positivo) para cada tweet. Durante el análisis, descubrieron que el valor emocional total de los tweets tenía un efecto significativo en los retornos del SP500 del mismo día y de los retornos de 10 días después. Adicionalmente, estudiaron la relación entre el tamaño de la cuenta de Twitter y los efectos en los activos, y descubrieron que las cuentas con muchos seguidores (más de 177) tenían un efecto directo en el retorno del mismo día, ya que la información se movía más rápido, mientras que las cuentas de menos seguidores tenían un efecto más grande en los retornos de 10 días, ya que la información se movía más lentamente.

El artículo *Predicting bitcoin price fluctuation with Twitter sentiment analysis* escrito por Lönnö y Stenquist analiza la relación entre el sentimiento reflejado en Twitter y las fluctuaciones del precio sobre un periodo de un mes (Evita Stenqvist, 2017). Los autores adquirieron los datos usando la API de Twitter y realizaron análisis de sentimiento con librerías públicas. Con estas herramientas, crearon un modelo predictivo simple que ofrecía señales con una precisión de 83% en la predicción del precio. Los autores concluyeron que el sentimiento sí que tiene relación con los movimientos del precio de bitcoin, y que los próximos estudios deberían hacer uso de técnicas de *machine learning* y enriquecer las librerías de sentimiento con léxicos específicos del sector.

El artículo *Cryptocurrency Price Prediction Using Tweet Volumes and Sentiment Analysis* escrito por Abraham, Higdon, Nelson y Ibarra investiga la relación entre el volumen y el sentimiento de los tweets que hablan sobre Bitcoin y Ethereum (otra criptomoneda) y el volumen de búsquedas en Google de ambas criptomonedas con la fluctuación de precio, entre Marzo y Mayo de 2018 (Jethin Abraham, 2018). Durante su proyecto descartaron la variable del sentimiento porque descubrieron que no tenía una gran correlación con el precio. Los autores creen que realizaron el estudio en un momento de caída en el mercado, mientras otros estudios que si encontraron relación lo hicieron en un momento en el que el mercado estaba en subida. Aun así, realizaron un modelo de predicción usando el volumen de tweets y las búsquedas en Google que ofreció una precisión bastante acertada.

Los dos últimos artículos llegan a conclusiones contradictorias. El objetivo de esta investigación es corroborar los resultados de ambas investigaciones mediante el análisis de todos los datos entre agosto de 2017 hasta enero de 2019. El periodo de estudio de este TFG contiene y amplía los periodos estudiados por ambas investigaciones obteniendo la posibilidad de corroborar sus resultados y confirmar las relaciones entre el sentimiento de la conversación de Twitter y los movimientos del precio de bitcoin. La investigación parte de la hipótesis de que sí que existe una relación positiva entre el sentimiento de los actores del mercado y los movimientos del precio de Bitcoin.

Capítulo 2: Metodología

Este capítulo desarrolla los métodos utilizados para realizar el estudio. La metodología del estudio se puede dividir en cuatro secciones:

1. Descarga de datos: En esta sección se detallará el proceso de descarga de los datos utilizados en el estudio y se explicaran las herramientas utilizadas para ello.
2. Análisis de sentimiento: Esta sección explica técnicamente el proceso seguido para realizar análisis de sentimiento, las herramientas utilizadas y las modificaciones realizadas.
3. Reducción de ruido: La reducción de ruido es una tarea importante en todas las investigaciones realizadas con datos no estructurados. En esta sección se detalla el proceso seguido para reducir ruido y eliminar mensajes que no pertenecen al objeto de estudio de esta investigación.
4. Modelo de predicción: Esta sección explica cómo se ha desarrollado el modelo de predicción y cuál es el algoritmo de aprendizaje supervisado seleccionado para el desarrollo del modelo.

5.1 Descarga de datos

Para realizar esta investigación se han adquirido dos tipos de datos diferentes. El primero consiste en los datos financieros históricos de BTC/USD y el segundo son los tweets. Todos los datos se han adquirido a través de internet y son públicos.

5.1.1 Datos financieros de Bitcoin

Para este estudio se ha descargado diferentes datos financieros desde agosto de 2017 hasta enero de 2019. Todos los datos se han descargado con una granularidad horaria. Los datos descargados son el tipo de cambio de bitcoin a dólares estadounidenses, en formato *Open*, *High*, *Low*, *Close* y el volumen en dólares y en Bitcoins. La descarga de todos estos datos financieros se ha realizado desde la página web de www.bitconcharts.com (Bitcoincharts, s.f.). Para esta descarga no ha sido necesario desarrollar ningún tipo de programa puesto que esta información es fácilmente accesible.

5.1.2 Datos de Twitter

En esta sección se expondrán los métodos que han utilizado algunas investigaciones relacionadas para obtener los datos de Twitter e introduciremos una nueva herramienta a este campo de investigación que ofrece mejores resultados.

Twitter ha desarrollado varias *Application Programming Interfaces* o APIs para facilitar la interacción de otros servicios con Twitter (Twitter Apis, s.f.). Básicamente una API sirve para pedir a los servidores de alguna página web, en este caso la página web de Twitter, que te devuelvan algún tipo de información. Entre las APIs de Twitter, una de ellas te permite descargar mensajes y metadatos de los usuarios de la red. Las investigaciones más recientes que se enfrentaban a este problema utilizaron las herramientas creadas por Twitter para la descarga de datos (Jethin Abraham, 2018) (Evita Stenqvist, 2017).

En principio, las APIs de Twitter ofrecen buenos resultados. Pero para este estudio existían inconvenientes. La versión gratuita solo permite descargar hasta 1500 tweets sobre cualquier tema de los últimos 7 días. La descarga es aleatoria y está limitada a la última semana. Estas limitaciones han obligado a los investigadores anteriores a sortearlas con incómodos trucos y solo han podido adquirir datos durante periodos de tiempo pequeños. Abraham, Higdon, Nelson y Ibarra (2018) crearon una herramienta para hacer uso de la API cada 15 minutos y la mantuvieron funcionando durante 4 meses. Lönnö y Stenqvist (2017) recogieron datos de tan solo un mes. Para este estudio se planteaba la investigación de un periodo de tiempo muy grande e histórico.

GetOldTweets es una librería pública de Python que fue creada para sortear las limitaciones de la API pública de Twitter (GetOldTweets, s.f.). Gracias a esta librería, cualquiera puede descargar todos los tweets históricos sobre un tema. Su funcionamiento es sencillo. Realiza una búsqueda en Twitter con el término deseado limitándola a un periodo de tiempo fijo. Aprovechándose de la funcionalidad de “*scroll down*” infinito, carga todos los mensajes del periodo uno a uno descargando la información expuesta. Gracias a esto, este proyecto ha podido adquirir todos los datos del periodo y va a poder estudiar datos históricos.

Otra de las ventajas de GetOldTweets es que requiere muy poco conocimiento de programación. En la siguiente imagen se puede ver un extracto del código utilizado para descargar los tweets.

```
01. tweetCriteria = got.manager.TweetCriteria().setQuerySearch('bitcoin')\  
02.                 .setSince("2018-09-10")\  
03.                 .setUntil("2018-09-11")\  
04.                 .setLang('en')\  
05.                 .setLang('en')\  
06. tweet = got.manager.TweetManager.getTweets(tweetCriteria)[0]  
07. print(tweet.text)
```

Figura 2: Extracto de código en Python para extraer los mensajes de Twitter

Para la extracción de datos se ha utilizado una variante del extracto de código representado en la figura 2 cambiando las variables de tiempo. Todos los datos se han descargado día a día formando un total de 539 días y 17.737.519 millones de tweets.

5.2 Análisis de sentimiento

Para realizar análisis de sentimiento la investigación ha hecho uso de VADER, un programa realizado específicamente para realizar análisis de sentimiento en las redes sociales (Gilbert, 2013). En esta sección, se explicará detalladamente el funcionamiento de VADER y las modificaciones realizadas con el objetivo de obtener mejores resultados (VADER, s.f.).

5.2.1 VADER

VADER es un software de análisis de sentimiento que utiliza una combinación de léxicos y de reglas para detectar polaridad (Positivo, negativo y neutral) e intensidad en el texto (Gilbert, 2013). Los autores publicaron su trabajo junto con su artículo de investigación en 2014 con una licencia de MIT, por lo que se considera *Open Source*. Desde entonces VADER ha sido utilizado en numerosas investigaciones y en tan solo 4 años, ha sido citado más de 600 veces (SemanticScholar, 2019). VADER esta publicado en GitHub como una librería para Python.

Hutto y Gilbert crearon VADER específicamente para intentar solucionar el problema de realizar análisis de sentimiento en las redes sociales, ya que los mensajes están limitados a un numero de caracteres, provocando abreviaciones de las palabras, el uso de emoticonos y el uso de mucho argot.

Con este objetivo, los autores examinaron y seleccionaron léxicos de otros 3 diccionarios de léxicos ya validados por la comunidad de investigadores. *Linguistic Inquiry and Word Count (LIWC)*, *Affective Norms for English Words (ANEW)* y *General Inquirer (GI)* (Ashok Deb, 2018). Estos diccionarios de léxicos no están preparados para las redes sociales, asique los autores ampliaron, añadiendo emoticonos, argot, y las abreviaciones más comunes. A cada léxico se le añade un valor de sentimiento. Este valor de sentimiento es la media de la valoración de 10 personas independientes. Con este proceso, los autores crearon un diccionario de 7500 léxicos. Adicionalmente, los autores examinaron 800 tweets en búsqueda de patrones, y a raíz de eso incluyeron 5 reglas fijas a la solución. Las reglas son las siguientes:

1. Incrementar intensidad si hay un signo de exclamación. *Ej: ¡cuanto más lo veo más me gusta!*
2. Incrementar intensidad si hay palabras en mayúsculas en presencia de palabras en minúscula. *Ej: nunca entiendo NADA*
3. Incrementar intensidad en presencia de palabras que indican intensidad. *Ej: Él es extremadamente gracioso.*
4. Añadir sentimiento negativo en presencia de conjunciones negativas. *Ej: Me gusta, pero prefiero otra cosa*
5. Dar la vuelta al signo del sentimiento en caso de negaciones. *Ej: No está bien*

En la publicación compararon VADER a otras 11 herramientas de análisis de sentimiento realizando test en 4 plataformas diferentes, editoriales del New York Times, texto de las redes sociales, reseñas de productos y críticas de películas. VADER obtuvo resultados que le clasificaban entre los mejores en todas las plataformas, ya que era capaz de generalizar mejor que las demás, y en las redes sociales obtuvo la mejor precisión (Gilbert, 2013).

5.2.1.1 Modificaciones de VADER

VADER tiene un diccionario de léxicos bastante amplio, de unos 7500 términos. El sentimiento adjuntado a estos términos es genérico y tiene el objetivo de poder representar el sentimiento de dominios muy dispares. En el caso de la comunidad de bitcoin, existen muchas expresiones únicas que en ese entorno tienen un significado propio. Algunas de esas expresiones no están incluidas en el léxico de VADER. Investigaciones similares

observaron este problema y recomendaron implementar un diccionario específico del dominio. Por ello, este estudio implementa las recomendaciones de dichas investigaciones y añade léxicos propios al diccionario de VADER con el objetivo de representar mejor el sentimiento de la comunidad que rodea al bitcoin.

El proceso de creación del léxico propio tiene varias fases:

1. La investigación ha hecho un análisis de más de 1.500 mensajes extraídos analizando las expresiones utilizadas y creando un diccionario de expresiones para valorar.
2. Siguiendo el mismo método que VADER utilizó para registrar sentimiento a cada léxico, la investigación ha contactado a través de internet con 10 personas independientes familiarizadas con el dominio de Bitcoin en Twitter. A través de una encuesta en línea, las personas independientes han valorado cada palabra y expresión entre -4 y +4 siendo -4 extremadamente negativo y +4 extremadamente positivo.
3. Una vez obtenidos los resultados y siguiendo el mismo proceso que utilizaron los autores de VADER, se realiza una media y una desviación típica de cada expresión y palabra. La media será el sentimiento final que se incluye en el léxico de VADER y la desviación típica si mayor de 2.5 sirve como filtro para no incluir palabras o léxicos cuyo sentimiento no parece tener consenso.

Siguiendo este proceso la investigación ha añadido un total de 35 palabras y expresiones únicas del dominio de Bitcoin en Twitter al diccionario de léxicos de VADER. En la tabla 1 se puede observar un extracto de algunos de estos términos.

<i>Expresión</i>	<i>Media de sentimiento</i>	<i>Desviación típica</i>
<i>Bull</i>	1.8	1.6
<i>Bear</i>	-1.3	1.8
<i>Manipulation</i>	-2.7	1.27
<i>SEC</i>	0	1.4
<i>Hodl</i>	0	2.3

Tabla 1: Extracto de léxicos añadidos al diccionario de VADER

5.2.1.2 Clasificación de polaridad

Para hacer el análisis de sentimiento la investigación ha programado un script en Python utilizando la librería de VADER modificada. La figura 3 contiene un extracto del código escrito para evaluar los tweets con la librería de VADER.

```

01. from vaderSentiment.vaderSentiment import SentimentIntensityAnalyzer
02.
08. analyzer = SentimentIntensityAnalyzer()
09. for tweet in text:
10.
11.     info = analyzer.polarity_scores(tweet)
12.
13.     negative_string.append(list(info.values())[0])
14.     neutral_string.append(list(info.values())[1])
15.     positive_string.append(list(info.values())[2])
16.     compound_string.append(list(info.values())[3])

```

Figura 3: Extracto de código en Python para realizar análisis de sentimiento

La tabla 2 contiene ejemplos de cómo VADER evalúa y clasifica los tweets en sentimiento positivo, sentimiento neutral y sentimiento negativo. Los ejemplos de la tabla se han escogido al azar.

<i>Clasificación</i>	<i>Usuario</i>	<i>Tweet</i>	<i>Hipervínculo</i>
Positivo	iMarketingly	Whatever you decide to do, make sure it makes you Happy. #Hapiness #Inspiration #Spheris @spheris_io #ICO #Ethereum #Bitcoin #Blockchain	https://twitter.com/iMarketingly/status/912669307078938626
	Bitcoins_future	The technology is not under threat at all, it is extraordinary, highly successful #pauldavis #bitcoin #bitcoins #coins #pauldavis #bitcoin #bitcoins #coins	https://twitter.com/bitcoins_future/status/908369866238959618
Neutro	KXconnect	Moscow Stock Exchange Prepares to Trade Cryptocurrency - Bitcoin News http://ow.ly/ZilJ30eNU4t	https://twitter.com/KXconnect/status/904852859967217664

Negativo	AndrewBloch	Frank. Now accepting Bitcoin. pic.twitter.com/mr4iq8Qhhp	https://twitter.com/AndrewBloch/status/908656721576579072
	LifeGen	Bitcoin wallet hacked via SMS interception https://lnkd.in/gdFP8Yh	https://twitter.com/LifeGen/status/910622686434410496
	MrChrisEllis	Your Phone Is Unsafe, #BlueBorn Exploit Revealed - Oh And China Is Still "Banning" Bitcoin http://youtu.be/NZg1OlnpLQY pic.twitter.com/HSw4vP8hOv	https://twitter.com/MrChrisEllis/status/907722864215945218

Tabla 2: Ejemplos de mensajes clasificados como positivos, neutros y negativos

5.2.2 Reducción de ruido

No todos los tweets están escritos por humanos. Se estima que un 15% de todos los usuarios de Twitter son bots (Chong, 2017). Si estos bots escriben y publican mensajes que contienen cargas de sentimiento, los datos descargados contendrán mensajes que no pertenecen al objeto de este estudio, y a la hora de analizarlos provocara conclusiones erróneas. En esta sección se detallará el proceso seguido para identificar a los bots, consiguiendo reglas fijas que servirán como filtro tras un análisis de 700.000 tweets.

Para identificar a los usuarios que son bots, este estudio ha analizado individualmente más de 3.000 mensajes. Los 3.000 mensajes se iban eligiendo al azar sobre un extracto de 700.000 mensajes. El objetivo del análisis es identificar patrones de comportamiento de usuarios que tienen objetivos diferentes al dialogo sobre el valor de bitcoin. Durante el análisis se han identificado mensajes que (1) buscaban aumentar sus seguidores en diferentes plataformas (2) ofrecían criptomonedas gratuitamente (3) publicaban el precio actual de la criptomoneda periódicamente (4) hablaban de otras criptomonedas (5) realizaban actividades comerciales buscando participantes para concursos, plataformas de casino o incitaban a la compra de criptomonedas desde links patrocinados (6) no hablaban en absoluto de Bitcoin. El estudio se ha cerciorado de que la mayoría de los mensajes que se ajustan a los patrones descritos anteriormente no son válidos.

Tras identificar estos patrones de comportamiento se han realizado reglas fijas que actúan como filtros eliminando su carga sentimental y se han clasificado como bots. Clasificarlos como bots nos permite eliminar la carga sentimental de estos mensajes para evitar el sesgo aun manteniendo una medida de volumen que representa interés por parte de actores que crean estos bots para beneficiarse del ecosistema junto con el valor de bitcoin. Las reglas fijas que formaran parte del filtro son:

1. Se eliminarán todos los mensajes que no contengan la palabra “bitcoin” o variantes (“BTC”, “btc”, “Bitcoin”, “BITCOIN”) ni en el texto del mensaje ni como hashtag.
2. Se eliminarán todos los mensajes que se identifiquen como bots en el hashtag
3. Si cualquier usuario publica exactamente el mismo mensaje que ya publico anteriormente se eliminaran porque se entiende que es un bot publicitando o spam.
4. Todos los mensajes que contienen palabras como “Bitcoin cash” (otra criptomoneda), “Free bitcoin”, “Join now”, “Current Price” o “earn bitcoin”, “free bitcoin”, “Join now”, “current price”, “giveaway”, “Airdrop”, “giveaway” tanto en el texto del mensaje como en el hashtag.
5. Algunos usuarios comparten links con la intención de que otros usuarios se unan a grupos o reclamen premios. Estos enlaces suelen contener las palabras “/claim” o “/join” en la url. Todos los mensajes que contengan links con esas palabras serán eliminados.

Regla	Usuario	Tweet	Hipervínculo
<i>Tweets que no hablan sobre Bitcoin</i>	cryptos_teem	I feel somewhere in between Scam? And Buy now.. but not Meh.. Long Forgotten. I bought 650k of them and sold at 22sat.. next day it was 70.. then 100.. then 900 and so on. #sittinout	https://twitter.com/cryptos_teem/status/954914921896185856
<i>Tweets que se identifican como bots</i>	BTCPriceBot	#BTC 24hr Summary: Last: \$16408.70 High: \$17122.00 Low: \$15755.01 Change: -3.55% \$-603.30 Volume: \$140,985,634.3 \$BTC #Bitcoin #Pricebotspic.twitter.com/aVyn6HqXff	https://twitter.com/BTCPriceBot/status/950140415243567104

<i>Tweets del mismo autor exactamente iguales</i>	nicolem7797073 1	Start mining Bitcoin today. Join here to win a mining rig! https://gocryptly.com/need-new-mining-rig/ ...	https://twitter.com/nicolem77970731/status/962689087768485888
<i>Tweets con palabras identificadas como bots</i>	Tobarman	Mega #Airdrop of \$1 Million #BTK \$BTK #BitcoinToken ! There will be 10 winners [The rules are] Follow us >> @bitcoin_token Like & RT this tweet. Comment with your ETH address. This Mega #Airdrop will finish once there are 4000 participants joined.	https://twitter.com/Tobarman/status/955752294200561664
<i>Tweets que buscan seguidores</i>	JonnyCrypto111 1	Get into Crypto with £7 free Bitcoin when you buy with Pounds or Dollars https://www.coinbase.com/join/59ea7ceae7be8200c5938493?src=twitter ... #BTC #Bitcoin #Crypto #Cryptocurrencies #free #Ether #ETH #Ethereum #Money #BTC #Bitcoin #Crypto #Cryptocurrencies #free #Ether #ETH #Ethereum #Money	https://twitter.com/JonnyCrypto1111/status/948308473061797889

Tabla 3: Ejemplos de mensajes que no han pasado el filtro establecido

Tras procesar todos los datos con el filtro se han clasificado un 15.57% de los mensajes como bots, sumando un total de 2.887.231 tweets. La tabla 3 contiene algunos de los mensajes clasificados como bots.

5.3 Modelo de predicción

Finalmente, en esta sección describimos la metodología seguida para crear el modelo de predicción. Tras explorar las opciones de modelos de predicción que se podían aplicar a este problema, la mejor solución la ofrecen los algoritmos de aprendizaje supervisado de Deep learning. Para esto se utiliza la librería Keras, una librería creada inicialmente como parte de la investigación en el proyecto ONEIROS (*Open-ended Neuro-Electronic Intelligent Robot Operating System*) (Keras, s.f.).

Keras es una librería muy compleja, de la cual solo usamos su capacidad para crear modelos de predicción a través de redes de neuronas recurrentes (*Recurrent neural networks*). Las redes neuronales recurrentes es una de las mejores soluciones para crear modelos sobre datos secuenciales o dinámicos, es decir, que tienen dependencia del tiempo. En nuestro caso, tenemos datos que dependen del tiempo, y al utilizar redes neuronales recurrentes, el modelo tendrá en cuenta los valores pasados y presentes antes de predecir un valor futuro. El modelo final que utilizamos está realizado con LSTM (*Long Short Term Memory*), que es uno de los algoritmos más comunes para crear este tipo de redes neuronales recurrentes.

Para crear el modelo se han utilizado únicamente datos adquiridos a través de Twitter y el precio de bitcoin que sirve para que el modelo pueda ajustarse a esa variable. La mayoría de los datos de Twitter se adquieren tras el análisis de sentimiento y el filtro agrupados horariamente. En la figura 4 se pueden observar un extracto de los datos utilizados para crear el modelo.

Date	Close	Compound_Score	Total Volume of Tweets	Count_Negatives	Count_Positives	Count_Neutrals	Sent_Negatives	Sent_Positives	Count_News	Count_Bots
2017-08-01 00:00:00	2825.92	0.082893	1027.0	139.0	347.0	397.0	-0.516620	0.417882	695.0	144.0

Figura 4: Variables finales del estudio

De estos datos, algunos reflejan sentimiento como ‘*compound_Score*’ que es el sentimiento medio únicamente de los mensajes que no han sido clasificados como bots por el filtro, ‘*Sent_Negatives*’, ‘*Sent_Positive*’ que es el sentimiento medio únicamente de los mensajes no clasificados como bots negativos y positivos respectivamente. También hay datos que reflejan medidas de volumen como ‘Total volumen of tweets’ que refleja el volumen total de tweets incluyendo a los mensajes clasificados como bots, ‘*Count_News*’ que indica el volumen de mensajes que comparten links (Esto se utiliza porque si hay alguna noticia importante el volumen de ‘*Count_News*’ aumenta), ‘*Count_bots*’ que mide el volumen de mensajes eliminados al ser clasificados como bots por el filtro, y por último ‘*Count_Negatives*’, ‘*Count_Neutrals*’ y ‘*Count_Positives*’ que es el volumen de mensajes negativos, neutrales y positivos respectivamente. La variable ‘Close’ es el

precio de bitcoin al final del periodo. Todas estas variables se podrían clasificar en variables que representan volumen de mensajes y sentimiento medio de los mensajes.

De entre las muchas opciones de configuración que tiene LSTM, una de ellas es cuánto tiempo en el pasado tendrá en cuenta el modelo para predecir el valor futuro. Esta decisión es complicada porque hay que conseguir que el modelo conozca suficiente del pasado para entender la tendencia del valor de bitcoin, pero al aumentar esta variable incrementa exponencialmente el tiempo computacional de crear el modelo. Durante la creación del modelo se ha experimentado con diferentes periodos de tiempo, y parece razonable utilizar 1 día anterior para predecir un valor en el futuro.

Otra de las opciones de configuración de LSTM es cuanto tiempo a futuro se quiere predecir. Para esto se ha experimentado con diferentes tiempos y en capítulo siguiente se enseñarán las predicciones de 3 modelos diferentes que han sido entrenados para predecir a 4h en el futuro, 24 horas y 48 horas.

Capítulo 3: Resultados

Este capítulo desarrolla en primera parte un análisis exploratorio de los datos adquiridos y posteriormente los resultados de los modelos de predicción propuestos. El objetivo del análisis exploratorio es descubrir las relaciones existentes entre las variables como el sentimiento o el volumen de tweets con relación a los movimientos del valor de Bitcoin. Esto nos servirá para ajustar las variables de entrada que el modelo de predicción usa para aprender obteniendo predicciones más precisas.

El periodo de estudio (desde 2017-08-01 hasta 2019-01-21) ha sido seleccionado intencionadamente por contener un mercado alcista donde el valor de bitcoin creció un 700% en 4 meses y un mercado bajista con unas pérdidas de 82% en 13 meses con respecto al valor más alto. Tras limpiar y modificar los datos adquiridos durante este periodo podemos obtener una visión global de la relación de las variables con respecto al valor de bitcoin durante los dos mercados diferentes y observar si las correlaciones entre las variables se mantienen. La figura 5 contiene el valor de bitcoin durante todo el periodo de estudio, identificando con el color azul el periodo del mercado alcista y con el color rojo el periodo del mercado bajista.




Figura 5: Gráfica del precio de bitcoin durante el periodo del estudio. Gráfica realizada con la Matplotlib en Python.

6.1 Análisis exploratorio del sentimiento

Una de las hipótesis presentadas inicialmente deduce que existiría una correlación positiva entre el sentimiento expuesto en las redes sociales y el valor de bitcoin, siendo los mensajes positivos cuando el valor aumenta y mensajes negativos cuando el valor disminuye. Por lo tanto, se esperaba que durante el mercado alcista los mensajes fuesen positivos y durante el mercado bajista los mensajes fuesen negativos. En la figura 6 se muestra un histograma del sentimiento que rompe la hipótesis, puesto que el sentimiento es durante todo el periodo estable sobre valores positivos (entre 0 y +1) y no hay casi ningún valor de sentimiento negativo (entre -1 y 0). Además, la media del sentimiento durante el mercado alcista es un poco más negativa que la media del sentimiento durante el mercado bajista, siendo un poco más positiva. La diferencia en el tamaño entre el sentimiento del mercado bajista (expresado con color rojo) y el sentimiento del mercado alcista (expresado con color azul) viene dada por que el periodo del estudio contiene solo 4 meses de mercado alcista y 13 meses de mercado bajista.




Figura 6: Histograma del sentimiento. Gráfica realizada con la Matplotlib en Python.

Para reafirmar que la hipótesis no se cumple, en las figuras 7 y 8 se puede observar la relación entre los movimientos del valor de Bitcoin y el sentimiento medio expuesto en Twitter durante el periodo de 10 días (desde el 1 de agosto de 2018 hasta el 10 de agosto de 2018, escogida al azar). Ambas variables se han suavizado con una media móvil de 24 horas para ver claramente las tendencias en la primera imagen. La correlación Pearson es de 0.015 durante todo el periodo de la investigación.




Figura 7: Relación entre precio de Bitcoin y sentimiento 1. Gráfica realizada con la Matplotlib en Python.




Figura 8: Relación entre precio de Bitcoin y sentimiento 2. Gráfica realizada con Matplotlib en Python.




Figura 9: Gráfica de dispersión que representa el sentimiento medio en el eje Y con el cambio de precio en el eje X. Gráfica realizada con Matplotlib en Python

Como se puede observar en la figura 9 la relación entre el sentimiento medio en el presente con el cambio de precio en el presente es aleatoria. Sería importante observar si existe la posibilidad de que el sentimiento medio presente pueda estar correlacionado con el cambio de precio en el futuro para entender las capacidades predictivas de la variable. Para ello se ha realizado la figura 10 que representa la correlación entre ambas variables para cada momento en el futuro. Para un lag temporal de 200 el valor representado es la relación entre el sentimiento actual con el cambio del precio de dentro de 200 horas. Como se puede observar, esta variable no tiene capacidades predictivas a futuro.




Figura 10: Autocorrelación entre el sentimiento y el cambio de precio según el tiempo. Gráfica realizada con Matplotlib en Python

6.2 Análisis exploratorio del volumen

Aunque la carga de sentimiento no tiene correlación con el valor de bitcoin, el volumen de tweets sí que tiene una correlación positiva incluso durante el periodo del mercado bajista. Esto puede ser porque cuando el mercado es bajista las personas que siguen participando en la conversación en línea son aquellos que les interesa más cosas que el valor de bitcoin hablando positivamente de él. Lo que sí que parece ser es que el volumen de mensajes es una mejor variable para ver el interés del público hacia la criptomoneda y tiene una correlación más fuerte hacia el precio. En la figura 11 se compara el precio histórico de Bitcoin con el volumen de tweets y visualmente se puede observar la relación positiva. La correlación Pearson es de 0.64 durante todo el periodo de la investigación.

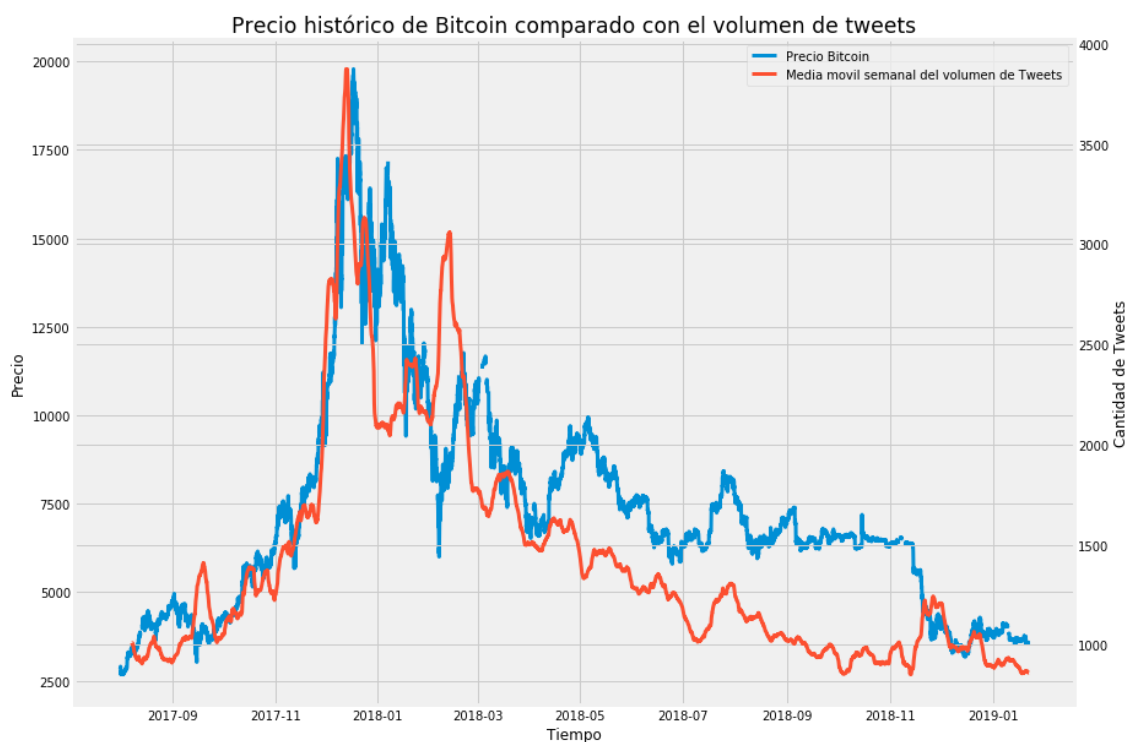


Figura 11: Relación entre volumen de mensajes y el precio de Bitcoin. Gráfica realizada con la Matplotlib en Python.

Como en la sección anterior, es interesante observar la capacidad predictiva de la variable de volumen. En la figura 12 se puede observar la correlación entre las variables para diferentes periodos del futuro. La variable de volumen tiene una buena capacidad predictiva teniendo mejor correlación entre el volumen del presente con el precio de dentro de 8 días que con el precio del presente.

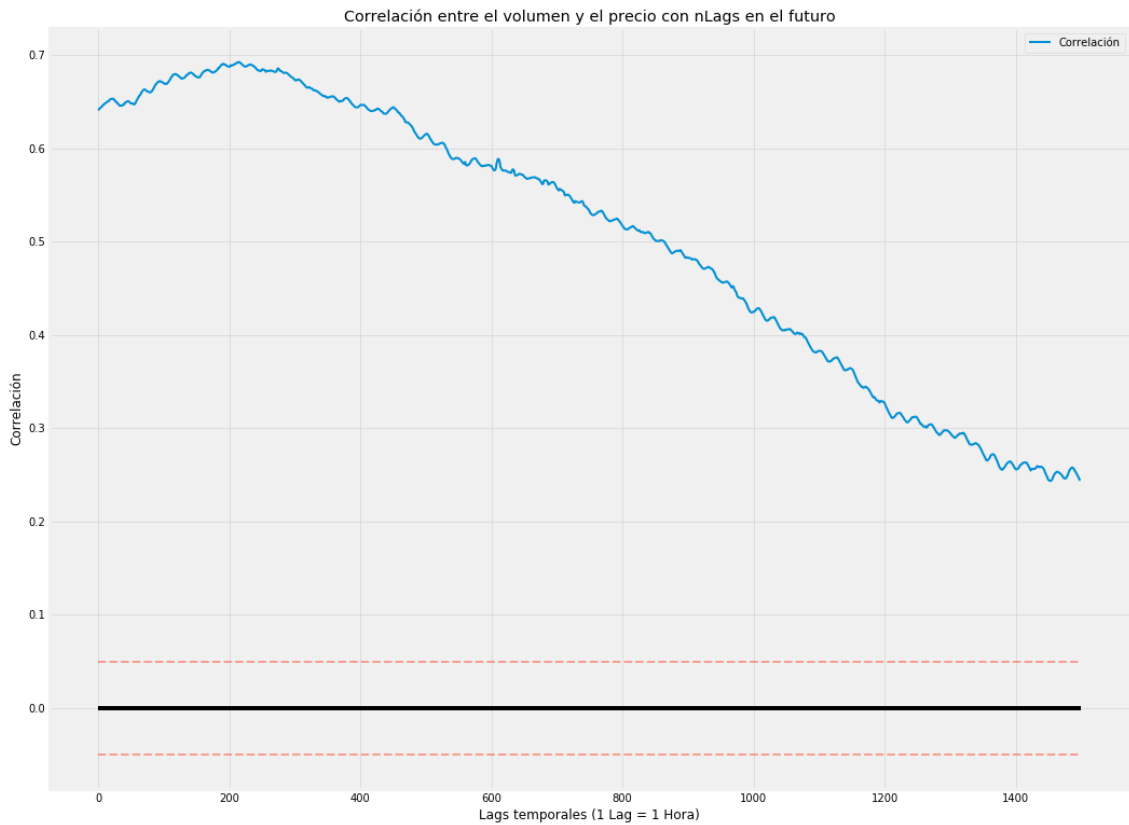


Figura 12: Autocorrelación entre el volumen y el cambio de precio según el tiempo. Gráfica realizada con Matplotlib en Python

6.3 Resultados

Se han creado 3 modelos diferentes que predicen 1h en el futuro, 4h y 24h en el futuro. Todos los modelos utilizan los datos de las últimas 24 horas para predecir. Dos tipos de variables han sido consideradas para crear los modelos de predicción, volumen de tweets y sentimiento medio de los tweets. Aunque el sentimiento no es una buena variable para predecir el valor de Bitcoin ya que la correlación positiva no se mantiene cuando el mercado es bajista, se han incluido este tipo de variables en el modelo de predicción. Los datos de volumen si tienen una alta correlación con el precio. Los datos del modelo están en una franja de tiempo horaria.

La creación del modelo ha seguido los fundamentos clásicos del protocolo de machine learning. Los datos adquiridos se han dividido en 80/20 utilizando el 80% de los datos para entrenar a los modelos y el 20% para comprobar la precisión del modelo. La figura 13 representa la distribución de los datos.




Figura 13: Distribución del periodo de entrenamiento y de pruebas. Gráfica realizada con la Matplotlib en Python.

La imagen 14, enseña los resultados de predicción de los modelos a 4 horas a futuro, 24 y 48 horas de predicción. Los modelos tienen un error cuadrático medio de 387, 483 y 818 respectivamente es decir que el error medio de predicción es de esos valores. Como se puede observar en las gráficas, la primera parte de la predicción es bastante certera, pero tras una gran caída el modelo tiende a predecir por encima de los valores reales. Esto se debe a que la caída ha sido un evento único no presente en los datos de entrenamiento del modelo. La predicción de un futuro más lejano es mucho menos certera, con un error cuadrático medio de 818.




Figura 14: Resultados de las predicciones de todos los modelos con el precio real 1. Suavizado con media móvil de 24 horas. Gráfica realizada con la Matplotlib en Python.




Figura 15: Regresión lineal de los precios estimados y los reales. Gráfica realizada con la Matplotlib en Python.

Puesto que el modelo no había sido entrenado con el evento único, los resultados no son los mejores. En la figura 16 se pueden ver las predicciones de los 3 modelos incluyendo el evento único en el entrenamiento. Una vez incluido el evento único en el entrenamiento del modelo los resultados de predicción son mucho mejores con unos errores cuadráticos medios de 244, 320, 600 para los modelos de 4 horas, 24 horas y 48 horas.




Figura 16: Resultados de las predicciones de todos los modelos con el precio real 2. Suavizado con media móvil de 24 horas. Grafica realizada con la Matplotlib en Python.

<i>Modelos</i>	<i>Error cuadrático medio</i>
<i>4 horas a futuro sin evento único en entrenamiento</i>	387.5
<i>24 horas a futuro sin evento único en entrenamiento</i>	483.56
<i>48 horas a futuro sin evento único en entrenamiento</i>	818.43
<i>4 horas a futuro con evento único en entrenamiento</i>	244.3
<i>24 horas a futuro con evento único en entrenamiento</i>	320.8
<i>48 horas a futuro con evento único en entrenamiento</i>	600.5

Tabla 4: Rendimiento de todos los modelos

Capítulo 4: Discusión

El capítulo 4 es el último capítulo de este artículo y en él se desarrollan las ideas finales sobre la investigación realizada. El capítulo se divide en 3 secciones, la primera establece los problemas éticos y debilidades de la metodología seguida identificados durante todo el proceso de la investigación, la segunda sección trata todas las recomendaciones para investigaciones futuras, aportando una opinión subjetiva sobre el camino a seguir para contribuir a esta literatura y, por último, la tercera sección es una conclusión destacando todo el proceso y los resultados obtenidos.

7.1 Problemas éticos y debilidades técnicas

Durante todo el transcurso de la investigación se han identificado varias problemáticas importantes que pueden afectar al resultado. Esta sección detalla todas las problemáticas dignas de mención con el objetivo de aportar información valiosa a futuros investigadores. Los problemas técnicos identificados son la falta de datos al realizar una descarga histórica y la falta de robustez en el análisis de sentimiento. También se mencionan consideraciones éticas en el tratamiento de los datos, que, aunque sean propiedad pública pueden ser de contenido sensible.

7.1.1 Falta de datos

Aunque los mensajes descargados han sido adquiridos históricamente, no son los mismos mensajes que existían en aquel momento. Al adquirir los mensajes históricamente solo se están obteniendo aquellos mensajes que no han sido borrados por los usuarios o por la propia plataforma de Twitter, es decir, los mensajes que en el momento de descarga están todavía accesibles en la plataforma. Durante el análisis descrito en el capítulo 2 para realizar el filtro de los mensajes, realizado en abril de 2019, se observó que muchos mensajes descargados en noviembre de 2018 ya no estaban disponibles en la plataforma de Twitter ya sea porque el usuario ha eliminado los mensajes individualmente, toda la cuenta en su totalidad o hayan sido eliminados por Twitter. Además, Twitter elimina activamente todas las cuentas que considera que están controladas por bots o las cuentas abandonadas. Las medidas de volumen y el sentimiento adquiridos por esta investigación están claramente afectados por este problema ofreciendo medidas de volumen y sentimiento ligeramente diferentes a las reales, complicando la predicción del valor de bitcoin.

Otro de los problemas que la investigación ha identificado es la descarga de los emoticonos que contenían los tweets. GetOldTweets, el programa utilizado para la descarga de datos de la plataforma de Twitter no tenía soporte para la descarga de los emoticonos que iban asociados al mensaje. Ya que uno de los puntos más fuertes de VADER es tener disponible un diccionario de emoticonos con medidas de sentimiento asociadas, no poder descargar los emoticonos, provoca una falta de información que es importante ya que aporta contexto al resto del dialogo de cada tweet. Cuantos más completos son los datos de la investigación, VADER ofrecerá mejores estimaciones de sentimiento y las asociaciones con el movimiento del precio serán más precisas. Futuras investigaciones deberán tener en cuenta la carga de sentimiento que ofrecen los emoticonos y modificar los programas de extracción para no perder esa información.

7.1.2 Falta de robustez en el análisis de sentimiento

Aunque VADER es una de las mejores herramientas para realizar análisis de sentimiento en las redes sociales, la investigación ha identificado muchos mensajes puntuados erróneamente. Algunos de los problemas más comunes suceden en mensajes positivos con una puntuación negativa o mensajes que contienen carga sentimental, pero han sido identificados con una puntuación neutra. El primero de los casos sucede porque los mensajes contienen complejas formas léxicas y expresiones con dobles negaciones complicando la estimación del sentimiento y el trabajo de VADER. El segundo de los casos parece estar relacionado con la falta de léxicos específicos del dominio provocando que VADER no asocie las nuevas expresiones con su carga de sentimiento correcta. Esta investigación ha aumentado el diccionario de léxicos de VADER, pero la cantidad de palabras analizadas y incluidas es pequeña. Investigaciones futuras podrían analizar e incluir muchos más léxicos específicos del dominio para mejorar la precisión de las medidas de sentimiento realizadas por VADER.

7.1.3 Consideraciones éticas

Trabajar con los datos de Twitter introduce preocupaciones éticas en torno a la privacidad del autor de los tweets recopilados y la responsabilidad ética de mantener la privacidad de quienes le confían sus datos. Todos los tweets recopilados son puestos a disposición pública por el autor a través publicación y el envío del "tweet" en la plataforma de Twitter.

Además, Twitter permite la descarga de estos tweets haciéndolos accesibles a través de su API (interfaz de programación de aplicaciones). Los autores aceptan que toda la información publicada en la plataforma pasara a ser de propiedad pública al aceptar los términos y condiciones de la plataforma. Pero esto no significa que los autores de los tweets tengan conocimiento de todas las formas diferentes en que se puede acceder a su información y de la utilidad comercial y de investigación que aporta todo lo que twitteen. Algunos pueden creer que solo sus amigos u otras personas que elijan "seguirlos" en Twitter verán sus tweets. Como tal, es posible que la recopilación y el trabajo de estos datos estén haciéndolos algo más "públicos" de lo que el autor pretendía o se dio cuenta de que sería. Teniendo esto en cuenta, esta investigación ha decidido proteger la privacidad de los autores de la información pública recopilada. Los tweets recopilados nunca se almacenaron en lugares visibles públicamente como GitHub. Toda la información publicada esta agregada haciendo imposible la identificación de los autores de la información.

Consideraciones éticas adicionales rodean las propias criptomonedas. Actualmente el comercio y la inversión de las criptomonedas no está regulado, y aunque esto genera desconfianza en muchos inversores, para muchas otras personas es parte de su atractivo. Las criptomonedas han servido en muchas ocasiones para el comercio de bienes y servicios ilegales. El ejemplo más conocido es la página web *silkroad* o la "Ruta de la Seda" activa en la *deepweb* ("red oscura") hasta julio de 2017. En esta página web se comerciaban todo tipo de bienes y servicios ilegales (Ej. pornografía infantil, drogas, armas, material radiactivo). El anonimato de las criptomonedas lo hizo atractivo como moneda de cambio para actividades ilícitas. Proporcionar un modelo para predecir los cambios en el precio de la criptomoneda podría llevar al aumento de la inversión por parte de ciudadanos sin experiencia y conocimiento en búsqueda de beneficio seguro confiando en la eficacia del modelo. Esto a su vez podría llevar a que las personas utilicen cada vez más las criptomonedas como un almacén de valor. El riesgo existe en el posible error de predicción que puede tener el modelo generando grandes pérdidas a todas las personas que confiaban en las predicciones. Para evitar esto, se han hecho esfuerzos para explicar claramente cómo funciona el modelo de predicción enseñando los errores predictivos que suceden cuando el mercado realiza un movimiento único e inesperado. La aplicación comercial de modelos de predicción similares para la inversión en cualquier tipo de activo ha de hacerse con conocimiento de los riesgos que conlleva un error de predicción del

modelo. La volatilidad del precio de bitcoin significa que un movimiento inesperado puede generar pérdidas de hasta un 50% o más.

Finalmente, en la medida en que el modelo de predicción sí que es útil y aporta información valiosa para predecir los precios del futuro, también permite la manipulación de otros. En un mundo en donde la información adecuada es lo más valioso, el acceso a las predicciones de un modelo certero es una promesa que puede generar grandes beneficios. Con esta promesa, empresas pueden convencer a inversores para utilizar su capital o incluso se pueden distribuir información conflictiva para mejorar tu posición competitiva. Cualquier información dada debe hacerse tan honestamente como sea posible. Además, en la mayor medida posible, se deben proporcionar las advertencias del riesgo que conlleva invertir en estos activos basándose únicamente en las predicciones del modelo. Es importante aportar toda la información disponible para que cada persona pueda tomar decisiones informadas. Siendo razonables, el modelo debería servir únicamente como herramienta para evaluar la salud de la comunidad de bitcoin y esta información puede permitir que los inversores tomen mejores decisiones disminuyendo su riesgo. Sin embargo, no entender los riesgos asociados con él o esconderlos de otros será perjudicial, incluida una pérdida significativa de riqueza.

7.2 Trabajo futuro

En esta sección se ofrecen mejoras que son necesarias para ampliar la literatura de esta cuestión. Se han identificado dos mejoras interesantes, la primera sería aplicar la teoría de grafos para establecer una ponderación del sentimiento de los usuarios basado en la influencia y la segunda sería realizar el estudio sobre múltiples plataformas de discusión y estudiar una masa más homogénea de actores del mercado, no solo a la comunidad anglosajona.

7.2.1 Aplicar teoría de grafos

Esta investigación observa que el sentimiento medio de los mensajes no tiene relación con los movimientos del precio, pero esta observación no significa que los movimientos del precio no se vean afectados por los sentimientos de los actores del mercado. En esta investigación se cuenta el sentimiento de todos los mensajes por igual y se establece la media de estos mensajes en una franja de tiempo de 1 hora. Esta es la forma mas simple

de analizar y agrupar el sentimiento medio de los mensajes, pero no es la más precisa. Parece evidente, pero es importante decir que no todos los actores de cualquier mercado tienen la misma influencia. De forma similar sucede en Twitter. No todos los mensajes tienen la misma influencia. La mayoría de los mensajes son compartidos con pocos usuarios, y algunos pocos mensajes son distribuidos a grandes redes de seguidores. Dentro de la rama de la teoría de grafos, investigadores estudian las relaciones entre complejas redes de usuarios identificando a aquellos usuarios que son más importantes o claves en la distribución de información. Como ejemplo, esta rama de investigación intenta responder a cuestiones como ¿Quién o quienes, dentro de la comunidad de bitcoin, puede distribuir información a la mayor parte del resto de la comunidad? Investigaciones futuras deberían hacer uso de la teoría de grafos para detectar aquellos actores que tienen más influencia y aumentar la ponderación del sentimiento de sus mensajes respecto a los demás actores del mercado.

7.2.2 Implementar un análisis polígloto y multiplataforma

Como se ha explicado en capítulos anteriores, el movimiento del precio de bitcoin viene dado por la expectativa de valor futuro de todos los actores del mercado. Bitcoin es un activo comercializado en todo el mundo y gran parte de los actores que influyen el precio de bitcoin interactúan en otros idiomas y en otras plataformas. Por ejemplo, uno de los países más inversores en criptomonedas es Corea del Sur. El análisis de sentimiento de varios lenguajes es complicado, pero sería importante que otras investigaciones incluyan en sus análisis datos y mensajes de algunos de los idiomas más importantes en la comunidad de bitcoin y de esta forma obtener una muestra de datos más homogénea que represente a todos los actores que participan en el comercio de Bitcoin. Para esto, será necesario encontrar nuevos programas capaces realizar el análisis de sentimiento.

Además de realizar un análisis de sentimiento en varios idiomas sería esencial analizar el sentimiento en más redes sociales. A parte de Twitter, otra de las plataformas más utilizadas por Europa y Estados Unidos para la discusión de criptomonedas es Reddit. Futuras investigaciones podrían implementar los mensajes compartidos en Reddit y en las plataformas más importantes asiáticas para obtener una visión global de la opinión de toda la comunidad de bitcoin. Como en el caso anterior, adquirir una muestra de datos más homogénea es esencial para obtener una mejor relación entre sentimiento y el precio.

7.3 Conclusión

En este artículo estudiamos la posibilidad de predecir el precio de Bitcoin únicamente a través de la información ofrecida públicamente en las redes sociales. La investigación se centra en la predicción de Bitcoin por la naturaleza digital del activo y por los intereses puramente financieros de los inversores. Y de entre todas las redes sociales el estudio se realiza sobre la plataforma de Twitter por la facilidad de descarga de la información y se analiza únicamente a la comunidad de Bitcoin de habla inglesa.

Con este objetivo, el artículo presenta el análisis de todos los mensajes sobre bitcoin publicados entre agosto de 2017 hasta enero de 2019 en Twitter. La investigación ha descargado un poco más de 17.737.519 de mensajes. Al contenido de los mensajes se ha realizado un análisis de sentimiento con VADER clasificando los mensajes entre positivos, negativos y neutros. Todos los datos se han agregado en una franja de tiempo horaria obteniendo el sentimiento medio y medidas de volumen de mensajes del periodo. La ponderación realizada valora el sentimiento de todos los mensajes por igual.

La investigación partía de la hipótesis de que el sentimiento de los actores del mercado sí tienen relación con los movimientos del precio de Bitcoin y que el volumen de los mensajes sería irrelevante. Otras investigaciones encontraron relaciones contradictorias entre el sentimiento de la comunidad de Bitcoin de Twitter y la fluctuación del precio de Bitcoin. Tras el análisis completo de los datos obtenidos observamos que el sentimiento medio expresado en los mensajes se mantiene positivo incluso cuando el valor de bitcoin cae, y con esto, confirmamos los resultados de la investigación de Jethin Abraham, D. H. (2018). También se observa que el volumen de los mensajes tiene una correlación alta y sólida durante todo el periodo, incluso cuando el precio cae.

También el artículo presenta un modelo predictivo realizado con *Machine learning* que obtiene resultados cercanos a los precios reales con errores medios razonables. Investigaciones futuras deberán hacer uso de la teoría de grafos para determinar una mejor ponderación del sentimiento medio y podrían ampliar la muestra del estudio a diferentes plataformas y diferentes idiomas para obtener datos más representativos de todos los actores que interactúan en la comunidad inversora de bitcoin.

6. Bibliografía

- Andranik Tumasjan, T. O. (2010). Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment . Munich, Germany: Technische Universität München .
- Ashok Deb, K. L. (14 de 04 de 2018). Predicting Cyber Events by Leveraging Hacker Sentiment. USC Information Sciences Institute.
- Aslam, S. (06 de 01 de 2019). *Omnicores*. Obtenido de <https://www.omnicoreagency.com/twitter-statistics/>
- Bitcoin. (s.f.). *Bitcoin- P2P Digital Currency*. Obtenido de <http://bitcoin.org>
- Bitcoin Foundation. (s.f.). *Bitcoin Foundation*. Obtenido de <https://bitcoinfoundation.org>
- Bitcoincharts*. (s.f.). Obtenido de www.bitcoincharts.com
- Castelló, J. S. (09 de 2015). Desarrollo de un sistema de análisis de sentimiento sobre Twitter. Universitat Politecnica de Valencia. Obtenido de <https://riunet.upv.es/bitstream/handle/10251/55471/SELVA%20-%20Desarrollo%20de%20un%20sistema%20de%20análisis%20de%20sentimiento%20sobre%20Twitter.pdf?sequence=1>
- Chong, Z. (14 de 03 de 2017). *Cnet*. Obtenido de <https://www.cnet.com/news/new-study-says-almost-15-percent-of-twitter-accounts-are-bots/>
- Coindesk*. (s.f.). Obtenido de <https://www.coindesk.com/bitcoin-venture-capital>
- Evita Stenqvist, J. L. (2017). Predicting bitcoin price fluctuation with Twitter sentiment analysis. Estocolmo, Suecia: Kth royal institute of technology.
- GetOldTweets*. (s.f.). Obtenido de <https://github.com/Jefferson-Henrique/GetOldTweets-python>
- Gilbert, C. H. (2013). VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text. Georgia Institute of Technology.
- Hany Mohamed, A. E. (14 de August de 2015). *The road to emotion mining in social network*. Helwan University - Department Of Computer Science.
- IBM*. (2013). Obtenido de <https://www.ibm.com/blogs/insights-on-business/consumer-products/2-5-quintillion-bytes-of-data-created-every-day-how-does-cpg-retail-manage-it/>
- Jethin Abraham, D. H. (2018). Cryptocurrency Price Prediction Using Tweet Volumes and Sentiment Analysis . SMU Data Science Review.
- Joshua A. Kroll, I. C. (2013). *The Economics of Bitcoin Mining or, Bitcoin in the Presence of Adversaries*. Princeton University.
- Keras*. (s.f.). Obtenido de <https://keras.io/>
- Matplotlib libreria de Python*. (s.f.). Obtenido de <https://matplotlib.org/>
- Numpy libreria de Python*. (s.f.). Obtenido de <https://www.numpy.org/>
- Pandas libreria de Python*. (s.f.). Obtenido de <https://pandas.pydata.org/>

Price, D. (05 de 12 de 2018). *Blocksdecoded*. Obtenido de <https://blocksdecoded.com/best-online-crypto-communities/>

SemanticScholar. (2019). Obtenido de <https://www.semanticscholar.org/paper/VADER%3A-A-Parsimonious-Rule-Based-Model-for-Analysis-Hutto-Gilbert/a6e4a2532510369b8f55c68f049ff11a892fefeb?tab=abstract&citingPapersSort=year&citingPapersLimit=10&citingPapersOffset=0&citedPapersSort=is-influential&>

Simon Barber, X. B. (2013). *Bitter to Better — How to Make Bitcoin a Better Currency*. Palo Alto research center.

Sklearn libreria de Python. (s.f.). Obtenido de <https://scikit-learn.org/>

Statista. (2017). Obtenido de <https://www.statista.com/statistics/278414/number-of-worldwide-social-network-users/>

Statista. (2019). Obtenido de <https://www.statista.com/statistics/617136/digital-population-worldwide/>

Statista. (Febrero de 2019). Obtenido de <https://www.statista.com/statistics/282087/number-of-monthly-active-twitter-users/>

Strachey, C. (1952). Logical or non-mathematical programmes. Toronto: in: Proc. Association for Computing Machinery Meeting.

Takeshi Sakaki, M. O. (02 de 11 de 2016). *Earthquake Shakes Twitter Users: Real-time Event Detection by Social Sensors*. Tokyo, Japan: The University of Tokyo.

Twitter Apis. (s.f.). Obtenido de <https://developer.twitter.com/en/docs.html>

VADER. (s.f.). Obtenido de <https://github.com/cjhutto/vaderSentiment>

Zantal-Wiener, A. (14 de 09 de 2018). *Hubspot*. Obtenido de <https://blog.hubspot.com/news-trends/two-thirds-americans-still-get-news-on-social-media>