

UNIVERSIDAD DE ALMERÍA
ESCUELA SUPERIOR DE INGENIERÍA

Analizador de tendencias de mercado

Curso 2020/2021

Alumno/a:

Alberto Morante Bailón

Director/es:

Antonio Leopoldo Corral Liria

A aquellos que lucharon por construir un futuro mejor para todo el mundo, gracias

Agradecimientos

Quisiera dedicar estas líneas a todos aquellos que han contribuido a que este trabajo sea posible, en primer lugar, a mis amigos, en especial a Daniel, que ha hecho mucho más ameno este proyecto y en general este duro periodo de crisis. También a Miguel Ángel, por haber contribuido a esos ratos de ocio y a mitigar el estrés que me generaba la realización de este trabajo.

También a mi familia, a mis padres Alberto y Victoria, porque me inculcaron los valores y la educación necesarios para afrontar este trabajo y a mi hermana Laura por haber escuchado mis problemas y haberme dado ánimos cuando más lo necesitaba.

No me olvido de mi mujer, Cyril, que siempre me ha hablado de no rendirme y me ha animado a seguir hacia delante sin importar lo duros que sean los momentos que estamos viviendo, porque todo lo malo tiene un final, y esperanzas para que ese final sea bueno.

Además, doy las gracias a aquellos docentes que me han acompañado a lo largo de este duro periodo, y con los cuales he compartido momentos de alegría, de tristeza y han contribuido a la consecución de cada uno de los objetivos que se han propuesto, principalmente a mi tutor, Antonio Corral, y a los miembros del presente tribunal: Antonio Becerra, Juan Sanjuan, José Joaquín Martínez e Irene Martínez, y aunque no forme parte del tribunal, quiero agradecer a Manuel Torres por su gran labor como docente y por ser una gran persona.

Prólogo

La globalización, así como el uso de las tecnologías, han propiciado el aumento del número de inversores y operadores de activos (principalmente acciones, contratos futuros y divisas). Gracias a las tecnologías de la información, existen cada vez más productos financieros disponibles, y ha hecho que la información relativa a los activos se pueda presentar en un formato más legible, y visualmente amigable, como los gráficos de velas japonesas, en los cuales se pueden representar de manera sencilla varios indicadores técnicos como las medias móviles, permitiendo detectar tendencias de mercado.

El presente Trabajo Fin de Máster (TFM) está centrado en el ámbito de las APIs (Application Programming Interface) encargadas de ofrecer soporte a través de indicadores técnicos para operar en el mercado.

La API implementada en este TFM permite que cualquier operador de bolsa analice las tendencias de mercado (tanto alcistas como bajistas) haciendo uso de estrategias diseñadas para operar en base a indicadores técnicos muy utilizados, como las medias móviles.

Además, se propone un nuevo indicador que se basa en las emociones generadas por las noticias que se emiten diariamente, y permite al operador de activos conocer si en un momento dado se puede comprar o vender un activo basándose en las emociones generadas por estas noticias.

Índice general

Capítulo 1. Introducción.....	15
1.1. Objetivos.....	17
1.2. Fases de realización y cronograma asociado.....	18
1.3. Materiales y métodos utilizados.....	21
1.4. Estructura de la memoria.....	22
Capítulo 2. El mercado financiero.....	23
2.1. Elementos.....	23
2.1.1. Entidades.....	23
2.1.2. Instrumentos financieros.....	24
2.1.3. Organizaciones.....	25
2.2. Antecedentes.....	26
2.3. Estado del arte en las tecnologías de mercado.....	27
Capítulo 3. Análisis técnico y las emociones en el mercado.....	31
3.1. Las velas japonesas.....	35
3.1.1. Elementos de las velas japonesas.....	35
3.1.2. Otros tipos de gráficos.....	37
3.1.3. Información adicional de las velas japonesas.....	39
3.1.4. Desventajas.....	41
3.2. Las medias móviles.....	42
3.2.1. Combinación de dos medias móviles.....	44
3.2.2. Combinación de tres medias móviles.....	46
3.3. Emociones en el mercado.....	48
Capítulo 4. Diseño.....	53
4.1. Diseño general de la API.....	53
4.2. Aplicación web.....	60
Capítulo 5. Experimentación y resultados.....	61
5.1. Experimento basado en estrategias de posición de precios y medias móviles.....	69
5.2. Experimento basado en estrategias de tres medias móviles.....	71
5.3. Experimento basado en emociones surgidas de noticias.....	73
5.4. Resultados.....	75
Capítulo 6. Conclusiones y trabajo futuro.....	85
6.1. Conclusiones.....	85

6.2. Ampliaciones futuras.....	85
Bibliografía.....	87
Glosario de términos.....	89
Anexo I. Diagrama de clases de microservicio NewsEmotions.	90
Anexo II. Diagrama de clases de microservicio MarketEmotions.	91

Índice de figuras

Figura 1-1. Número total de compañías listadas. Fuente: [5].....	15
Figura 1-2. Patrón alcista (Marubozu). Fuente: [10].....	16
Figura 1-3. Esquema general.....	17
Figura 1-4. Medias móviles.....	19
Figura 1-5. Cronograma.....	20
Figura 1-6. Infraestructura del proyecto.....	21
Figura 2-1. Visión general de instrumentos del mercado. Fuente [20].....	24
Figura 3-1. Cambio de dirección del mercado.....	32
Figura 3-2. Continuación del precio en la misma dirección.....	32
Figura 3-3. Precio de S&P 500 de 2000 a 2003.....	34
Figura 3-4. Componentes de las velas japonesas.....	35
Figura 3-5. Comparativa entre una barra y una vela.....	36
Figura 3-6. Gráfico de líneas.....	38
Figura 3-7. Gráfico de barras.....	38
Figura 3-8. Volumen.....	40
Figura 3-9. Ejemplo de tendencia alcista.....	42
Figura 3-10. Comparativa entre medias móviles de 20 y 200 periodos.....	43
Figura 3-11. Ejemplo de combinación de dos medias móviles.....	45
Figura 3-12. Ejemplo de tres medias móviles combinadas.....	47
Figura 3-13. Ejemplo de alta volatilidad.....	48
Figura 3-14. Proceso de análisis de noticias en el mercado.....	52
Figura 4-1. Esquema general de microservicio NewsEmotions.....	53
Figura 4-2. Esquema general de microservicio MarketEmotions.....	55
Figura 4-3. Esquema de red de Openstack.....	57
Figura 4-4. Fichero docker-compose.yml.....	59
Figura 4-5. Ventana de activos.....	60
Figura 4-6. Ventana de análisis de tendencias.....	60
Figura 5-1. Estados del análisis predictivo.....	61
Figura 5-2. Proceso de aprendizaje automático supervisado.....	63
Figura 5-3. Esquema de Azure ML Studio. Fuente: [8].....	63
Figura 5-4. Esquema de experimento en Azure ML Studio.....	65
Figura 5-5. Ejemplo de árbol de decisión.....	66
Figura 5-6. Ejemplo de red neuronal.....	66
Figura 5-7. Proceso de selección de algoritmo de entrenamiento.....	68
Figura 5-8. Análisis de tendencias de Walmart en 2019.....	77
Figura 5-9. Análisis de tendencias de Walmart en 2020.....	78
Figura 5-10. Análisis de tendencias de Google en 2019.....	79
Figura 5-11. Análisis de tendencias de Google en 2020.....	80
Figura 5-12. Análisis de tendencias de Disney en 2019.....	81
Figura 5-13. Análisis de tendencias de Disney en 2020.....	82
Figura 5-14. Ganancia por operación realizada en 2019.....	83
Figura 5-15. Ganancia total anual por activo.....	83

Índice de tablas

Tabla 1-1. Temporización.	20
Tabla 2-1. Bolsas globales y volumen de operaciones. Fuente [3]	26
Tabla 3-1. Recuperación de pérdidas.	34
Tabla 3-2. Gráfico de figuras y puntos.....	39
Tabla 3-3. Cálculo de media móvil de cinco periodos.	43
Tabla 5-1. Ejemplo de árbol de decisión.	66
Tabla 5-2. Comparativa de algoritmos de Azure Machine Learning.	68
Tabla 5-3. Resultados utilizando algoritmo Árbol de Decisión Ampliado de Dos Clases.	70
Tabla 5-4. Resultados utilizando algoritmo Bosque de Decisión de Dos Clases	70
Tabla 5-5. Resultados utilizando algoritmo Red Neuronal de Dos Clases.....	70
Tabla 5-6. Matriz de decisión usando algoritmo Árbol de Decisión Ampliado Multiclase.....	72
Tabla 5-7. Matriz de decisión usando algoritmo Bosque de Decisión Multiclase.....	72
Tabla 5-8. Matriz de decisión usando algoritmo Red Neuronal Multiclase	72
Tabla 5-9. Matriz de decisión usando algoritmo Árbol de Decisión Ampliado Multiclase.....	74
Tabla 5-10. Matriz de decisión usando algoritmo Bosque de Decisión Multiclase.....	74
Tabla 5-11. Matriz de decisión usando algoritmo Red Neuronal Multiclase.	74
Tabla 5-12. Comparativa de precisión en cada estrategia utilizada.....	75
Tabla 5-13. Ganancia de Walmart en 2019 aplicando cada estrategia.....	76
Tabla 5-14. Ganancia de Walmart en 2020 aplicando cada estrategia.....	76
Tabla 5-15. Ganancia de Google en 2019 aplicando cada estrategia.	78
Tabla 5-16. Ganancia de Google en 2020 aplicando cada estrategia.	79
Tabla 5-17. Ganancia de Disney en 2019 aplicando cada estrategia.	80
Tabla 5-18. Ganancia de Disney en 2020 aplicando cada estrategia.	81

Capítulo 1. Introducción.

Debido a fenómenos como la globalización, o el tratado de Maastricht, el cual hizo posible la formación de la Unión Europea, se produjo un incremento del número de activos que se podían operar en todo el mundo.

La Figura 1-1 representa el número total de compañías listadas desde agosto de 1998 hasta 2009 [5], en la que desde 2001 tanto Europa como el resto del mundo, excepto Estados Unidos, han sufrido un aumento del número de compañías listadas para ser operables por cualquier inversor. En el caso de Europa la incorporación del Euro, una divisa común para todos los países de la Unión Europea, jugó un papel fundamental en dicho aumento.

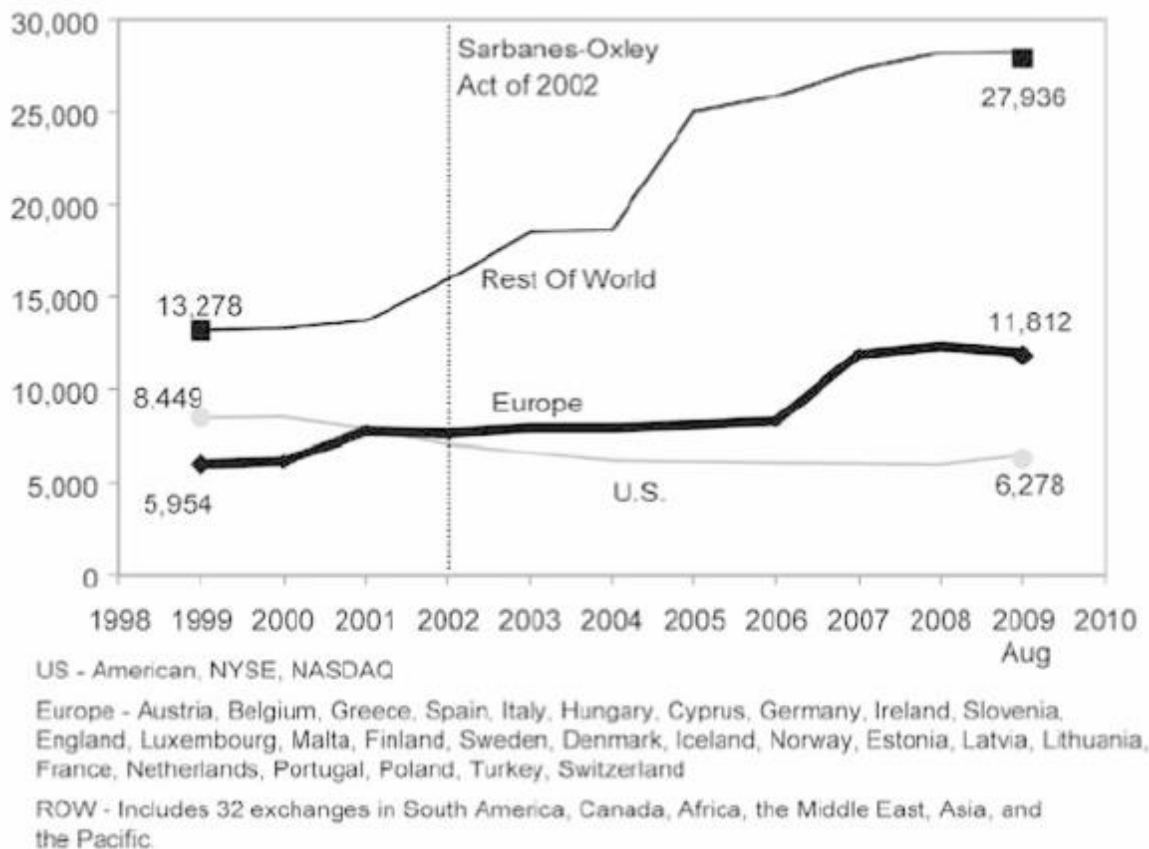


Figura 1-1. Número total de compañías listadas. Fuente: [5]

La gran cantidad de activos disponibles hizo que a mediados de los años 90 el número de operaciones financieras ejecutadas se disparase, siendo necesario el uso de las tecnologías para el proceso de una cantidad ingente de transacciones, y pasando de los informes en papel a informes en ordenador. La evolución de los estas tecnologías también hizo posible la detección de patrones en los precios, como el patrón de compra mostrado en la Figura 1-2 a través de una vela japonesa, y la aplicación de aprendizaje automático (Machine Learning) al mercado financiero, ya que el mercado se basa en tendencias, que pueden ser alcistas, neutrales, o bajistas.

1. Introducción.



Figura 1-2. Patrón alcista (Marubozu). Fuente: [10]

Este trabajo se enfoca en el diseño de una API para detectar tendencias alcistas, neutrales o bajistas basándose en estrategias de análisis técnico de mercado, como la estrategia de tres medias móviles y en emociones surgidas de noticias. Esta API a su vez utiliza un motor de predicciones, que consume tres modelos de predicción desarrollados y desplegados como servicios web en Azure Machine Learning.

El motor de predicciones se trata de un mecanismo para saber cómo se comporta el mercado en base a ciertos parámetros. Los motores de predicciones se basan en resultados pasados para poder predecir el futuro. En el caso particular de este proyecto se basa en los datos recogidos de emociones surgidas de noticias sobre un activo y en los datos surgidos de aplicar una estrategia basada en tres medias móviles (la media de 20, de 50 y de 200 periodos) [14] durante un periodo de tiempo.

Con el objetivo de saber si aplicando el motor de predicciones se habría obtenido una pérdida o una ganancia, se implementará la API para analizar tendencias, que da como resultado la ganancia o pérdida que se habría obtenido en aquellas tendencias detectadas de un activo en particular entre dos fechas dadas y habiendo aplicado las estrategias mencionadas.

la Figura 1-3 muestra un esquema general del proyecto realizado, las APIs de emociones y la de mercado servirán como entrada de datos de varios experimentos realizados con Azure Machine Learning, que permitirán generar modelos de predicción desplegados como servicios web que utilizará la API de análisis de tendencias de mercado.

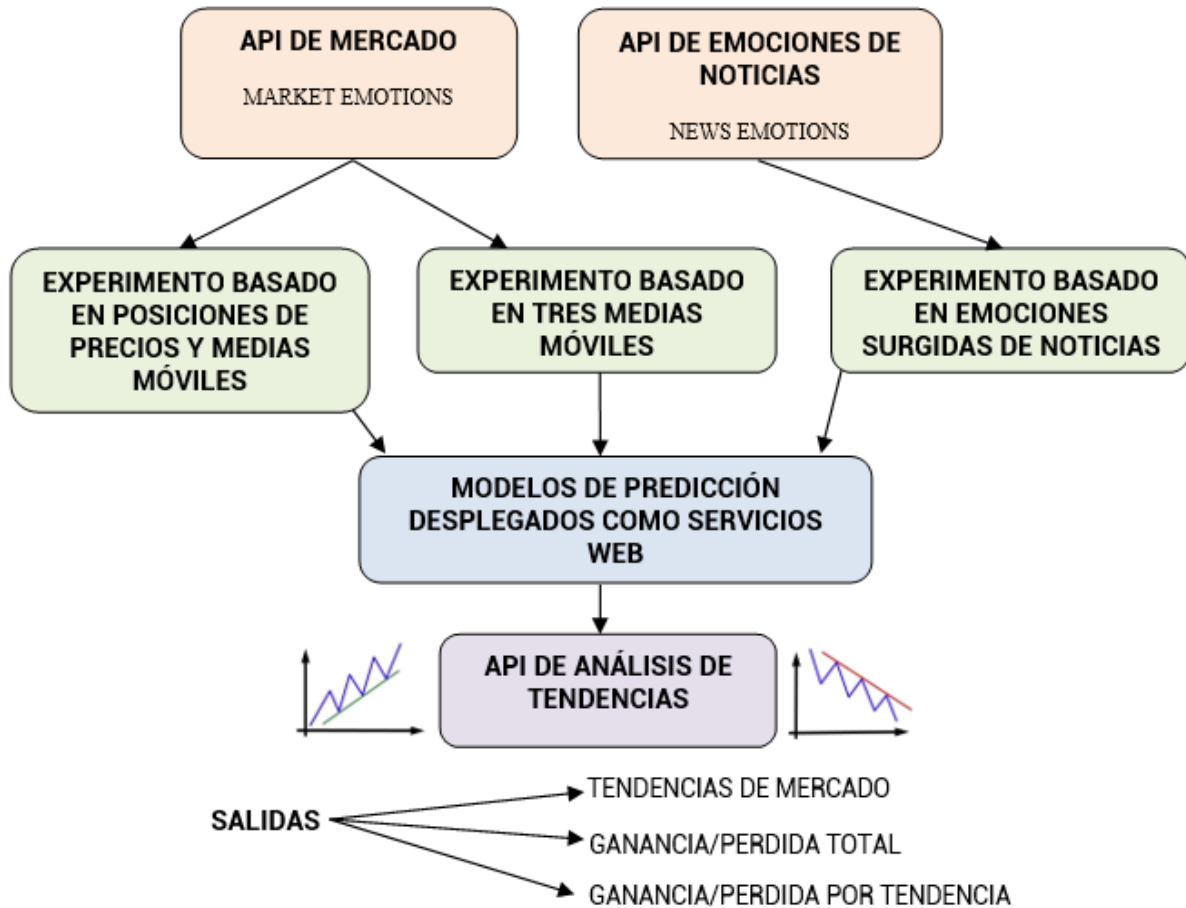


Figura 1-3. Esquema general.

1.1. Objetivos.

Los objetivos principales de este TFM son los siguientes:

- Dar soporte a un usuario que opere en el mercado financiero para que pueda tomar mejores decisiones basándose en otro parámetro más aparte de los indicadores técnicos ya conocidos actualmente (medias móviles, MACD, RSI...). Este parámetro es un conjunto de emociones (positivas o negativas) que surgen de noticias, y estas emociones tienen un efecto directo sobre el comportamiento del mercado.
- Saber más acerca de cómo influyen las emociones en el mercado financiero [6].
- Analizar tendencias en un momento histórico determinado para poder saber por qué ocurren ciertos momentos de compra y venta.
- Saber si se puede automatizar el proceso de realización de operaciones en bolsa basándose también en las emociones surgidas de noticias sobre el mercado.
- Proporcionar al usuario una manera de minimizar los riesgos de realizar operaciones en bolsa en base a estrategias basadas en medias móviles y emociones surgidas de noticias.
- Conocer la ganancia o la pérdida que se habría obtenido en el pasado si se hubiese aplicado cualquiera de las estrategias que se plantean: basada en emociones, basada en medias móviles o basada en ambas.

1.2. Fases de realización y cronograma asociado.

Este TFM se estructura en las siguientes fases de desarrollo, habiendo estimado la siguiente temporización de cada parte:

1. Investigación de APIs y testeo. Preparación del entorno de trabajo: 12 días (60 h).

En esta etapa se ha realizado una investigación exhaustiva de APIs que permitan obtener emociones de noticias relacionadas con cierto activo (por ejemplo, las emociones surgidas de noticias de la compañía Apple). Después, con el objetivo de asociar las emociones resultantes de la API anterior con el comportamiento del mercado, se han investigado APIs que permitan obtener los precios de mercado en forma de velas japonesas [11], las cuales permiten representar el comportamiento del mercado de forma más legible, y las medias móviles de 20, 50 y 200 periodos asociadas a estas velas.

Para obtener las emociones de noticias se ha elegido la API StockNews [16], que ofrece las emociones asociadas a las noticias de los dos últimos años de un activo en concreto. Los datos sobre el comportamiento de los precios de mercado se han obtenido de la API Alphavantage [1], que es de uso gratuito y permite obtener resultados de un activo en particular de los últimos veinte años.

También se incluye la recopilación bibliográfica y la preparación del entorno de desarrollo, el cual incluye: la creación de máquinas virtuales en Openstack, con objeto de albergar los microservicios desarrollados; la instalación de las herramientas Jenkins y Sonar para el despliegue automático de los microservicios y la medición de la calidad del código; la configuración inicial de Spring Tool Suite y la preparación de un servidor de configuraciones Spring Cloud Config [15].

2. Desarrollo de API (llamada *newsemotions*) para obtención de emociones a partir de noticias: 2 días (20 h)

Se ha implementado una API [19], la cual calcula una puntuación por día según las emociones obtenidas de la API StockNewsAPI [16], cada una de estas emociones puede ser positiva, negativa o neutral, y se utilizarán para asociarlas posteriormente al comportamiento del mercado.

3. Creación de API para asociar el comportamiento del mercado al resultado devuelto por la API *newsemotions*: 7 días (40 h)

En esta fase se ha implementado una API (llamada *marketemotions*) que permite asociar las emociones obtenidas de la API *newsemotions* con el comportamiento que ha tenido el mercado en ese periodo de tiempo, según la subida y bajada de precios y la posición de las medias móviles [14] en un día determinado.

4. Entrenamiento de datos a través de Azure Machine Learning y despliegue de modelos de predicción: 23 días (100 h)

En esta fase se han creado tres experimentos distintos a través de Azure Machine Learning con el objetivo de entrenar y desplegar tres modelos como servicios web que sirven para predecir un comportamiento del mercado (compra, venta o neutral) según una estrategia.

En el primero de ellos se ha entrenado un modelo el cual utiliza como descriptores las posiciones de las medias móviles y las posiciones de los precios de cierre con respecto a las posiciones de las medias móviles, que son unos indicadores muy utilizados en el mercado. La variable a predecir es la subida o bajada de los precios con respecto al día anterior. La Figura 1-4 muestra un ejemplo de las medias móviles (Moving Average, M.A) más utilizadas en un gráfico de velas japonesas.




Figura 1-4. Medias móviles

En el segundo experimento se ha entrenado un modelo que se basa en una estrategia en la cual solo se predicen los momentos de compra o venta en el momento en que las medias móviles se encuentran en una posición concreta, y que aumenta las probabilidades de éxito al comprar o vender un activo. No se utiliza la posición del precio respecto a las posiciones de las medias móviles, la cual se utilizaba en el experimento anterior.

El tercer experimento consiste en entrenar un modelo utilizando como descriptores una serie de emociones obtenidas de noticias, de manera diaria, con el objetivo de conocer si es posible predecir momentos de compra o venta en base a estas emociones surgidas de las noticias de activos.

Una vez entrenados los modelos se han desplegado como servicios web en Azure.

5. Desarrollo de API para analizar tendencias de mercado: 11 días (60 h)

Después de la fase de entrenamiento de datos, se ha desarrollado una API la cual utiliza los endpoints desplegados en la fase anterior para detectar tendencias de compra, venta o neutrales de un activo en particular entre dos fechas. También permite conocer la ganancia o pérdida que se habría obtenido si se hubiese intentado predecir el comportamiento del mercado a través de las predicciones creadas.

1. Introducción.

6. Difusión del TFM: 12 días (70 h)

Selección de distintas alternativas que permiten dar a conocer esta librería por Internet, por ejemplo, diseño de página web, comentarios en foros y difusión en portales especializados. Además, se publica en la web de GitHub tanto el código libre como la ayuda en español e inglés, para su correcta utilización. En este apartado, también se incluye la redacción de la memoria del TFM y la elaboración de presentaciones y videos para la defensa del TFM.

7. Elaboración de aplicación web: 19 días (76 h)

Finalmente, la planificación temporal ha quedado de la siguiente manera, en la Tabla 1-1 se muestra la temporización y en la Figura 1-5 se muestra el cronograma asociado.

Nombre	Duración	Fecha de inicio	Fecha de fin
1. Investigación de APIs. Preparación de entorno.	12 días. 60 h.	vie 02/10/20	dom 18/10/20
2. Desarrollo de API para obtención de emociones a partir de noticias, llamada <i>newsemotions</i> .	2 días. 20 h.	vie 23/10/20	dom 25/10/20
3. Creación de API para asociar el comportamiento del mercado con las emociones de noticias.	7 días. 40 h.	vie 30/10/20	dom 08/11/20
4. Entrenamiento de datos. Creación de motor de predicciones.	23 días. 100 h.	vie 13/11/20	mar 15/12/20
5. Desarrollo de API de análisis de tendencias de mercado.	11 días. 60 h.	mie 16/12/20	mie 30/12/20
6. Difusión del TFM.	12 días. 70 h.	mar 31/12/20	vie 15/01/21
7. Elaboración de una aplicación web.	19 días. 76 h.	sab 16/01/21	mie 10/02/21

Tabla 1-1. Temporización.

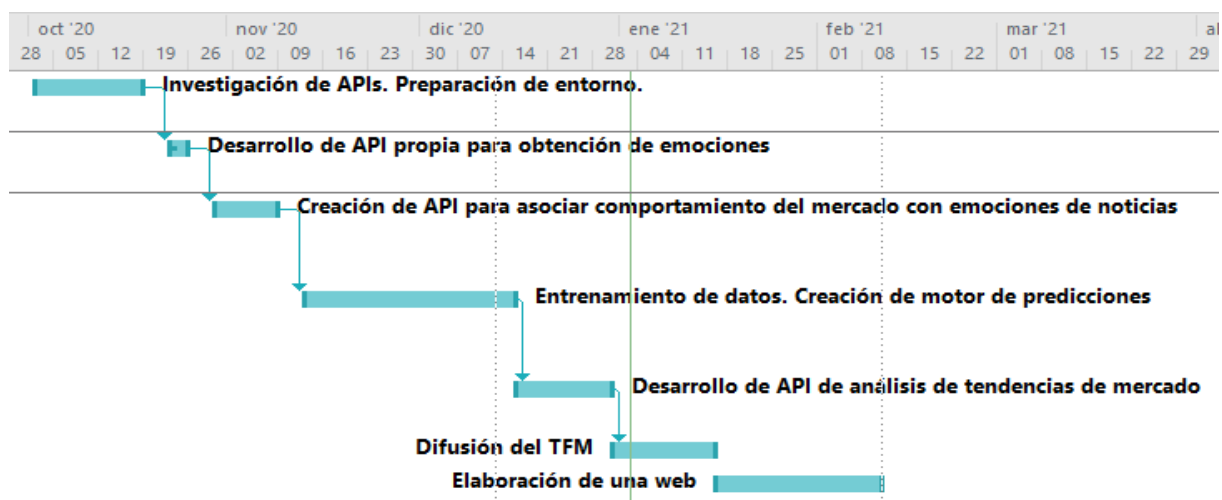


Figura 1-5. Cronograma.

El número total de horas invertidas en la realización de este TFM ha sido de 426, habiendo estimado 300 horas en el anteproyecto, el tiempo real dedicado al proyecto ha excedido en 126 horas, las cuales se han invertido en el entrenamiento de datos en Azure Machine Learning y en el desarrollo de la aplicación web.

1.3. Materiales y métodos utilizados.

Para realizar el desarrollo de la API se ha utilizado el lenguaje Java, con el apoyo de Spring Framework, dividiendo las distintas partes del proyecto en dos microservicios llamados *newsemotions* y *marketemotions*.

Estos microservicios se han desplegado en máquinas virtuales (MVs) de Openstack, en forma de contenedores Docker, y se han creado varias tareas en Jenkins para el despliegue automático de los microservicios. Dentro de cada tarea, al ejecutar el comando *mvn clean install* se ejecuta un plugin que monta una imagen de Docker del microservicio y la sube al repositorio DockerHub, después, en el servidor (las máquinas virtuales de Openstack) se baja dicha imagen actualizada y se ejecuta el contenedor. La Figura 1-6 muestra un esquema de la infraestructura del proyecto.

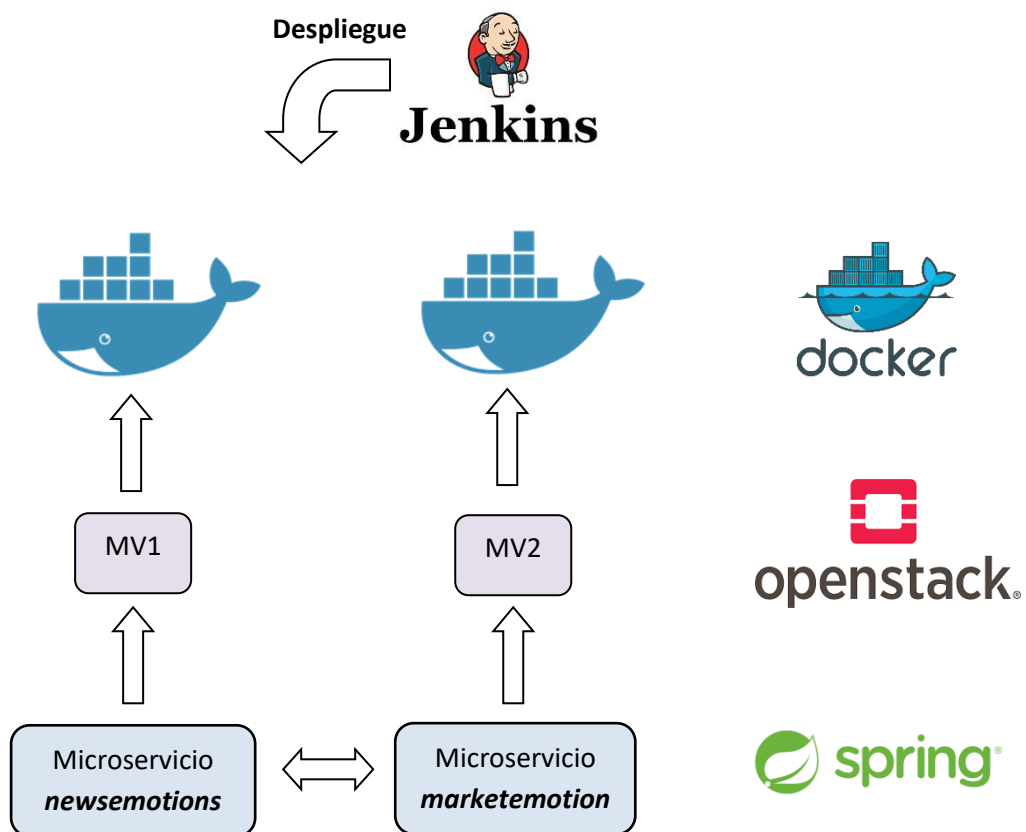


Figura 1-6. Infraestructura del proyecto.

1.4. Estructura de la memoria.

La presente memoria se ha estructurado en seis capítulos, de tal forma que permitan ilustrar las distintas etapas del TFM realizado:

- En el presente capítulo se ha realizado una introducción sobre el trabajo, los objetivos que se pretenden alcanzar y la motivación que ha llevado a su realización.
- El capítulo 2 ofrece una base en la que se explica en qué consisten los mercados financieros y las distintas partes que lo componen.
- En el capítulo 3 se realiza una introducción a los gráficos de velas japonesas y a las medias móviles, ambos procedentes del análisis técnico de los mercados. También se realiza una explicación acerca de cómo influyen las emociones en el comportamiento del mercado, que entra dentro del ámbito de la psicología.
- El capítulo 4 se centra en el diseño de la API de análisis de tendencias de mercado, explicando cómo se ha realizado la implementación de la API y mostrando la aplicación web asociada.
- En el capítulo 5 se exponen los resultados obtenidos al ejecutar la API de análisis de tendencias de mercado, comparando las distintas estrategias y activos de distinta naturaleza. Por ejemplo, activos relacionados con distintos sectores, como el sector de las tecnologías de la información y el sector de la medicina.
- Por último, en el capítulo 6 se exponen las conclusiones obtenidas durante el desarrollo del proyecto y plantea el trabajo futuro.
- En las últimas páginas de la memoria se pueden encontrar las referencias bibliográficas y un glosario de los términos a los que se ha hecho referencia en los distintos capítulos.

Capítulo 2. El mercado financiero.

Este capítulo pretende explicar cómo están compuestos los mercados, describiendo las entidades que participan en estos y la variedad de activos que se pueden operar en ellos. Además, se da una breve explicación sobre los mercados globales, la gestión del riesgo y la regulación. Finalmente, se explica el origen de las bolsas y los cambios más actuales que han sufrido los mercados relativos a las tecnologías.

2.1. Elementos.

En la mayoría de los mercados, las entidades que operan los instrumentos financieros son organizaciones comerciales altamente reguladas, así como individuos que deben presentar los documentos necesarios para estar registrados y evitar, entre otras, penas por blanqueo de capitales, ya que en muchos brokers electrónicos se ha dado esta práctica.

2.1.1. Entidades.

Las principales entidades que componen el mercado son:

- Los compradores, que utilizan los servicios de los vendedores para operar instrumentos financieros, con el objetivo de obtener un beneficio a través de las operaciones con activos.
- Los vendedores, están principalmente compuestos por brokers y negociadores. Los negociadores actúan en beneficio propio, pero los brokers o bancos de inversiones tienen dos objetivos principales. El primero de ellos es ayudar a las empresas y a los gobiernos a recaudar dinero para financiar sus operaciones emitiendo nuevos activos. Y el segundo objetivo es ayudar a los clientes a operar activos que ya han sido emitidos. El bróker nunca debe beneficiarse conociendo de antemano la intención de un cliente y siempre debe estar de parte de éste.
- Los mercados son lugares en los que los activos financieros pueden ser operados por aquellos individuos que los poseen, y que desean venderlos a compradores que quieren obtener estos instrumentos, estos pueden ser lugares físicos o electrónicos. Los mercados han sido regulados a lo largo del tiempo por instituciones y también por los propios gobiernos. Los ingresos de estas instituciones provienen de varias fuentes, entre ellas los datos de mercado, la tecnología y el trading.
- Existe también una serie de entidades que dan soporte al mercado de valores, como las compañías de compensación, que aseguran la transacción desde que se realiza la operación hasta que los fondos son formalmente intercambiados en las bolsas de valores. En Estados Unidos existen solamente tres compañías de compensación: una para capitales, otra para contratos futuros y otra para opciones. Los bancos forman parte de estas entidades, ya que contribuyen a gestionar inversiones y poseen brokers

2. El mercado financiero.

subsidiarios, como por ejemplo el banco Santander, que tiene su propio bróker electrónico como servicio.

2.1.2. Instrumentos financieros.

Los instrumentos de mercado son aquellos productos que se intercambian en los mercados, y se dividen en tres categorías: efectivo, derivados e instrumentos empaquetados.

La característica principal del instrumento efectivo es que el inversor lo compra y lo posee, dentro de esta categoría se encuentran las divisas, las acciones de una compañía y los recursos.

Los instrumentos derivados son contratos estandarizados, y derivan su valor del valor de otro instrumento o activo. El contrato obliga a un participante a llevar a cabo determinadas acciones que se definen en el propio contrato.

Los instrumentos empaquetados permiten a los inversores participar en portafolios diversificados de instrumentos sin tener que comprar directamente un activo, estos pueden ser, por ejemplo, fondos mutuos. También permiten al inversor diversificar la inversión de capital en diversos activos.

La Figura 2-1 muestra una visión general de los instrumentos de mercado disponibles.

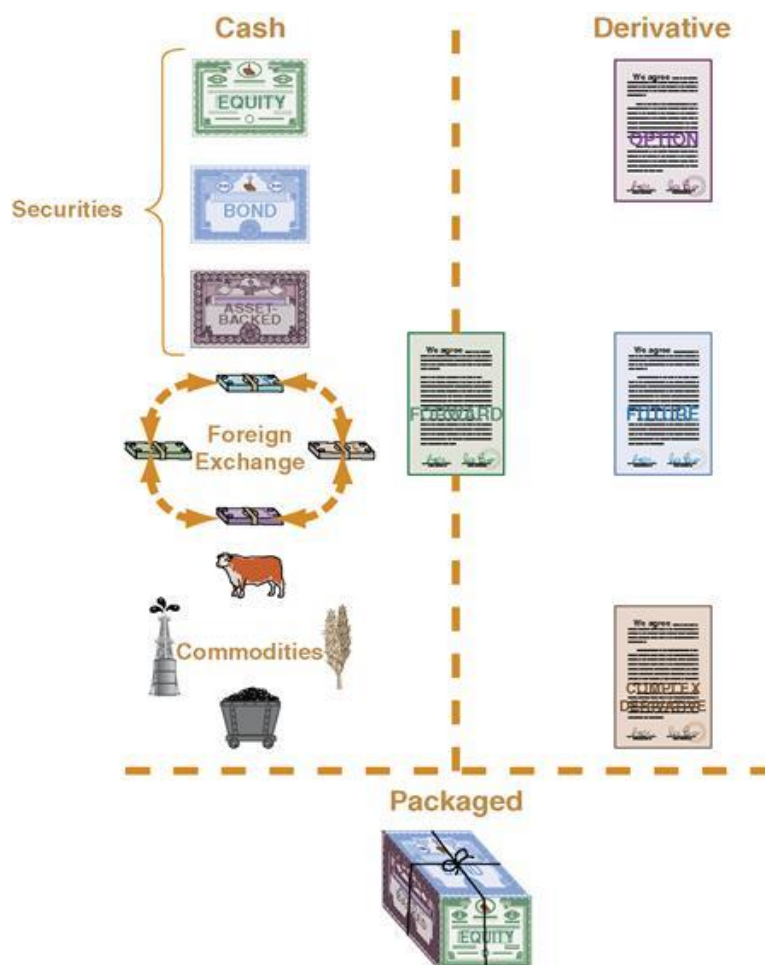


Figura 2-1. Visión general de instrumentos del mercado. Fuente [20].

2.1.3. Organizaciones.

Los valores se operan en organizaciones altamente reguladas llamadas bolsas de valores, o en brokers electrónicos, llamados también mercados extrabursátiles (en inglés, over-the-counter, OTC markets), que son mercados más descentralizados que las bolsas y menos regulados.

Una bolsa es un lugar de mercado centralizado donde los compradores y vendedores compiten por la oferta más baja y la demanda más alta, respectivamente.

Anteriormente las compañías operaban principalmente en la bolsa de Nueva York (NYSE) o en mercados OTC como el NASDAQ. En NYSE, un solo especialista intermediaba las transacciones de un solo activo, el especialista recibía órdenes de compra y venta por medio de un bróker y registraba las ordenes límites en un libro. Estas órdenes eran ejecutadas con una prioridad basada en el tiempo y el precio.

En el NASDAQ, múltiples creadores de mercado, que son especialistas, facilitaban la fluidez de las transacciones. El NASDAQ es un índice, que sirve para medir varias compañías, algunas de ellas incluidas dentro del sector de la tecnología, como Google o Microsoft.

Hoy en día, el trading se ha fragmentado, y en vez de dos lugares principales en los Estados Unidos, hay más de treinta lugares para operar, incluidas las bolsas y otros sistemas de trading sin regular (ATs) como redes electrónicas de comunicación.

La Tabla 2-1 muestra algunas de las bolsas más grandes del mundo y el volumen de operaciones para un año, terminando en marzo de 2018.

Exchange	Stocks				
	Market cap (USD mn)	Listed companies	Volume / day (USD mn)	Shares/day	Options/day
NYSE	23,138,626	2,294	78,410	6,122	1,546
Nasdaq — US	10,375,718	2,968	65,026	7,131	2,609
Japan Exchange Group Inc.	6,287,739	3,618	28,397	3,361	1
Shanghai Stock Exchange	5,022,691	1,421	34,736	9,801	
Euronext	4,649,073	1,240	9,410	836	304
Hong Kong Exchanges and Clearing	4,443,082	2,186	12,031	1,174	516
LSE Group	3,986,413	2,622	10,398	1,011	
Shenzhen Stock Exchange	3,547,312	2,110	40,244	14,443	

2. El mercado financiero.

Deutsche Boerse AG	2,339,092	506	7,825	475	
BSE India Limited	2,298,179	5,439	602	1,105	
National Stock Exchange of India Limited	2,273,286	1,952	5,092	10,355	

Tabla 2-1. Bolsas globales y volumen de operaciones. Fuente [3]

Los sistemas de trading mencionados anteriormente incluyen docenas de fondos sin regular que permiten a operadores realizar ejecuciones de forma anónima. Se estima que un 40% de todas las operaciones que se realizaron en Estados Unidos en el año 2017 eran anónimas [3]. Aunque no están totalmente sin regular, ya que estos fondos están obligados a informar de sus operaciones a la Autoridad Regulatoria de la Industria Financiera (Financial Industry Regulatory Authority, FINRA) después de que las transacciones hayan ocurrido.

2.2. Antecedentes.

En este apartado se ofrece una base acerca de cómo evolucionaron los mercados de valores [21].

En el pasado, se operaba con bienes básicos, pero la gama de productos financieros disponibles se ha ampliado recientemente. El primer mercado de intercambios comenzó en la ciudad de Bruges, en lo que ahora es Bélgica. El intercambio tomó lugar en una taberna cuyos propietarios eran una familia que se apellidaba Van Der Bourse.

En aquel entonces era necesario un lugar físico para que los comerciantes pudieran consultar el valor actual o precio del mercado para los activos que estaban comprando o vendiendo.

La Compañía Neerlandesa de las Indias Orientales fundó la primera bolsa en 1602. En primer lugar, los inversores invertían en expediciones individuales, si la expedición salía bien se les pagaba con una parte proporcional a su inversión, pero si la nave era robada, se perdía o era vendida por menos del coste de la expedición, los inversores perdían todo el dinero. Por tanto, la compañía solicitó la inversión en la propia empresa en vez de en expediciones individuales.

De esta manera nacieron las acciones, que consistían en inversiones de propiedad. Si un inversor quería vender su parte de la propiedad tenía que encontrar a alguien dispuesto a comprar ese activo para que el inversor estuviese libre de ese activo. Por tanto, la bolsa de Ámsterdam se convirtió en el primer lugar que se dedicó exclusivamente a que los vendedores de activos pudieran establecer sus precios y encontrar compradores.

Londres copió rápidamente la estructura de la Bolsa Neerlandesa y la práctica de operar acciones, primero se operaba en bares y en la calle, y más tarde se formó la Bolsa de Londres. Otras ciudades europeas copiaron esta práctica. En Estados Unidos, Filadelfia creó la primera bolsa, seguida un año después por Nueva York, pero el intercambio ya había existido en tabernas algún tiempo antes de las

bolsas se formasen. En Asia, todavía gobernada por el colonialismo, no se formaron estas estructuras económicas hasta más tarde.

El intercambio de valores continuó hasta mediados de 1800. Uno de los grandes hitos para la industria fue la creación del símbolo para reportar precios para el oro y capitales. El único atributo importante del símbolo era la capacidad de imprimir precios de acciones en una cinta de papel en dispositivos remotos. Las bolsas comenzaron a vender estos dispositivos de impresión, creando el negocio de datos de mercado. El símbolo permite identificar unívocamente cada uno de los activos.

En 1950, el creciente uso de los ordenadores creó oportunidades para automatizar el procesamiento de activos. Al mismo tiempo, un pequeño grupo de especialistas desarrollaron tecnología que permitió transmitir precios de activos a demanda. Los símbolos de activos, como los que ofrecían las bolsas. Con la llegada de los ordenadores un operador podía consultar el último precio de un símbolo en particular, y proveedores de datos de mercado independientes ofrecían los precios de varias bolsas al mismo tiempo. Como consecuencia, los precios se empezaron a mostrar en tiempo real [20].

El aumento del volumen de operaciones casi trajo el colapso del mercado de activos en Estados Unidos en los años 60, ya que esta enorme cantidad de operaciones sobrepasó la capacidad de los sistemas manuales de operaciones. Esto ocurrió en mitad de un periodo de mercado alcista, con compañías realizando un número elevado de operaciones. Varias de estas compañías quebraron y otras fueron forzadas a fusionarse con compañías más fuertes.

A finales de los años 70 los mercados de activos de Estados Unidos crecieron más fuertes, y Reino Unido revisó sus mercados bajo la recomendación del primer ministro Harold Wilson, que recomendó cambios similares a los de Estados Unidos.

Los cambios más significativos llegaron con la caída de la Unión Soviética y el rápido desarrollo de la economía de Asia. Estos dos eventos resultaron en un rápido crecimiento de los mercados de activos en todas las economías, con todas ellas teniendo mercados de importancia a nivel global.

2.3. Estado del arte en las tecnologías de mercado.

La información siempre ha sido un conductor esencial del trading, y los operadores se han beneficiado enormemente de ella. Se tiene constancia de que estos esfuerzos comenzaron al menos cuando la Casa Rothschild se benefició enormemente de la compra de bonos debido a las noticias por adelantado de la victoria británica de Waterloo, que fue llevada por palomas a lo largo del canal.

Hoy en día, la latencia entre la Bolsa de Chicago (CME) y algunos intercambiadores en Nueva York ha bajado a un límite teórico de tan solo 8 milisegundos [3], de los cuales se están beneficiando muchos operadores.

Tradicionalmente, los inversores confiaban en información públicamente disponible y en el **análisis fundamental**, que proviene de la información financiera de las propias compañías, por ejemplo, los informes de ganancias cuatrimestrales. Los esfuerzos por adquirir conjuntos de datos privados, por ejemplo, a través de encuestas privadas, fueron limitados. Las estrategias convencionales se centran en el análisis fundamental de capital. De manera alternativa, se aprovechó el potencial del **análisis**

2. El mercado financiero.

técnico para extraer señales del mercado utilizando indicadores que provienen del precio y el volumen de operaciones realizadas.

Los algoritmos de Machine Learning (ML) ayudan a explotar el mercado y los datos de manera más eficiente que las reglas definidas por los humanos y las heurísticas. Además, la aparición de Internet y las redes móviles han propulsado el crecimiento y el uso de los datos digitales, y se han realizado muchos avances en la tecnología para poder procesar, almacenar y analizar nuevas fuentes de datos. El crecimiento exponencial en la disponibilidad y la habilidad para manejar un mayor rango de datos digitales ha sido crítico para las mejoras en rendimiento que ha experimentado el aprendizaje automático, el cual está llevando a cabo la innovación en muchos sectores, incluyendo el sector financiero.

El escalado de la revolución de datos es extraordinario: los dos últimos años han sido testigos de la creación del 90% de todos los datos que existen en el mundo actualmente, y en 2020 se esperaba que cada uno de los 7,7 billones de personas usuarias de la red produjesen 1,7 MB de nuevos datos cada segundo de cada día. Por otra parte, en 2012, solo un 0,5% de todos los datos eran analizados o utilizados, mientras que en 2020 se esperaba que el 33% de los datos tuviesen algún valor. También se previó que el salto entre la disponibilidad de datos y el uso de estos fuese más estrecho a medida que las inversiones globales en análisis subiesen por encima de los 210 billones de dólares en 2020 [4].

Los datos del mercado son el producto que ayuda a los operadores a posicionar órdenes para un instrumento financiero directamente o a través de intermediarios en uno de los numerosos mercados. Entre estos datos se encuentran los precios, que cambian a través de la **oferta** y la **demand**a. Como resultado, los datos reflejan el comportamiento directo de los lugares de comercio, incluyendo las reglas y regulaciones del gobierno, la ejecución de operaciones y la formación de los precios.

Los operadores pueden utilizar algoritmos, incluyendo ML, para analizar el flujo de compra y venta y el volumen resultante, así como las estadísticas de los precios, con objeto de extraer señales para operar y poder obtener análisis. Por ejemplo, la dinámica de la oferta y la demanda o el comportamiento de ciertos participantes del mercado. Además, se pueden posicionar varios tipos de órdenes de compra y venta. Algunas de estas órdenes garantizan una ejecución inmediata, mientras otras pueden estar a la espera de que se dispare alguna condición para ser ejecutadas, por ejemplo, cuando el precio alcance cierto valor.

Existen tres tipos de órdenes:


- Orden de mercado: se ejecuta inmediatamente.
- Orden limitada: solo se ejecuta si el precio del mercado es superior al límite para una orden de compra, o si el precio es inferior al límite para una orden de venta.
- Orden de parada: solo se activa si el precio sube por encima de un valor específico para una orden de compra, o baja por debajo de un valor específico para una orden de venta.

Aparte de estas órdenes, se pueden establecer otras condiciones, incluso cancelar una orden de manera inmediata, o hacer que se ejecute a una hora específica.

Actualmente existen proveedores que ofrecen multitud de datos de mercado (por ejemplo, el comportamiento de los precios) mediante APIs, las cuales, a través de llamadas tipo REST permiten utilizar los datos para desarrollar servicios financieros que facilitan las operaciones en bolsa, algunas de estas APIs son las siguientes:

- Alphavantage¹ 

Este proveedor, el cual ha sido utilizado para obtener el comportamiento de los precios de mercado utilizados en el desarrollo de la aplicación del presente proyecto, ofrece de forma gratuita distintos datos de mercado, como son: datos de precios a lo largo de un periodo de tiempo, datos de las compañías (como informes de ganancias cuatrimestrales), información acerca de las divisas e indicadores técnicos. Permite realizar 5 peticiones por minuto y 500 peticiones diarias.

- Finnhub² 

Ofrece un mayor rango de APIs que Alphavantage y, además, permite obtener noticias del mercado, informes de prensa, sentimientos de noticias (de la última semana consultada), indicadores de análisis fundamental y análisis técnico, y otros datos de interés. Permite realizar 60 llamadas por minuto de forma gratuita, pero sus endpoints están limitados. La versión de pago, que cuesta 1000 dólares al mes, no posee ninguna limitación en cuanto al rango de endpoints que ofrece, y tampoco en cuanto al número de llamadas.

- StockNews³ 

A través de este proveedor se han obtenido los datos de noticias que han sido utilizados en la realización del presente TFM. Ofrece diversos endpoints, uno de los más importantes sirve para obtener todos los símbolos de compañías, por ejemplo, el símbolo de Apple es AAPL, que permite identificar la compañía unívocamente. También se utiliza para obtener los datos de noticias de los dos últimos años relacionados con una compañía en particular, y los sentimientos asociados a éstas, por ejemplo, una noticia puede ser positiva, neutral o negativa, y dependiendo del número de noticias en un periodo de dos años, el sentimiento asociado a este periodo puede ser positivo, negativo o neutral.

Hoy en día muchas aplicaciones utilizan estos datos y hacen uso del aprendizaje automático para realizar predicciones acerca del comportamiento del mercado, sobre todo, relacionadas con el comportamiento de los precios y las emociones que surgen de las noticias.

La aplicación desarrollada en el presente TFM aplica este tipo de predicciones para poder detectar tendencias que han ocurrido en el pasado y realizar un análisis de estas tendencias para saber que estrategias funcionan mejor, y aparte, conocer si se puede crear un indicador a partir de las emociones.


¹ <https://www.alphavantage.co/>. Último acceso: 25/01/2021.

² <https://finnhub.io/>. Último acceso: 03/02/2021.

³ <https://stocknewsapi.com/>. Último acceso: 03/01/2021.

2. El mercado financiero.

Algunas aplicaciones financieras, similares a la que se ha desarrollado en el TFM, son las siguientes:

- StockSight⁴ 

Esta aplicación es de código abierto y permite obtener métricas de un activo en particular a partir de tweets, analizando el sentimiento de dicho activo para determinar cómo se siente el autor. Mediante esta aplicación se pueden analizar diversos activos y operar a partir de estas emociones, por ejemplo, realizando un ranking con los activos que se asocian con un sentimiento más positivo y aquellos asociados a un sentimiento más negativo.

- Kavout⁵ 

Ofrece rankings de activos utilizando un indicador obtenido a través de Machine Learning llamado K-Score, el cual da una puntuación de 0 a 9 a cada uno de los activos, siendo aquellos con valores más altos los que tienen más probabilidad de éxito al ser operados, esta aplicación es de pago, teniendo un coste de hasta 12.000\$ por año.

⁴ <https://github.com/shirosaidev/stock sight>. Último acceso: 25/01/2021.

⁵ <https://www.kavout.com>. Último acceso: 25/01/2021.

Capítulo 3. Análisis técnico y las emociones en el mercado.

El análisis técnico es el estudio del comportamiento del precio en los mercados financieros, con el objetivo de predecir el próximo movimiento y poder operar de manera robusta y con decisiones firmes.

Enfocarse en el comportamiento del precio ofrece una ventana a la mente de los demás participantes y ayuda a tomar mejores decisiones. Esto no significa que se pueda predecir el futuro a través del análisis técnico, pero si puede ayudar a identificar la probabilidad de que el precio de un activo pueda cambiar de dirección, como se muestra en la Figura 3-1, o continuar en la misma dirección, como se muestra en la Figura 3-2. Ambas figuras se muestran en un tipo de gráfico llamado gráfico de velas japonesas, que se utiliza para representar el comportamiento del mercado, y se explicará en detalle en el [apartado 3.1](#).

En estos gráficos se muestran diferentes tendencias, las cuales a menudo perduran a lo largo de un periodo largo de tiempo. Una tendencia es un cambio discernible en la dirección de los precios, y pueden ser alcistas, bajistas, o neutrales, las tendencias neutrales van de lado a lado y no está claro si van hacia arriba o hacia abajo. Los analistas técnicos, a nivel básico, deben ser capaces de identificar estos cambios en la tendencia o de saber cuándo una tendencia va a continuar.

El análisis técnico no funciona en todas las ocasiones, ya que existen momentos en los que cuando parece que una tendencia se va a revertir, continúa en la dirección de la tendencia primaria. Además, una técnica no funciona el 100% de las ocasiones, y hay que saber identificar estos momentos.

La probabilidad de que un evento ocurra se determina comparando diferentes instancias de diferentes **patrones de comportamiento** en el pasado. El análisis técnico utiliza información histórica del comportamiento pasado procedente de las operaciones de distintos inversores, con objeto de comprender mejor las emociones que hay detrás del comportamiento humano, para tomar mejores decisiones sobre posibles movimientos del precio en el futuro [12].

Aparte de esto, el análisis técnico intenta identificar el comportamiento de una multitud de personas, esto es llamado el efecto vagón (Bandwagon effect) [13]. Este efecto funciona de la siguiente manera, cuando una serie de noticias se publican, muchos operadores interpretan las noticias como favorables y las compras sobrepasan a las ventas, como consecuencia, el precio sube. Es necesario sacar beneficio cuando está subiendo, y cuando todo el mundo salta del vagón, hay que bajarse y cortar pérdidas.

Lo mismo ocurre con el miedo, cuando se compra un activo, el miedo a la pérdida hace que se venda demasiado pronto, cuando se ha tenido oportunidad de venta más tarde. Incluso cuando se publican una serie de noticias desfavorables, o en periodos de crisis, hay una tendencia a la venta.

El análisis técnico se abstrae de las noticias, y por tanto reduce el riesgo de que las emociones entren en juego a la hora de operar.

3. Análisis técnico y las emociones en el mercado.



Figura 3-1. Cambio de dirección del mercado.



Figura 3-2. Continuación del precio en la misma dirección.

A finales del siglo XIX, Charles Dow, uno de los fundadores del Wall Street Journal, observó que el precio de un activo es una de las piezas de información más importantes, y en la que se puede confiar. Algunas de las observaciones que se le atribuyen a Dow son las siguientes:

- Los precios de los activos se mueven en tendencias.
- Las tendencias se pueden identificar a través de patrones que se ven repetidamente.
- Las tendencias primarias (que duran meses o años) se interrumpen con movimientos secundarios (que duran semanas o meses) en la dirección opuesta de la tendencia primaria.
- Las tendencias permanecen activas hasta que algún evento hace que paren.

Estas ideas forman parte de la teoría Dow, a pesar de que Charles Dow nunca llamó de esa manera a sus propias ideas.

Es complicado considerar el análisis técnico como algo científico, pero este sigue el método científico, lo cual incluye una observación sistemática de los indicadores, que están creados con medidas estándar, para formar una hipótesis y poder validar la teoría.

Hoy en día el análisis técnico se considera más como un campo de la estadística y la probabilidad. La teoría de la probabilidad se originó en los siglos XVI y XVII, pero fue utilizada en su mayor parte para tratar de descifrar como ganar en los juegos de azar. Actualmente se utiliza también para predecir el comportamiento del precio en el mercado.

Existen dos tipos de participantes en el ámbito del análisis técnico, estos pueden ser inversores y operadores (traders). La mayoría de personas considera que un trader es aquel que mantiene sus posiciones de compra/venta durante un corto periodo de tiempo, desde minutos a años. Y un inversor es aquel que mantiene sus posiciones de compra/venta desde meses a toda la vida, uno de los inversores más famosos es Warren Buffet.

El análisis técnico se puede utilizar en cualquier periodo de tiempo. Por ejemplo, se puede abrir una posición en Apple cuando el precio esté relativamente bajo, tomar algunos beneficios cuando está parcialmente alto y cerrar cuando el activo vuelva a descender. También se puede reducir el riesgo operando el capital en diversos activos y tener un portafolio, operando un porcentaje de capital para cada activo.

Comprar y mantener activos durante un largo periodo de tiempo es un camino bien documentado para obtener beneficios, pero solamente si se abre y se cierra la operación en el momento correcto. Por ejemplo, si se hubiesen comprado activos justo antes de la quiebra de 1929, hubiese llevado 20 años recuperar las pérdidas.

Desde enero de 2000 hasta octubre de 2002 el S&P 500 (Standards And Poor's 500 Index), que es uno de los índices más importantes de Estados Unidos, donde capitalizan 500 empresas, cayó un 50%, como se muestra en la Figura 3-3. Si se hubiesen poseído activos del S&P 500 durante este periodo se hubiese perdido un 50% de esos activos, lo que significa que para recuperarlos habría que obtener una ganancia equivalente al 100% de capital para recuperar otra vez el dinero, como se muestra en la Tabla 3-1, que representa las ganancias necesarias para recuperar algunos porcentajes de pérdidas que se dan en el mercado de manera usual.

En el siguiente apartado se explicará en qué consisten los gráficos de velas japonesas, como se originaron y su uso en el campo del análisis técnico.

3. Análisis técnico y las emociones en el mercado.



Figura 3-3. Precio de S&P 500 de 2000 a 2003.

Pérdida	Ganancia necesaria para recuperar la pérdida
10%	11.1%
20%	25.0%
30%	42.9%
40%	66.7%
50%	100.0%
60%	150.0%
75%	300.0%

Tabla 3-1. Recuperación de pérdidas.

3.1. Las velas japonesas.

La vela japonesa es simplemente una caja rectangular y vertical, algunas de ellas poseen mechas en la parte superior e inferior. Estas formas tienen un gran significado en el reconocimiento del comportamiento del precio y la predicción de que es más probable que suceda después.

El uso de esta herramienta se remonta al siglo XVII en Japón, en el mercado de arroz de Dojima (Osaka), que fue el primer mercado de contratos futuros del mundo. Un hombre llamado Munehisa Homma desarrolló la metodología de monitorizar los precios diarios del arroz, y estos métodos evolucionaron en lo que hoy en día se conoce como velas japonesas.

3.1.1. Elementos de las velas japonesas.

Las velas japonesas poseen cuatro componentes, los cuales se muestran en la Figura 3-4:

- Precio de apertura: el precio al cual un activo abre es la primera pieza de información utilizada para crear una vela, y dependiendo de la dirección del tipo de vela (alcista o bajista) este precio estará en la parte inferior o superior de la vela.
- Precio más alto: se trata del precio más alto que un activo ha alcanzado en un periodo dado, no obstante, si la vela es muy bajista este no existirá y no habrá mecha superior en la vela.
- Precio más bajo: es el precio más bajo que un activo ha alcanzado durante un periodo, pero si la vela es muy alcista este no existirá y no habrá mecha inferior en la vela.
- Precio de cierre: después de que un activo haya terminado de ser operado en un periodo de tiempo, su precio de cierre es la última pieza de información usada para crear una vela, y dependiendo de si la dirección de la vela es alcista o bajista este estará en la parte superior o inferior, respectivamente.




Figura 3-4. Componentes de las velas japonesas.

3. Análisis técnico y las emociones en el mercado.

Es complicado precisar un precio de apertura, ya que muchos activos se operan en múltiples mercados o redes electrónicas. Por ejemplo, si un activo cierra el día anterior a 56\$/acción, muchas redes electrónicas permiten operar horas antes de que el activo abra. Por tanto, las noticias pueden hacer que el activo abra a un precio más alto del que se encontraba el día anterior, o a un precio más bajo, dependiendo si las noticias inducen un sentimiento de optimismo o de miedo, de esta forma, el precio puede dar un salto con respecto al día anterior [17].

Una de las mayores ventajas de las velas japonesas es que se puede detectar de un solo vistazo la naturaleza del precio durante ese periodo de tiempo (que puede ser de minutos hasta años).

Aparte de esto, son muy fáciles de leer en comparación con otros métodos, como los gráficos de barras, como se muestra en la Figura 3-5.

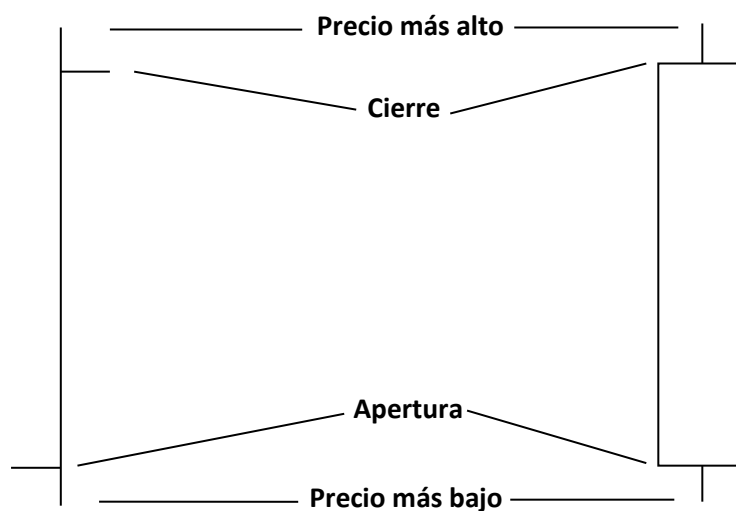


Figura 3-5. Comparativa entre una barra y una vela.

Una de las mayores ventajas de las velas japonesas es que se puede detectar de un solo vistazo la naturaleza del precio durante ese periodo de tiempo (que puede ser de minutos hasta años).

Otra ventaja es que se puede distinguir una vela alcista (toro) de una vela bajista (oso), ya que una vela representa una batalla entre toros (compradores) y osos (vendedores). La vela blanca (o verde) es un oso, y la vela negra (o roja) es un toro.

Los términos oso y toro han formado parte del léxico del trading durante muchos años. Ambos términos se aplican tanto a personas como a tendencias del mercado. Un toro es un participante del mercado que espera o desea que el mercado se mueva en una tendencia alcista, es también una expresión para indicar que el mercado se va a mover hacia arriba. Un oso, por otro lado, indica un mercado bajista o es una persona que desea o espera que el mercado baje.

3.1.2. Otros tipos de gráficos.

También existen otro tipo de gráficos que se mencionarán, ya que pueden servir de apoyo a los gráficos de velas japonesas:

- Gráficos de líneas

Este tipo de gráficos muestra los precios de los activos a lo largo del tiempo, normalmente se trata del precio de cierre. No obstante, estos gráficos no permiten desarrollar una estrategia de trading, ya que no hay suficiente información para detectar patrones. Se muestra un ejemplo de este tipo de gráficos en la Figura 3-6.

- Gráficos de barras

Un gráfico de barras representa el comportamiento del precio de un periodo a otro. Cada barra es una línea vertical que muestra la diferencia entre el precio más alto y el precio más bajo del periodo. La parte superior de la barra es el precio más alto y la parte inferior de la barra el precio más bajo. La distancia entre ambos es similar a las mechas de un gráfico de velas japonesas. Una muesca a la izquierda de la barra representa la apertura, y una muesca a la derecha de la barra representa el cierre, como se muestra en la Figura 3-5, en la que se compara una barra con una vela japonesa. La Figura 3-7 muestra un gráfico de barras completo.

Estos gráficos han sido utilizados en el sector financiero durante algún tiempo, pero han sido rápidamente reemplazados por los gráficos de velas japonesas.

- Gráficos de figuras y puntos

Los gráficos de figuras y puntos son otro tipo de gráficos de acciones que están compuestos por x's y o's dibujados en una hoja. No se construye sobre un periodo de tiempo, sino que se basa en cambios de dirección del precio. Las x's representan movimientos alcistas, mientras que las o's representan movimientos bajistas, este tipo de gráficos se puede representar en tablas, ya que no requiere de un periodo de tiempo, tal y como se muestra en la Tabla 3-2.

Este tipo de gráficos son únicos ya que solamente representan movimientos del precio. El tiempo no es un factor importante y solamente es necesario actualizarlos cuando el precio cambia. Por ejemplo, si el precio oscila entre 60 y 70, un gráfico de figuras y puntos ofrece una visión clara de estos cambios, los cuales se llaman niveles de soporte y resistencia, en este caso 60 es un nivel de soporte y 70 un nivel de resistencia.

3. Análisis técnico y las emociones en el mercado.




Figura 3-6. Gráfico de líneas.



Figura 3-7. Gráfico de barras.

		X						
		X	O			X		
		X	O			X		
	O	X	O	X		X		
	O	X	O	X	O	X		
	O		O		O	X		
					O			

Tabla 3-2. Gráfico de figuras y puntos.

3.1.3. Información adicional de las velas japonesas.

Existen otros componentes que se pueden añadir a los gráficos de velas japonesas, como los que se describen a continuación:

- Volumen

El volumen es el número de participaciones o acciones que se operan durante un periodo de tiempo. La medida del volumen aparece normalmente en la parte inferior de un gráfico, como muestra la Figura 3-8.

- Interés abierto

El interés abierto, en el caso de gráficas de contratos futuros, es lo mismo que el volumen. Es decir, que cuando un comprador y un vendedor de contratos futuros inician una nueva posición, el interés abierto aumenta en uno.

Cuando se compra un contrato futuro se está abriendo una nueva posición en ese contrato, y cuando se vende un contrato futuro se está cerrando una posición en ese contrato.

Los contratos futuros se crearon como medio para permitir a los granjeros fijar un precio de sus cultivos y eliminar el riesgo de que cuando estos estuvieran listos para ser vendidos, el precio de venta no fuese suficiente para cubrir los costes y proporcionar un beneficio. Para los granjeros esto era una manera de eliminar el precio de venta de sus riesgos, ya que había muchos factores que escapaban a su control.

Por ejemplo, se desea compra paneles solares, y se espera que el 1 de junio los paneles cuesten 100€ la unidad, pero no se desea pagar tanto por ellos. Una tienda te ofrece contratos futuros de paneles solares, los cuales te costarán solamente 70€, y justo el día 1 de junio estos contratos expiran, por tanto, se deposita un porcentaje y se compran tantos contratos futuros como paneles se deseen. Cuando llega el 1 de junio, se podrá pagar 70€ por estos paneles solares, a pesar de que el precio sea de 100€ en el mercado.

La ventaja de los contratos futuros es que le permiten al vendedor planificar la producción, fijando un número de ventas en una fecha determinada y a cierto precio. También puede ser un especulador que crea que puede comprar paneles solares a un precio menor a 70€ antes de que el contrato futuro expire, generando un beneficio.

3. Análisis técnico y las emociones en el mercado.



Figura 3-8. Volumen.

- Indicadores técnicos

Los indicadores técnicos pueden aparecer de manera automática en una gráfica, y son una forma de analizar tendencias del mercado con la esperanza de predecir tendencias en el futuro. Se puede esperar también ver alguna especie de media de los precios de cierre, que son las medias móviles, explicadas en detalle en el [apartado 3.2](#). Estas medias móviles se pueden añadir o eliminar según convenga, y se pueden configurar según el periodo que están analizando. Las más importantes son las de 20, 50 y 200 periodos. Existen indicadores que necesitan su propio espacio en la gráfica, como el volumen o el interés abierto.

- Información fundamental

Los gráficos que contienen este tipo de información no son comunes, ya que la información fundamental es aquella que pertenece al activo en particular, o a la compañía. Como por ejemplo, fechas de reportes de las ganancias o pérdidas de la empresa, o el número de días que las personas con información legal e interna de la empresa han comprado o vendido acciones. Esta información pertenece exclusivamente a gráficos de acciones (stocks).

Durante cada cuarto del año (cada cuatro meses o cuatrimestre), las compañías están obligadas a publicar un informe de las ganancias del cuarto previo. Estas cifras son publicadas normalmente a través de la prensa, y son rápidamente distribuidas a otros medios. Los operadores reaccionan a las noticias resultantes. La emisión de esta información por parte de la prensa es seguida por una hora o dos de conferencias protagonizadas por miembros de la propia compañía, los cuales contestan a las preguntas de analistas del sector acerca de las ganancias recientes de la empresa.

Respecto a los gráficos, saber cómo operan las acciones antes y después de cada informe cuatrimestral es útil para tomar decisiones. Por ejemplo, para saber si el precio de una acción ha subido o bajado después de estas fechas.

En el [apartado 3.3](#) se profundiza sobre el papel que juegan las noticias, y cómo influyen en el mercado y en las emociones de los inversores.

- División de las acciones

A veces, cuando el precio de una acción alcanza cierto valor, la compañía decide dividir el valor de la acción, y la información de la división se añade a menudo a las gráficas. La división de una acción se considera un evento positivo, ya que la acción estará disponible para más operadores.

Por ejemplo, si un operador posee 10 acciones de una compañía y hay una división de 2:1, significa que la acción se va a dividir en dos. Por tanto, el día que se divida el operador poseerá 20 acciones, si cada acción costaba 100€ antes de la división ahora costará 50€, por tanto, más operadores podrán comprar esta acción, ya que es más barata.

Dividir acciones permite una mayor propiedad de acciones. Muchas personas se pueden permitir comprar 100 acciones de una compañía que opera a 5€ por acción, pero pocas personas pueden permitirse comprar 100 acciones de una compañía que opera a 200€ por acción. La idea es poder aumentar el alcance de la propiedad de acciones a más personas.

La información de estas divisiones en una gráfica puede ser de utilidad, de hecho, muchas gráficas muestran la información del precio ajustado al aplicar la división. Normalmente, después de la división de la acción el precio tiende a ir hacia arriba.

3.1.4. Desventajas.

Existen ocasiones en las que los gráficos de velas no funcionan muy bien, las cuales se describen a continuación:

- No funcionan en un periodo corto de tiempo: los gráficos de velas japonesas representan de forma excelente el precio, pero no funcionan muy bien con algunas estrategias de trading a corto plazo, ya que los patrones que se revelan en un gráfico diario no se revelan tan bien en un periodo muy corto de tiempo (por ejemplo, cinco minutos o menos). Estas estrategias de trading se denominan intradía, y cada operación se mantiene como máximo durante un solo día.
- No reflejan el volumen fuera de horas de mercado: el surgimiento de un número elevado de brokers electrónicos significa que a veces el volumen puede ser muy elevado durante horas en las que el mercado no está abierto, esto puede producir patrones que no reflejan el panorama completo en un gráfico de velas japonesas. Por ejemplo, si un activo abre a las 9:30 a.m. a un precio de 60€, pero durante horas que no son de mercado baja hasta 50€, este salto se reflejará en la gráfica, pero no se sabrá que ha pasado en ese periodo de tiempo, lo cual puede ser de utilidad.

3.2. Las medias móviles.

Una tendencia es un fenómeno muy bien conocido en el campo del análisis técnico y del estudio del comportamiento de los precios de las acciones, ya que estos tienden a moverse en una dirección determinada durante un periodo de tiempo antes de parar o cambiar de dirección. Cuando los precios se mueven lejos de su media móvil de mayor periodo, la tendencia es que la dirección cambie y vuelva a la media móvil. Las tendencias son los indicadores técnicos más básicos.

Se puede dibujar una tendencia solamente con un gráfico de velas japonesas y una línea recta, como se muestra en la Figura 3-9.



Figura 3-9. Ejemplo de tendencia alcista.

A pesar de que distintas tendencias dibujadas en la misma dirección pueden parecer distintas, la dirección continúa siendo la misma. Las tendencias pueden ser alcistas, bajistas, o puede no existir una tendencia en absoluto (tendencias neutrales).

El siguiente paso a dibujar tendencias es calcular la media móvil. Una media móvil es la media de los precios de cierre de un activo en un periodo de tiempo. Se puede comparar un precio de cierre con una media móvil para determinar una tendencia, ya que estos están estrechamente relacionados.

Los periodos de tiempo de las medias móviles se determinan por el número de precios de cierre que se incluyen, ese número depende del estilo de trading que se utilice, y del tiempo que pueda dedicar el operador a observar el mercado. Por ejemplo, si se pretende operar durante meses, hay que elegir una media móvil de 200 periodos, pero si solo se va a operar durante un solo día, con una media móvil de 20 periodos es suficiente. Se considera que un mercado alcista a largo plazo opera siempre

por encima de la media móvil de 200 periodos, ya que ésta constituye una barrera psicológica a través de la cual el operador no está dispuesto a cruzar hacia abajo cuando hay un mercado alcista, o no está dispuesto a cruzar hacia arriba cuando hay un mercado bajista.

Existen distintos tipos de media móvil, el más básico es la media móvil simple, y la más utilizada. La Tabla 3-3 muestra cómo se calcula una media móvil de 5 periodos usando los precios de cierre de los cinco días previos. Los cinco precios de cierre se suman y se dividen entre cinco.

Día	Precio de cierre
1	67,56
2	68,9
3	64,5
4	63
5	67
Total	330,96
Total / 5	66,192

Tabla 3-3. Cálculo de media móvil de cinco periodos.

Si se tiene pensado operar a largo plazo, no tiene sentido utilizar una media móvil de cinco periodos ya que no tiene suficientes puntos. Aunque una media móvil calculada en un periodo más largo tiene menos probabilidad de revelar precios que cruzan la media. La Figura 3-10 compara dos medias móviles de 20 (azul) y 200 (rojo) periodos sobre los mismos precios de cierre, existe una diferencia muy notable entre ambas, ya que la media móvil de 200 periodos tiene menos fluctuaciones que la media móvil de 20 periodos.



Figura 3-10. Comparativa entre medias móviles de 20 y 200 periodos.

3. Análisis técnico y las emociones en el mercado.

Las medias móviles pueden ser confirmadas por otros indicadores técnicos, o por otras medias móviles. Es posible utilizar combinaciones de medias móviles para detectar tendencias, combinando dos o tres medias móviles, como se explica en el siguiente apartado.

3.2.1. Combinación de dos medias móviles.

A veces, observar una convergencia o divergencia entre dos señales es un método efectivo para predecir un cambio en la tendencia [18]. Por tanto, se pueden utilizar dos medias móviles y compararlas para poder tomar mejores decisiones, ya que el objetivo principal de las medias móviles es **reducir el ruido de las fluctuaciones en el precio**.

Para ello, se deben seguir los siguientes pasos:

1. Calcular o mostrar las dos medias móviles a comparar.
2. Determinar cuál de las dos medias móviles es más lenta y cual es más rápida.

La media móvil más rápida es siempre aquella con el número más bajo de precios de cierre (por ejemplo, la media móvil de 20 es más rápida que la de 200 periodos). Se dice que es más rápida porque cambia más rápidamente y por tanto fluctúa más que la lenta. La media móvil de 200 es más lenta y el precio tiende a cruzar esta media móvil en menos ocasiones.

3. Comparar las medias móviles para detectar una tendencia.

Si la media móvil rápida está por encima de la media móvil lenta, esto significa que hay una tendencia alcista, si está por debajo, significa que hay una tendencia bajista. Además, hay que tener en cuenta las propias velas, ya que si están por encima de ambas medias móviles es más probable que el precio siga subiendo, y si están por debajo de ambas medias móviles es más probable que el precio siga bajando.

La Figura 3-11 muestra un ejemplo utilizando la media móvil de 20 y de 50 para detectar una tendencia alcista, perteneciente al índice NASDAQ, que ocurre entre el 16 de abril y el 13 de agosto de 2019. Los puntos de cruce entre las medias son muy importantes ya que indican cuando se debe entrar en la operación y cuando se debe parar. En el primer punto de cruce entre las medias móviles el precio es de \$87,26, que es el precio al que se abre la operación, y cuando se vuelven a cruzar las medias móviles el precio es de \$98,26, habiendo obtenido una ganancia del 12,6%, la ganancia se ha calculado a través de la fórmula que se muestra a continuación:

$$Ganancia (\%) = \left(\frac{p_{cierre} * 100}{p_{apertura}} \right) - 100$$

Donde p_{cierre} representa el precio de cierre de la operación, y $p_{apertura}$ representa el precio al que se abre la operación.

Por tanto, la ganancia obtenida en la Figura 3-11 se ha calculado como:

$$Ganancia (\%) = \left(\frac{p_{cierre} * 100}{p_{apertura}} \right) - 100 = \left(\frac{98,26 * 100}{87,26} \right) - 100 = \left(\frac{9826}{87,26} \right) - 100 = 12,6\%$$



Figura 3-11. Ejemplo de combinación de dos medias móviles

Por lo cual, si se hubiese comprado una sola acción a ese precio el día de apertura de la operación y se hubiese vendido el día de cierre, se hubiese obtenido un 12,6% de la inversión realizada, es decir:

$$\text{Ganancia (\$)} = 12,6\% * 87,26 = \$10,99$$

Para obtener esta ganancia se ha requerido que la operación esté abierta durante aproximadamente cinco meses. Por tanto, si se hubiese querido obtener una ganancia superior, la cual permita ser económicamente independiente, teniendo en cuenta que el salario mínimo interprofesional en España es de 950€ (\$1170,82), habría que obtener un beneficio equivalente a \$5854,1 durante los meses que dura la tendencia. Por lo que, mediante una simple regla de tres se calculará la inversión necesaria para obtener este beneficio:

$$\text{Inversión} = \frac{5854,1 * 87,26}{10,99} = \$46481,23 = 37716,5\text{€}$$

Lo cual prueba que, para invertir a largo plazo, y dependiendo del precio de la acción, se requieren cantidades muy elevadas de capital.

Hoy en día existen otros productos financieros, como los contratos por diferencia (CFDs). Cuando se opera con CFDs no se posee un activo, sino que se asume una posición sobre la dirección futura en la que se moverá dicho activo. Por tanto, el beneficio o pérdida dependerá de la variabilidad en el

3. Análisis técnico y las emociones en el mercado.

precio. Esto es más arriesgado que poseer acciones, pero también permite tener que invertir menos capital. Además, el apalancamiento permite operar con más dinero del que realmente se dispone, multiplicando la posible rentabilidad, pero también el riesgo. Por tanto, si se hubiese operado con apalancamiento en el ejemplo de la Figura 3-11, solamente se hubiese tenido que invertir un quinto de la inversión que se hubiese realizado sin CFDs, asumiendo que el apalancamiento es 1:5. Según estos datos tendríamos que:

$$Inversión_{CFDs} = \frac{5854,1 * 87,26}{10,99 * 5} = \$9296,24 = 7543,03€$$

Hoy en día cada vez más brokers electrónicos están incorporando este tipo de productos financieros, ya que están al alcance de más inversores minoristas.

3.2.2. Combinación de tres medias móviles.

Algunos operadores utilizan una combinación de tres medias móviles en vez de dos, sobre todo para invertir a largo plazo. En este caso, no es necesario dibujar una tendencia, ya que se aprovecha de movimientos del mercado que continúan durante un periodo largo de tiempo, por ejemplo, un mercado alcista que continúa durante días.

La comparación utilizando tres medias móviles se hace identificando cada media móvil como rápida, de velocidad media o lenta, dependiendo del número de puntos que tenga cada una. Las más importantes son la de 200 puntos, que refleja tendencias a largo plazo, la de 50, que sirve para reflejar tendencias medias, y la de 20 puntos que refleja tendencias más a corto plazo.

A través de ellas es fácil identificar una tendencia alcista cuando la media móvil de 200 se encuentra por encima de la media móvil de 50, y la media móvil de 50 se encuentra encima de la media móvil de 20 periodos. Cuando hay una tendencia bajista la media móvil de 20 se encuentra por debajo de la de 50, y la de 50 se encuentra por debajo de la de 200 puntos.

la Figura 3-12 muestra un ejemplo de combinación de tres medias móviles utilizando un gráfico del NASDAQ 100, el cual representa un mercado bajista que ocurre entre el abril de 2008 y febrero del 2009, se explicará cada una de las medias móviles que participan más en detalle.

Este periodo coincide con la crisis de 2008, en la que hubo una gran recesión debido a una crisis económica, la cual fue provocada en parte por los bancos, los cuales, en busca de más rentabilidad, adquirían y revendían préstamos de hipotecas a usuarios que no tenían ingresos, ni trabajo fijo o suficiente. Estas hipotecas basura les permitieron a algunos bancos y fondos de inversión de varios continentes colocar en ellas parte de sus capitales y activos bancarios. La crisis empezó por la economía americana, que es uno de los países más desbordados en vivir con el dinero que no tienen. Estas hipotecas hicieron que los bancos tuviesen que renegociarlas una y otra vez, llegando algunas de ellas a tener que renegociarse 35 veces.



Figura 3-12. Ejemplo de tres medias móviles combinadas.

Desde finales de abril hasta el 12 agosto de 2008 se detecta un periodo en el que las tres medias móviles están en un estado que indica un periodo bajista, es decir, la media móvil de 20 está debajo de la de 50, y la media móvil de 50 está debajo de la media móvil de 200, y el cual se puede aprovechar para obtener un beneficio a través de una venta. Desde el 13 de agosto hasta el 6 de octubre de 2008 se cumple que ambas medias móviles están debajo de la de 200, pero la media móvil de 50 está por encima de la de 20, lo cual significa que no se debería intentar realizar ninguna operación en ese periodo de tiempo. Por último, desde el 7 de octubre de 2008 hasta el 5 de enero de 2009 se detecta una segunda tendencia, ya que las medias móviles se encuentran en un estado que indica una nueva tendencia bajista, por tanto, se puede abrir una nueva operación para obtener un potencial beneficio.

Esta estrategia ha sido utilizada en uno de los modelos entrenados con Azure Machine Learning en el presente TFM.

Existen ocasiones en las que la estrategia de medias móviles falla, ya que la variabilidad en los precios es demasiado alta (la volatilidad es la incertidumbre en el mercado, que tiene una estrecha relación con la variabilidad en el comportamiento del precio). Esto se debe a que un efecto (por ejemplo, un ataque terrorista, una pandemia, una serie de noticias malas) hace que haya mucha incertidumbre entre los inversores, como se muestra en la Figura 3-13, en la que se muestra un gráfico de la compañía BAYER en el periodo de febrero a mayo de 2015. Entre el 13 y el 30 de abril de 2015 los precios bajan abruptamente, siguiendo un periodo de subidas y bajadas que indican una alta volatilidad.

3. Análisis técnico y las emociones en el mercado.



Figura 3-13. Ejemplo de alta volatilidad.

3.3. Emociones en el mercado.

En el presente apartado se explicará cómo afectan las emociones de las personas en el comportamiento del mercado, ya que existe un conjunto de emociones que influyen directamente en el comportamiento del precio, y, por tanto, se pueden aprovechar para detectar tendencias.

Estas emociones pueden surgir mientras se está operando en el mercado. Como por ejemplo el miedo, la avaricia, la rabia, la felicidad y en general un estado de excitación, o pueden surgir debido a algún evento que se ha observado antes de operar en el mercado. Como por ejemplo alguna serie de noticias que ha reforzado la decisión que íbamos a tomar (comprar o vender) o ha hecho que se cambie de opinión.

Poseer un conocimiento general del papel que juegan las emociones es un área válida de estudio para cualquier inversor, porque los estudios científicos han reconocido que las emociones son indispensables para tomar decisiones racionales durante la ejecución de operaciones en general, durante toda la vida, y han demostrado tener funciones muy importantes en la interacción social.

De hecho, anatómicamente, la capa del cerebro que controla las emociones se encuentra por debajo de la capa que controla la razón, lo que prueba que hubo un cerebro emocional antes que un cerebro racional. El sistema límbico es el centro del cerebro que controla las emociones, pero algunos científicos creen que las emociones se distribuyen entre distintas partes del cerebro.

Las emociones son las estructuras que gobiernan nuestras vidas. El término “estado anímico” se refiere a un estado emocional que dura normalmente horas, días o semanas. Exactamente, no está claro cuando un estado anímico comienza o para.

En el siglo XIX, los pioneros de la investigación en el campo de las emociones no creían que las emociones fuesen útiles. Charles Darwin pensaba que eran patrones de comportamiento que tenían alguna función en nuestro pasado, pero que ya no servían para ningún propósito.

La definición de emoción ha sido un reto para la disciplina de la psicología, y es probable que cualquier definición actual de emoción cambie conforme se vaya contribuyendo con más definiciones a través de la investigación. Mandler, en 1984, se quejó de que muchos psicólogos fallan en aceptar que no hay una definición clara de emoción.

Una definición acordada de emoción es la siguiente:

- Una emoción es normalmente causada por una persona consciente o inconscientemente evaluando un evento como relevante para un objetivo que es importante. La emoción es positiva cuando el objetivo ha tenido éxito, y negativa cuando el objetivo ha fallado. Por ejemplo, cuando un operador de bolsa se dispone a comprar, pero de repente la tendencia se vuelve negativa, el operador experimenta pérdidas que para otros operadores son un beneficio, ya que anticipaban que este operador iba a comprar erróneamente.
- El núcleo de una emoción se basa en la preparación para actuar: una emoción da prioridad a uno o algunos tipos de acciones que tienen prioridad. Diferentes tipos de preparación crean diferentes relaciones y comportamientos. Por ejemplo, un operador profesional que tiene pérdidas estará más preparado para afrontarlas que alguien que no ha operado nunca en el mercado.
- Una emoción se experimenta como un tipo de estado mental, algunas veces acompañado por cambios corporales, expresiones o acciones.

Existe una fuerte pero complicada relación entre las noticias y las emociones. Las noticias se transmiten desde todas las partes del planeta, y los inversores aprovechan continuamente estas noticias para entender mejor el mercado y las emociones asociadas a éste. Los operadores y otros participantes digieren las noticias rápidamente, revisando y reajustando sus posiciones de acuerdo con éstas. Conforme los mercados reaccionan rápidamente a las noticias, se buscan modelos efectivos que incorporan datos de noticias. Esto no se hace solamente con propósitos de ejecución de operaciones y gestión de capital, sino también para **reducir riesgos**. Los mayores eventos de noticias pueden tener un impacto significativo en el entorno del mercado y en las emociones de los inversores, dando como resultado cambios rápidos en las características de los riesgos de los distintos activos.

A pesar de que la relevancia de las noticias es ampliamente conocida, cómo incorporarlas dentro del proceso de toma de decisiones de las inversiones es una pregunta muy abierta.

Uno de los impactos que tienen las noticias en el mercado es la de un aumento del volumen de operaciones realizadas. El volumen incrementa en días en los que se transmite información importante de una empresa, como un informe de ganancias. Las noticias más importantes resultan frecuentemente en grandes beneficios o grandes pérdidas. Una 65% de los cambios en los precios y el volumen de una compañía está asociado con las noticias que se emiten públicamente. A veces los inversores podrían ver algo complicado el asociar un volumen alto de operaciones sin un cambio significativo en los precios.

Las noticias financieras pueden ser divididas en noticias esperadas (como informes de ganancias de una empresa) o noticias inesperadas (como una pandemia).

3. Análisis técnico y las emociones en el mercado.

Los tipos de noticias a los que tienen acceso los inversores pueden ser los que se explican a continuación:

- Noticias: se refiere a las noticias transmitidas por medios convencionales y que abarcan aquellas que provienen de fuentes fiables. Pueden ser publicadas por periódicos, radio y televisión, también se pueden obtener a través de periódicos digitales.
- Pre noticias: se trata de las noticias que investigan los reporteros antes de escribir un artículo. Procede de fuentes de información primarias como las comisiones de mercado.
- Rumores: estos provienen de blogs y sitios web que transmiten todo tipo de información, tienen menos reputación que las noticias y las pre noticias, no obstante, existen blogs que pertenecen a fuentes de alta reputación.
- Redes sociales: estos sitios web son los menos fiables, ya que existe mucha facilidad para publicar cualquier tipo de información, por lo que pueden ser fuentes peligrosas de las que extraer noticias. Si son aplicadas de manera cuidadosa, podrían llegar a detectar como mínimo la volatilidad del mercado, ya que se pueden analizar emociones en ellas.

Las noticias siempre han sido una fuente de investigación. Los volúmenes y fuentes de noticias están creciendo de forma veloz, por tanto, en mercados altamente competitivos, los inversores y traders deben ser capaces de seleccionar y analizar los eventos más importantes de las enormes cantidades de información disponibles con el objetivo de tomar buenas decisiones a tiempo. No obstante, la capacidad de un ser humano para procesar las noticias es limitada. A medida que la capacidad computacional crece, las tecnologías emergentes permiten extraer, agregar y categorizar grandes volúmenes de noticias de manera efectiva. El análisis automático de noticias puede ser un componente clave de las estrategias disponibles para los operadores, y aquellos que utilicen esta tecnología pueden reaccionar a tiempo a las noticias (reducir el tiempo de latencia).

Además, las tecnologías de análisis de noticias pueden ser utilizadas para ayudar a los inversores a monitorizar las noticias para ciertos activos en particular, o analizar las noticias de distintos sectores, como la medicina o la tecnología, y las emociones asociadas a estas noticias. La idea básica detrás de las tecnologías de análisis es la de automatizar el pensamiento humano. Los inversores y operadores son capaces de analizar el nivel de volatilidad (esto es la incertidumbre en el mercado) antes de tomar una decisión, ya que leen de manera cuidadosa las recientes noticias relacionadas con economía y finanzas para tomar ventaja de la situación actual. Usando su conocimiento acerca de cómo los mercados reaccionaron en el pasado bajo ciertas condiciones, de forma automática asociaran la situación actual a aquellas que se comportaron de manera similar en el pasado.

El análisis de noticias busca introducir la tecnología para automatizar u ofrecer un apoyo en la toma de decisiones. Además, a través de estos automatismos se pueden tomar decisiones sobre un conjunto más variado de activos.

Los algoritmos de Machine Learning pueden combinarse con el análisis de noticias para reforzar todavía más la toma de decisiones.

Para aplicar las noticias de manera efectiva en la gestión de riesgos y las decisiones de trading hay que ser capaz de identificar qué noticias son relevantes y cuáles no. Esto es particularmente cierto para aplicaciones intradía, en las cuales los algoritmos deben ser capaces de responder rápidamente a información precisa. Debemos ser capaces de distinguir también las noticias antiguas de las noticias

que son recientes. En 2008 se llevó a cabo un estudio el cual ilustra el impacto de las noticias sobre los retornos anormalmente acumulativos. Para ello se eligieron 350000 historias de noticias de las empresas del índice S&P 500, que aparecían en el Wall Street Journal de 1984 a 2004. Cada una de las noticias se clasificó como positiva o negativa [7].

Un aspecto del análisis de noticias es el descubrimiento de contenido informativo de noticias. La conversión de texto cualitativo en un formato legible por una máquina es un reto. Por tanto, se hace necesario distinguir si el contenido de una historia es positivo, negativo, o incluso neutral, ya que puede no aportar nada. Se puede llegar más lejos e intentar identificar cómo de positiva o negativa es la historia, asignando una puntuación de sentimiento a cada una. Estas emociones pueden ser definidas en términos de cómo de positivamente o negativamente las personas la interpretan. Además, se pueden definir estándares para clasificar historias. Algunos de ellos incluyen conjuntos de datos de entrenamiento de palabras, otros pueden ser interpretaciones psicológicas de palabras, ya que varios grupos de personas pueden estar afectadas de forma distinta por un evento y pueden tener una interpretación distinta.

Un enfoque muy atractivo es utilizar medidas basadas en el mercado para interpretar y definir la importancia de las noticias. Los cambios relativos en términos de volatilidad para un activo en particular o para un sector, cotejados con una serie de noticias, pueden ser utilizadas para definir la emoción de las noticias. Este enfoque asume que el mercado ha respondido a las noticias.

A través de las emociones detectadas por las noticias es posible desarrollar nuevos sistemas de inversión y nuevos procesos de gestión de riesgos. Enlazar estas puntuaciones de sentimientos a los retornos de activos, volúmenes de operaciones y volatilidad, o, en otras palabras, descubrir la conexión entre el análisis de noticias y el análisis financiero es un reto líder en el dominio de las aplicaciones.

El análisis de noticias en el sector financiero se centra en mejorar los sistemas de aplicaciones basados en las tecnologías de la información (IT). Estas mejoras vienen a través de la investigación y el desarrollo directo, y el trading automático. La buena práctica de aplicar este análisis de forma manual es también un enfoque correcto.

Para desarrollar sistemas de gestión de riesgos y sistemas de inversión, se debe aplicar un pre análisis a los datos de noticias, y después se deben extraer las métricas importantes, como la puntuación de emociones. Una vez obtenidas, se deben consolidar con los datos de los precios del mercado, y esto constituye los datos necesarios para alimentar un modelo de predicción, los cuales sirven para poder predecir ganancias y medir riesgos. Todo este proceso se resume en la Figura 3-14.

El desarrollo de analíticas de noticias y sus aplicaciones en el sector financiero está ganando cada vez más aceptación dentro de la comunidad de inversores. Un alto número de estudios académicos han sido llevados a cabo, y esto hace que muchos proveedores de datos y APIs ofrezcan las noticias de cada activo con las emociones asociadas a estas. Como la API Stock News [16], que se ha utilizado en el presente TFM en combinación con los datos financieros proporcionados por la API Alphavantage [1] con el objetivo de crear un indicador basado en estas emociones y poder realizar un análisis de tendencias de mercado basado en este indicador, para poder compararlo con otras estrategias.

3. Análisis técnico y las emociones en el mercado.

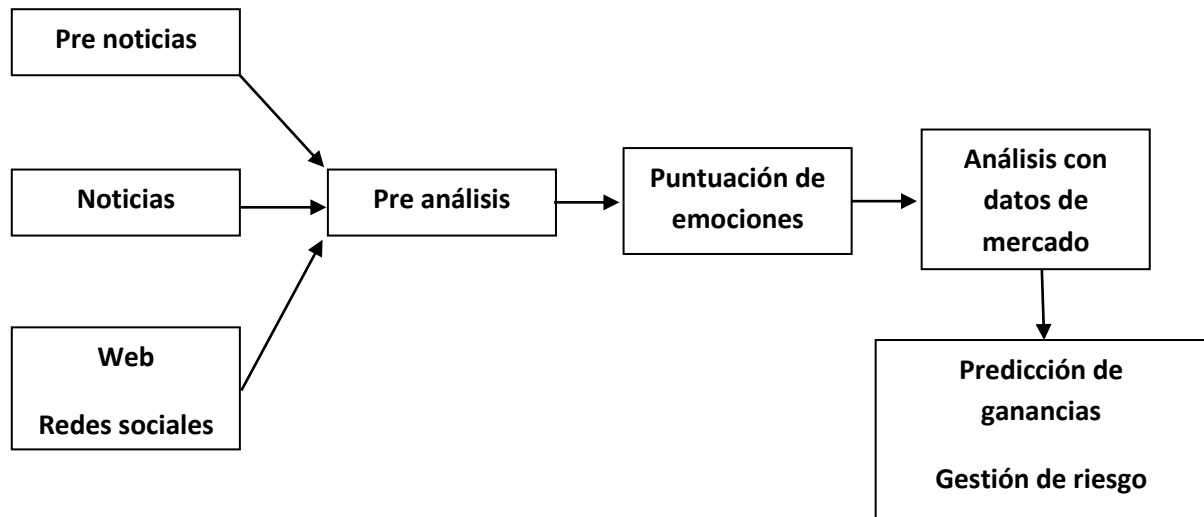


Figura 3-14. Proceso de análisis de noticias en el mercado.

Otro posible uso de estas APIs es crear un ranking de acciones dependiendo de la puntuación de las emociones asociadas a cada una, e identificar cuáles de ellas son atractivas (o no tan atractivas), pudiendo comprar o vender las acciones en la parte más alta del ranking, o tener un portafolio de activos. De manera similar, los datos de noticias pueden crear modelos para conocer de antemano la volatilidad de algunos activos en común, creando por tanto otro tipo de portafolio que indique qué activos hay que mantener.

Capítulo 4. Diseño.

En el presente capítulo se muestra un esquema general de la implementación de la aplicación, así como las distintas ventanas que componen la aplicación web desarrollada y la funcionalidad asociada a cada una.

4.1. Diseño general de la API.

Para realizar la implementación de cada microservicio [9], tanto *newsemotions* como *marketemotions*, se ha seguido un esquema basado en el patrón MVC a través de Spring Framework, el esquema general de *newsemotions* (microservicio para obtener emociones de noticias) se muestra en la Figura 4-1 y el esquema general de *marketemotions* (microservicio para relacionar el comportamiento del mercado con las emociones obtenidas de noticias) se muestra en la Figura 4-2. El diagrama de clases del microservicio *NewsEmotions* se adjunta en el Anexo I y el diagrama asociado al microservicio *MarketEmotions* se adjunta en el Anexo II, estos ofrecen un mayor nivel de detalle del diseño del que ofrecen los esquemas generales.

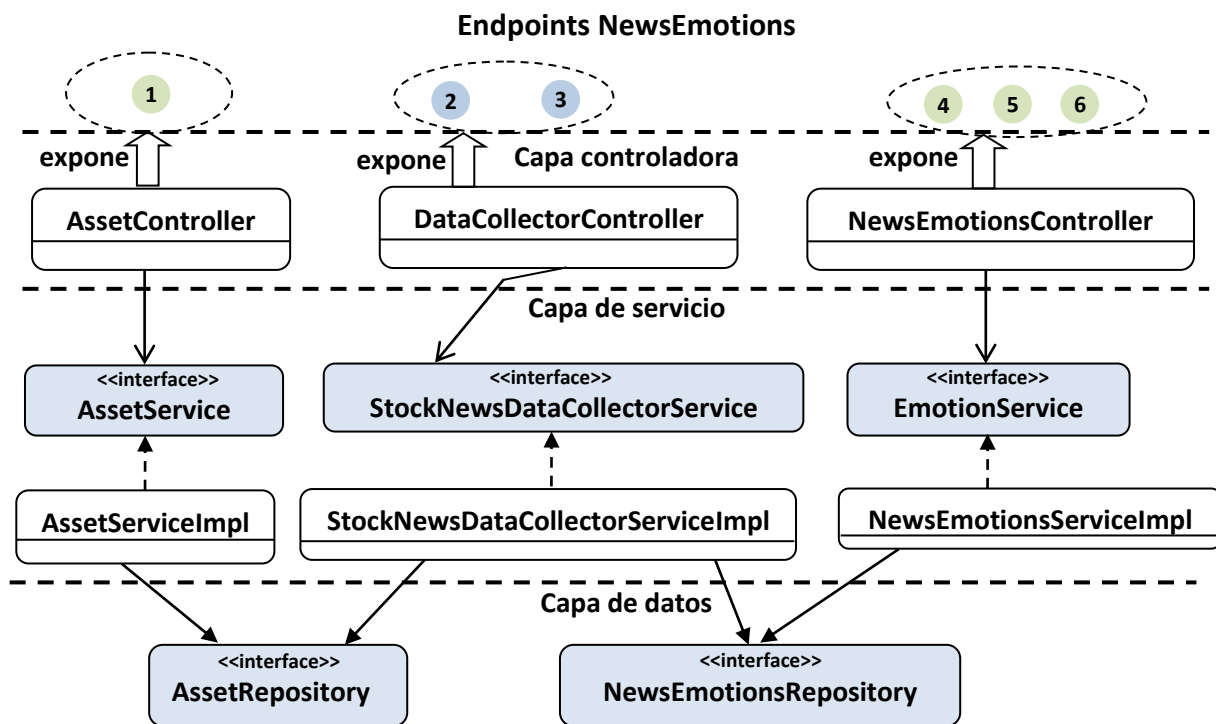


Figura 4-1. Esquema general de microservicio NewsEmotions.

La primera capa es la capa controladora, que contiene las clases encargadas de exponer los endpoints de la API. Estas clases contienen la anotación *@RestController*, perteneciente a Spring, que se encarga de indicar que la clase es un controlador y, además, en vez de retornar plantillas como Thymeleaf, implementará llamadas tipo REST, internamente todos los métodos de las clases anotadas con *@RestController* vienen anotados con *@ResponseBody*, lo que permite devolver el

4. Diseño.

objeto en formato JSON. *AssetController* es el encargado de exponer aquellos endpoints relacionados con los activos, como por ejemplo Apple o Microsoft.

A continuación, se explica para que se usa cada uno de los controladores implementados y se detallan los endpoints expuestos por ellos:

- *AssetController*

Es el encargado de exponer los endpoints relacionados con activos, como Microsoft o Apple. Por ejemplo, permite obtener todos los datos relacionados con Microsoft a través de su símbolo, MSFT.

1 /asset/{ticker} (GET)

Permite obtener información de una compañía por su símbolo, por ejemplo, la información de Google pasando GOOGL como variable de ruta.

- *DataCollectorController*

Este controlador se encarga de exponer los endpoints relacionados con la importación de datos de la API StockNews. De ésta se han obtenido los datos relativos a las emociones pertenecientes a las noticias diarias, y también toda la información de las compañías pertenecientes a su propia base de datos, que incluye los símbolos de las compañías.

2 /newsemotions/import/{ticker} (POST)

Permite importar todas las emociones de noticias asociadas a una compañía de los **dos años anteriores a la fecha actual** de la API StockNews.

3 /newsemotions/import/all-tickers (POST)

Permite importar todas las compañías de la base de datos de StockNews, incluyendo la información de los símbolos asociados a estas.

- *NewsEmotionsController*

A través de este controlador se obtienen las emociones de noticias asociadas a las distintas compañías.

4 /newsemotions/{ticker} (GET)

Permite obtener todas las emociones de noticias de los dos años anteriores a la fecha actual para una compañía en concreto.

5 /newsemotions/{ticker}/{date} (GET)

Permite obtener las emociones de noticias de una compañía en un día concreto. Por ejemplo, las emociones asociadas a las noticias del día 24/12/2020 de la compañía Mastercard.

6 /newsemotions/{ticker}/{from}/{to} (GET)

Permite obtener las emociones de una compañía entre dos fechas dadas (siempre que éstas entren dentro de los dos años anteriores a la fecha actual).

Mediante este controlador se pueden obtener los datos relacionados con las emociones extraídas de las noticias. Como por ejemplo, la etiqueta de la emoción, que puede ser positiva, neutral o negativa.

La segunda capa contiene todos los servicios, donde están declarados los métodos que utilizan los controladores para poder procesar los datos de la tercera capa, que es la capa de datos, donde se encuentran las clases de repositorio, que llaman directamente a la base de datos. La clase *StockNewsDataCollectorService* utiliza ambas clases de repositorio, ya que al realizar la importación tanto de activos como de emociones de noticias necesita guardar toda la información en la base de datos.

Para más información sobre los endpoints del microservicio *NewsEmotions* se puede ver la documentación de Swagger¹ asociada. Igualmente, se tiene acceso al código fuente en un repositorio de Github².

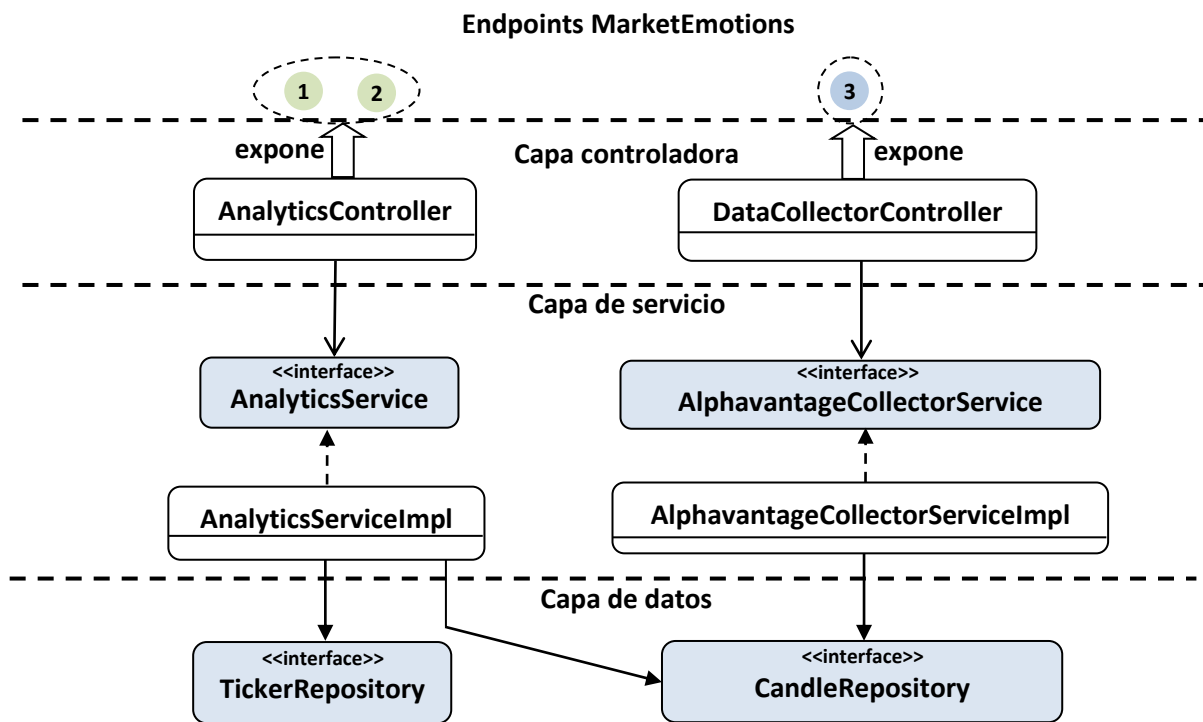


Figura 4-2. Esquema general de microservicio MarketEmotions.

El controlador *AnalyticsController* se encarga de exponer los endpoints relacionados con el análisis de tendencias, el cual se basa en tres estrategias y una combinación de dos de las estrategias, las cuales se detallan en el [Capítulo 5](#).

¹ <https://app.swaggerhub.com/apis/amb690/news-emotions/1.0.1>. Último acceso: 07/02/2021.

² <https://github.com/amb690/news-emotions>. Último acceso: 07/02/2021.

1 /marketemotions/analytics/{ticker}/{from}/{to} (GET)

Este endpoint permite analizar tendencias de un activo en particular entre dos fechas, basándose en tres estrategias, una estrategia basada en las posiciones de las medias móviles y los precios, una estrategia basada en la media móvil de 20, 50 y 200 periodos, y una estrategia basada en emociones que surgen de las noticias. Se debe precisar que la estrategia de emociones funciona dentro de los dos años anteriores a la fecha actual.

También se analizan tendencias basándose en la combinación de la estrategia de las tres medias móviles y la estrategia de emociones, ya que de esta manera se reduce el riesgo al tener en cuenta ambos indicadores. No obstante, se analizan menos tendencias, por lo que se pierden oportunidades de compra o venta.

2 /marketemotions/analytics/{ticker} (GET)

A través de este endpoint se pueden analizar los indicadores surgidos de aplicar las estrategias de la fecha actual para un activo en concreto. Por ejemplo, los indicadores de la estrategia de tres medias móviles para la fecha actual de la compañía APPLE, lo cual nos dará a conocer si se puede operar a través de las noticias (compra o venta), a través de las medias móviles o a través de la relación entre la posición de las medias móviles y la posición de los precios.

3 /marketemotions/import/{ticker} (POST)

Permite la importación de todos los datos relacionados con el comportamiento de los precios del mercado (velas japonesas) y la asociación de las emociones obtenidas de las noticias diarias a cada vela, los periodos son diarios.

Para más información sobre los endpoints del microservicio *MarketEmotions* se puede acceder públicamente a la documentación de Swagger³ asociada. Igualmente, se tiene acceso al código fuente en un repositorio de Github⁴.

Cada uno de los microservicios que se han descrito han sido desplegados en distintas máquinas virtuales creadas en Openstack a través de tareas de Jenkins, el cual se encuentra a su vez desplegado en otra máquina virtual, la Figura 4-3 muestra la red de Openstack que contiene todas las máquinas utilizadas para realizar el presente TFM.

Debido a las limitaciones de Openstack ya que todos los puertos excepto el 80 y 8080 se encuentran cerrados se ha decidido desplegar cada uno de los microservicios en una máquina virtual distinta con un sistema operativo Ubuntu 18.04 LTS. También se ha instalado SonarQube, para certificar que se cubre la cobertura de clases en cada uno de los microservicios desarrollados. Se utilizará Jenkins para desplegar cada uno de los microservicios según corresponda. Y se ofrece un servidor de configuraciones tipo Spring Cloud [15] para almacenar aquellos valores que requieran una mayor seguridad.

³ <https://app.swaggerhub.com/apis/amb690/market-emotions/1.0.0>. Último acceso: 08/02/2021.

⁴ <https://github.com/amb690/market-emotions>. Último acceso: 07/02/2021.

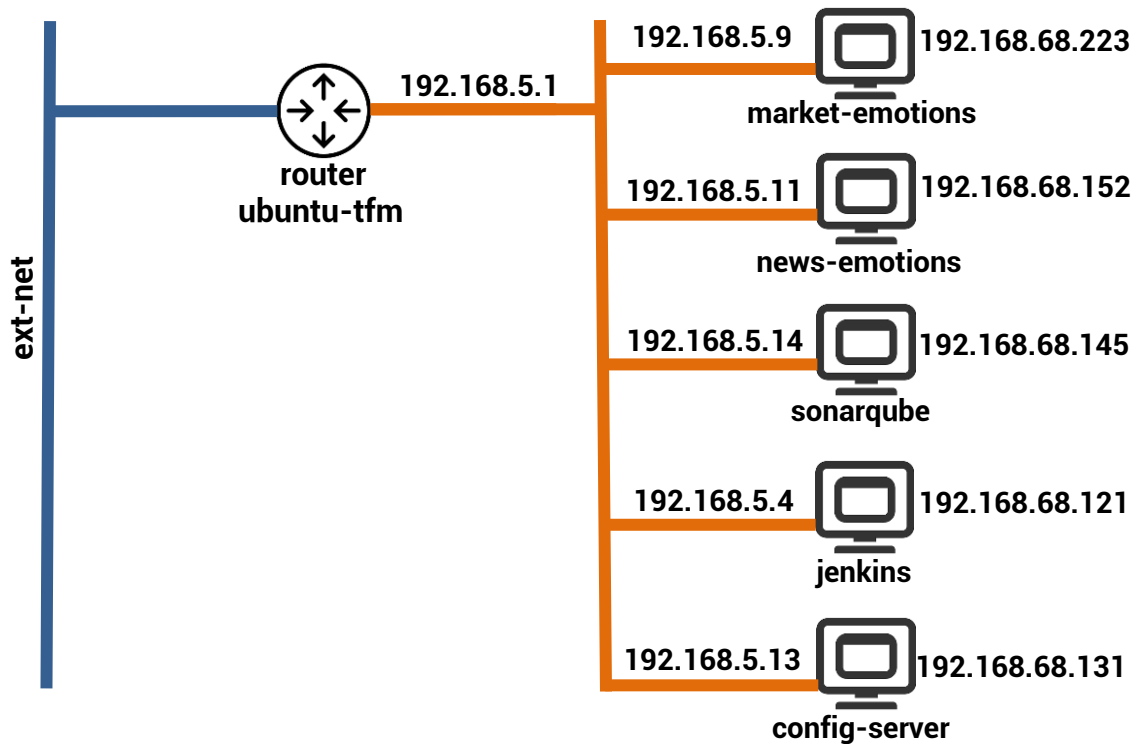


Figura 4-3. Esquema de red de Openstack.

Para desplegar los microservicios, en cada una de las tareas de Jenkins, se han ejecutado los siguientes pasos:

- Primero, se realiza la **compilación del proyecto**, la subida del código al repositorio de DockerHub, y la evaluación de la calidad a través de Sonarqube:

```
org.jacoco:jacoco-maven-plugin:prepare-agent clean install -U -Dmaven.test.failure.ignore=true
sonar:sonar -Dsonar.login=<login> -Dsonar.projectKey="<project_key>"
```

Tras ejecutar el comando `mvn clean install`, se ejecuta el plugin de jacoco, el cual se encarga de generar los informes de cobertura en Jenkins. Después, se ejecuta el plugin de sonar, el cual se encarga de evaluar la cobertura de todo el código fuente en sonar. El flag `U` actualiza las dependencias de terceros que lo necesiten basándose en el fichero `pom.xml`.

Una vez ejecutado sonar se ejecuta el plugin `maven spotify`, que se encarga de subir los últimos cambios a Dockerhub a través del comando `docker push`, ejecutado automáticamente.

Finalmente, un plugin de Jenkins llamado `Sonar Quality Gates` se encarga de que la tarea falle en caso de que el proyecto no haya cumplido con las condiciones impuestas en el proyecto de sonar.

- Una vez realizada la compilación, se ha ejecutado el despliegue a través del siguiente pipeline. Como ejemplo se muestra el pipeline del microservicio `marketemotions`:

Pipeline de microservicio MarketEmotions

```

(1) pipeline {
(2)   agent any
(3)   stages {
(4)     stage('Start build/deploy market-emotions') {
(5)       steps {
(6)         echo 'Starting market-emotions build process'
(7)       }
(8)     }
(9)     stage ('Build') {
(10)      steps {
(11)        build job: 'market-emotions', parameters: []
(12)      }
(13)    }
(14)    stage ('Deploy') {
(15)      steps {
(16)        sshagent(credentials : ['<credentials>']) {
(17)          sh 'ssh -o StrictHostKeyChecking=no <host> docker-compose pull <microservicio>'
(18)          sh 'ssh -o StrictHostKeyChecking=no <host> docker stop <microservicio>'
(19)          sh 'ssh -o StrictHostKeyChecking=no <host> docker rm <microservicio>'
(20)          sh 'ssh -o StrictHostKeyChecking=no <host>
(21)            docker-compose up -d <microservicio>'
(22)          sh 'ssh -o StrictHostKeyChecking=no <host> docker image prune -a --force'
(23)        }
(24)      }
(25)    }
(26)  }
(27) }

```

Primero, en el estado 'Start build/deploy market-emotions' se imprime por pantalla un mensaje descriptivo para que el usuario sepa que hace esa tarea. El siguiente paso ejecuta la tarea de compilación del proyecto, la cual se explica con detalle en el paso anterior.

Finalmente, en el estado 'Deploy' se utiliza el plugin SSH Agent para poder ejecutar comandos SSH de forma remota en los servidores donde se van a desplegar los microservicios. Primero, se descarga la última imagen de Docker a través del comando *docker pull <microservicio>*, al estar anotada con el tag 'latest' se descargará la imagen que contiene los últimos cambios. Después, se borra el contenedor que se esté ejecutando en ese momento y se crea un nuevo contenedor a partir de la nueva imagen mediante Docker Compose, el cual despliega cualquier microservicio que se encuentre en el archivo *docker-compose.yml*. La Figura 4-4 muestra una imagen del fichero utilizado.

Tras ejecutar el microservicio se han borrado las imágenes antiguas a través del comando *docker image prune -a --force*.

```

version: '3.1'

services:
  config-server:
    image: albertombln/config-server
    ports:
      - 8080:8080
    restart: always
    container_name: config-server

  news-emotions:
    image: albertombln/news-emotions
    ports:
      - 8080:8080
    restart: always
    container_name: news-emotions

  market-emotions:
    image: albertombln/market-emotions
    ports:
      - 8080:8080
    restart: always
    container_name: market-emotions

  database:
    image: mysql
    command: --default-authentication-plugin=mysql_native_password
    restart: always
    environment:
      MYSQL_ROOT_PASSWORD: root
      MYSQL_USER: alberto
      MYSQL_PASSWORD: root
    container_name: database
    ports:
      - 3306:3306

  sonarqube:
    image: bitnami/sonarqube:7
    ports:
      - '80:9000'
    environment:
      - SONARQUBE_DATABASE_NAME=bitnami_sonarqube
      - SONARQUBE_DATABASE_USER=bn_sonarqube
      - SONARQUBE_DATABASE_PASSWORD=bitnami1234
    volumes:
      - sonarqube_data:/bitnami

volumes:
  sonarqube_data:
    driver: local
  postgresql_data:
    driver: local

```

Figura 4-4. Fichero docker-compose.yml.

4.2. Aplicación web.

La aplicación web, que consume las APIs desarrolladas en el apartado anterior, ha sido desarrollada mediante el framework AngularJS. Las ventanas principales que componen la aplicación son las siguientes:

- Ventana de activos

Esta ventana permite gestionar los activos disponibles, ordenar por cualquier columna, buscar un activo en concreto y borrar un activo cualquiera, como se muestra en la Figura 4-5. También permite analizar las tendencias de ese activo.

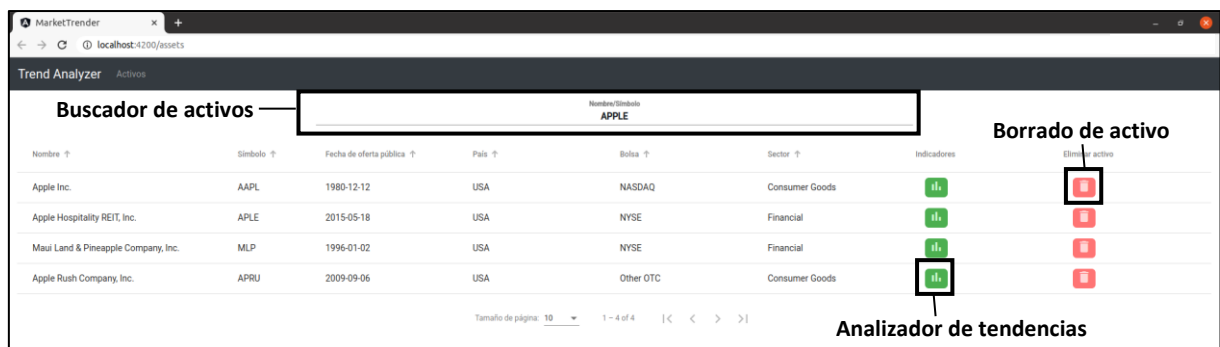


Figura 4-5. Ventana de activos.

- Ventana de análisis de tendencias

Permite obtener los indicadores de la fecha actual y analizar tendencias pasadas de un activo en particular, como se muestra en la Figura 4-6.



Figura 4-6. Ventana de análisis de tendencias.

Capítulo 5. Experimentación y resultados.

La ciencia de datos es la práctica de obtener conclusiones útiles a partir de un conjunto de datos, y es particularmente importante en Big Data, aunque se puede utilizar también con pequeños conjuntos de datos. La idea es poseer datos de distintas fuentes y obtener información de ellos.

Dentro del análisis de datos se encuentra la categoría de análisis predictivo, el cual sirve para ayudar a predecir qué ocurrirá en el futuro [2] a partir de un conjunto de datos. Por ejemplo, en el caso del presente proyecto sirve para ayudar a predecir si existe un momento de compra o venta de un activo en el mercado de valores.

En un proyecto de análisis predictivo es necesario pasar por distintos estados de manera iterativa, como se muestra en la Figura 5-1.

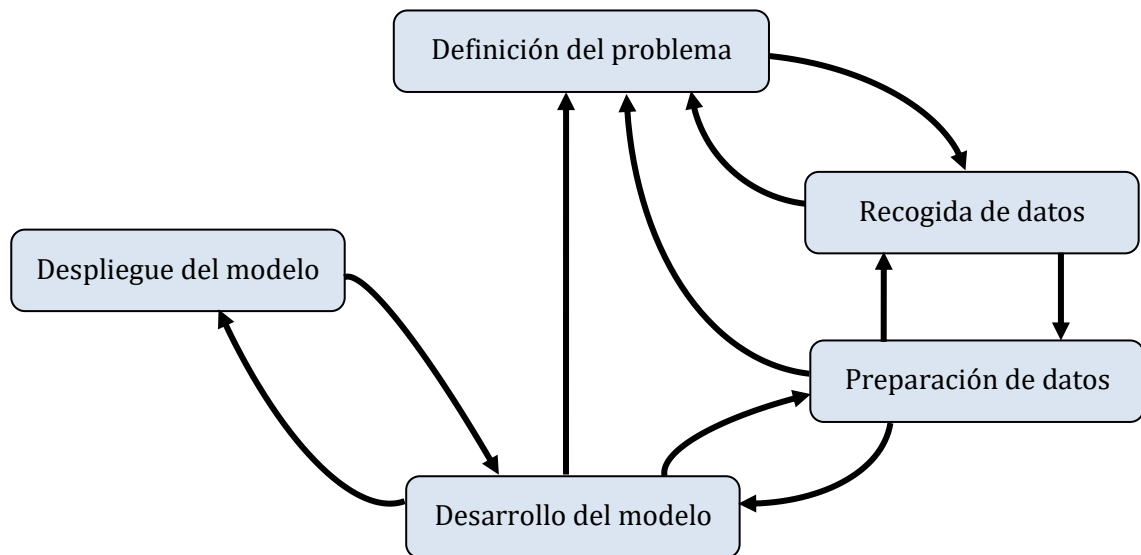


Figura 5-1. Estados del análisis predictivo.

- Definición del problema

En este estado se hace necesario saber cuáles son las necesidades de negocio y las soluciones que se buscan, por lo que hay que traducir el problema de negocio en un problema de análisis. Por ejemplo, la compañía podría estar interesada en ofrecer a sus clientes una plataforma de operaciones en bolsa que les ayude a conocer potenciales momentos de compra y venta. Por tanto, el problema tiene que ser traducido en una predicción de estos momentos de compra y venta a partir de datos del mercado, como el comportamiento del precio en forma de velas japonesas o las emociones surgidas de noticias diarias.

5. Experimentación y resultados.

- Recogida de datos

La solución comienza con la recogida de datos. En algunos casos, los datos se pueden encontrar en la nube, o en almacenes empresariales, los cuales los exponen en forma de APIs para que puedan ser consumidos por analistas de datos. En el caso del presente TFM se han obtenido las emociones surgidas de noticias de la API StockNews [16] y los datos sobre el comportamiento del mercado de la API Alphavantage [1].

- Preparación de datos

Después de obtener los datos, se requiere visualizarlos y explorarlos para una comprensión total de estos.

A menudo los datos del mundo real son confusos, y siempre hay que comprobar la calidad de los datos, ya que muchas veces llegan valores nulos, o se requiere seleccionar los descriptores adecuados de un gran número de descriptores. Por tanto, es necesario hacer un preprocesamiento de datos y en este caso se ha hecho necesario seleccionar los descriptores para cada uno de los experimentos y comprobar que no existen valores nulos.

También es necesario que el origen de datos esté en un formato adecuado y en este caso se ha utilizado el formato CSV.

- Desarrollo del modelo

En este paso se despliega el modelo ya entrenado como servicio web, de forma que pueda ser consumido por los clientes o por otras aplicaciones. En el presente TFM se han expuesto los endpoints pertenecientes a tres modelos entrenados, los cuales se asocian con tres estrategias de mercado distintas: la estrategia basada en la posición de los precios y las medias móviles, la estrategia de tres medias móviles (de 20, 50 y 200 periodos) y la estrategia basada en emociones surgidas de las noticias.

En la mayor parte de los casos es necesario trabajar este proceso de una manera iterativa, ya que normalmente será necesario ir a una fase anterior porque el modelo cambie en un futuro. Además, se puede realizar el entrenamiento varias veces para que la predicción sea lo más precisa posible.

El aprendizaje automático es una disciplina científica que explora la construcción y estudio de algoritmos que pueden aprender de los datos y detectar patrones. Estos algoritmos operan construyendo un modelo a partir de datos de ejemplo y utilizan este modelo para realizar predicciones o tomar decisiones en vez de seguir instrucciones estáticas de programación.

En el caso del presente proyecto, lo que se quiere predecir es un momento de compra o venta, o un momento neutral en el que no se pueden realizar operaciones. Por tanto, existe una variable objetivo o clase. El objetivo del algoritmo es aprender de un conjunto de datos de entrenamiento, y después de haber sido entrenado, el algoritmo predice un nuevo caso. Este tipo de aprendizaje es conocido como aprendizaje automático supervisado. Y funciona tal y como se muestra en la Figura 5-2.

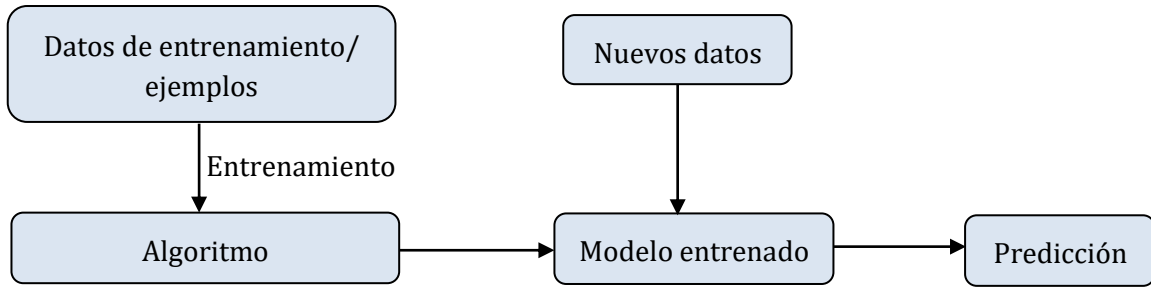


Figura 5-2. Proceso de aprendizaje automático supervisado.

Dentro del aprendizaje automático existen distintos tipos de problemas, en este caso lo que se intenta predecir es una etiqueta, que puede ser, por ejemplo, positiva, negativa o neutral. Por ello, se trata de un problema de clasificación. Si lo que se intentase predecir es un número o un valor continuo, se trataría de un problema de regresión.

El entorno de desarrollo utilizado para realizar el proyecto ha sido Azure Machine Learning Studio, el cual se trata de un entorno en la nube que permite a los desarrolladores construir y desplegar modelos de análisis predictivos, y proporciona un conjunto de algoritmos de aprendizaje automático.

Permite crear experimentos donde se arrastran distintos módulos y conectarlos entre sí, así como los conjuntos de datos en forma de CSV.

Normalmente los experimentos se ejecutan repetidas veces de forma iterativa, ya que se debe probar con distintos datos y distintos algoritmos hasta que el resultado sea un modelo que realice una predicción fiable.

La Figura 5-3 muestra un esquema del entorno de Azure Machine Learning Studio.

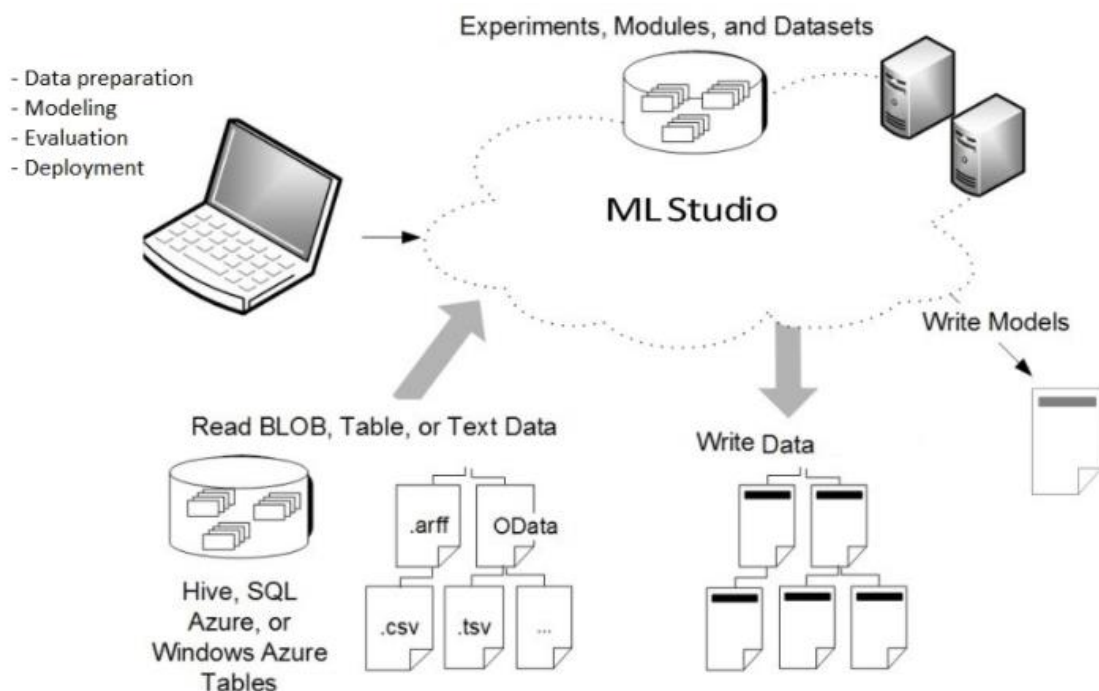


Figura 5-3. Esquema de Azure ML Studio. Fuente: [8]

5. Experimentación y resultados.

La Figura 5-4 muestra el experimento básico realizado en el presente TFM. Se han desarrollado tres experimentos para cada una de las tres estrategias, usando el mismo conjunto de datos para cada uno, pero seleccionando distintos descriptores de este conjunto de datos. Estos experimentos generarán modelos que se desplegarán como servicios web, y servirán como entrada de datos de la API de análisis de tendencias, como muestra la Figura 1-3.

El módulo 'Select Columns in Dataset' se encarga de seleccionar de un conjunto de datos⁵ los descriptores necesarios en cada experimento, los cuales se detallarán para cada estrategia. Este conjunto de 15815 datos posee información sobre el comportamiento de los precios de las compañías Microsoft, Tesla, Bayer y Amazon. Las compañías pertenecen a varios sectores, entre ellos las IT, la salud y el comercio electrónico.

A menudo, será necesario dividir el conjunto de datos para realizar el entrenamiento y posteriormente probar el conjunto de datos con el modelo ya entrenado. Para ello se ha utilizado el módulo 'Split Data', y se ha decidido entrenar un 70% del conjunto de datos y realizar la prueba del modelo ya entrenado con el 30% restante para detectar posibles errores. Esto forma parte de la etapa de preparación de los datos. Las proporciones más comunes para dividir los datos son 70-30 u 80-20.

Antes de realizar la predicción se hace necesario entrenar un algoritmo con los datos de ejemplo o conjunto de datos de entrenamiento donde la etiqueta a predecir es conocida. Después de entrenar el modelo, se puede realizar una predicción con él.

Después de entrenar el modelo, se pueden usar los datos de prueba para realizar una predicción o puntuar. En la fase de puntuación ya se conocen los valores predichos, y se les da una puntuación. En este punto no se conoce el rendimiento del modelo, necesita ser evaluado, por ello se comparan el valor puntuado y el valor actual.

Por ejemplo, en la fase de puntuación se conoce que la operación predicha es una compra, pero durante la evaluación se descubre que es venta, por tanto, existe un error.

⁵ <https://github.com/amb690/market-emotions/blob/master/marketemotions/training-set.csv>

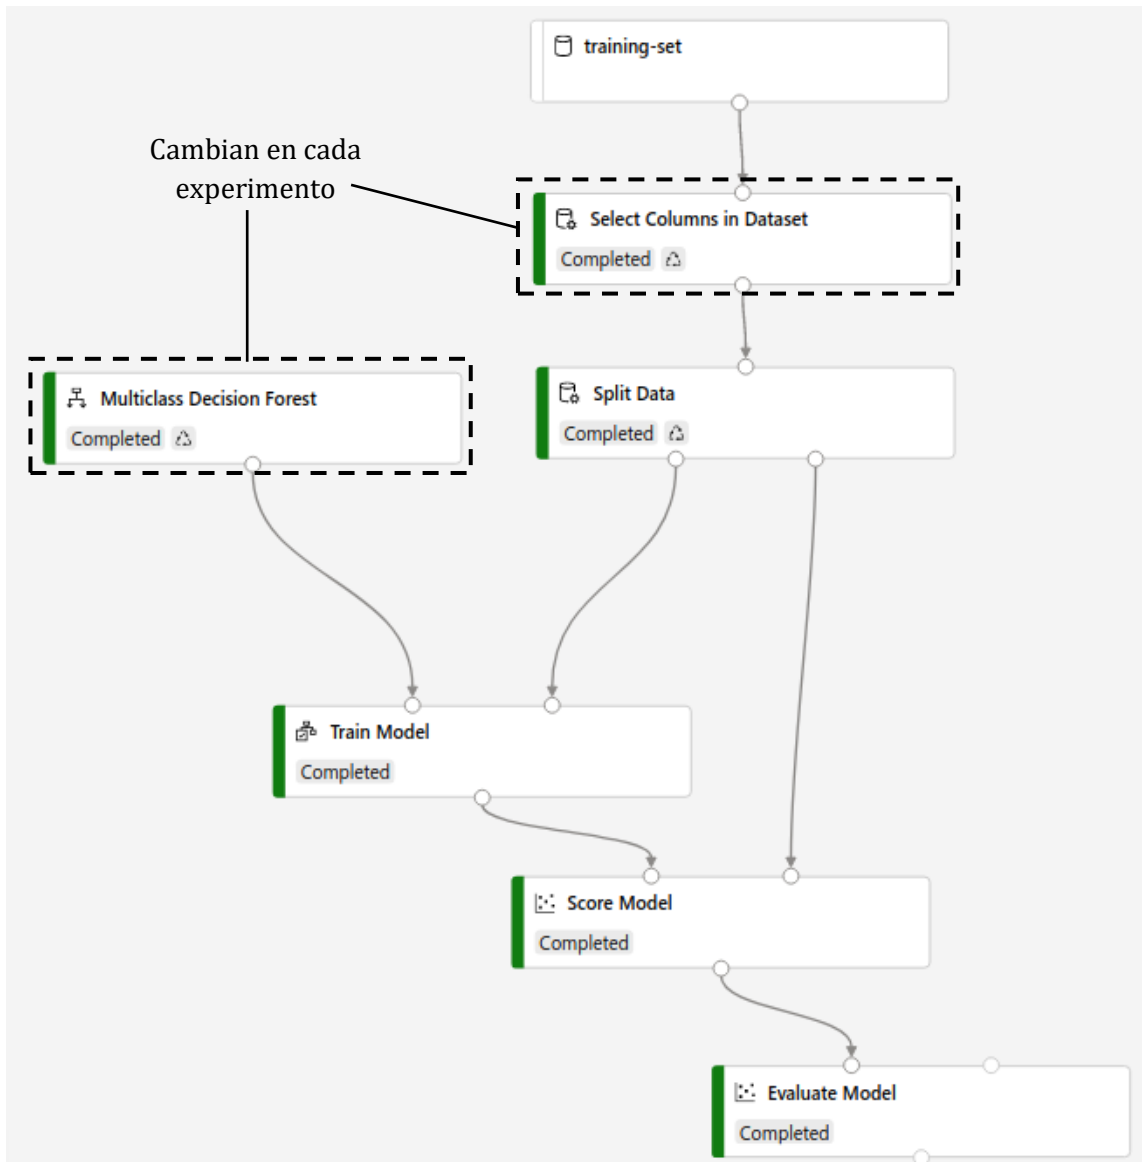


Figura 5-4. Esquema de experimento en Azure ML Studio.

Los algoritmos de clasificación que pueden ser utilizados para entrenar el modelo son muy diversos, pero los más populares incluyen los que se describen a continuación:

- Árboles de decisión

Los árboles de decisión son técnicas jerárquicas que dividen iterativamente el conjunto de datos basándose en ciertos criterios estadísticos. Cada nodo de un árbol de decisión representa el lugar donde se selecciona un atributo y se hace una pregunta. Las líneas del árbol representan las respuestas a la pregunta realizada en el nodo, y las hojas representan la salida o clase resultante. La Tabla 5-1 representa los datos de entrada y la clase a predecir, y la Figura 5-5 muestra el árbol de decisión simple, resultante de entrenar los datos de dicha tabla, el cual predice un comportamiento del precio (sube o baja con respecto al día anterior) dependiendo de las posiciones de las medias móviles de 20, 50 y 200 periodos una respecto de la otra en un día concreto en el que se han realizado operaciones en bolsa.

Día	Posición de media móvil de 20 respecto de 50	Posición de media móvil de 20 respecto de 200	Posición de media móvil de 50 respecto de 200	¿Comportamiento del precio?
1	Encima	Debajo	Encima	Sube
2	Debajo	Encima	Encima	Baja
3	Debajo	Encima	Debajo	Sube
4	Debajo	Debajo	Debajo	Baja

Tabla 5-1. Ejemplo de árbol de decisión.

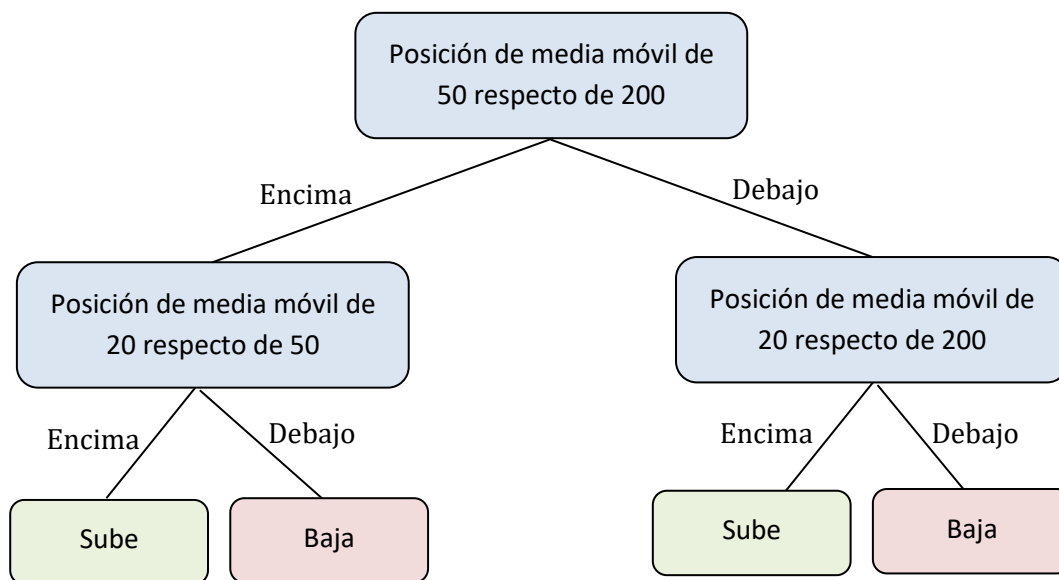


Figura 5-5. Ejemplo de árbol de decisión.

- Redes neuronales

Estos algoritmos están inspirados en el funcionamiento del cerebro humano. Construyen una red de unidades de cómputo, nodos o neuronas. En una red típica, existen tres capas de nodos: primero, la capa de entrada, la capa media o capa oculta, y las capas de salida. La Figura 5-6 muestra un ejemplo de red neuronal de tres capas.




Figura 5-6. Ejemplo de red neuronal.

El desarrollo de una red neuronal se lleva a cabo en dos pasos: entrenamiento y testeo. Durante el entrenamiento, se le pasa como entrada una serie de ejemplos del conjunto de datos de entrenamiento. Durante el entrenamiento se le muestran los ejemplos a la red neuronal de forma iterativa. En cada iteración, la red neuronal predice la respuesta. En la fase de propagación del entrenamiento, cada nodo de la capa oculta y de salida calcula una suma ponderada de sus entradas, y entonces, a partir de esta suma calcula su salida a través de una función de activación. La salida de cada neurona en la red neuronal utiliza a menudo la siguiente función de activación, llamada función sigmoide:

$$f(x) = \frac{1}{1 + e^{-x}}$$

Existen otras funciones de activación que se pueden utilizar en redes neuronales, como la función gaussiana.

Si existen M nodos de entrada, los pesos de cada conexión entre los nodos de entrada y la primera capa oculta se denotan por w^{1ij} . Para cada nodo oculto la suma ponderada se calcula a través de la siguiente fórmula:

$$S_j = \sum_{i=0}^{M-1} (x_i w^{1ij})$$

Tanto los árboles de decisión como las redes neuronales pueden ser utilizados tanto para regresión como para clasificación, la regresión predice valores numéricos, y la clasificación permite predecir otro tipo de valores como booleanos o cadenas de caracteres.

Azure Machine Learning ofrece una amplia gama de algoritmos de clasificación que permiten entrenar el modelo, el algoritmo a seleccionar depende principalmente de dos factores:

- El uso de los datos, cual es el objetivo de negocio al que se desea dar respuesta aprendiendo de datos pasados.
- Cuál es la precisión, el tiempo de entrenamiento, el número de parámetros y el número de características que admite la solución.

La Figura 5-7 muestra un esquema que resume el proceso de selección de un algoritmo para el entrenamiento de un modelo en Azure Machine Learning y en la Tabla 5-2 se muestran las características de los algoritmos utilizados en el presente TFM y la estrategia que se ha entrenado utilizando cada uno de ellos.

La principal desventaja de las tablas de decisión es que hacen un uso muy elevado de la memoria en comparación con las redes neuronales. Por otra parte, las tablas de decisión mejoran enormemente la precisión respecto a las redes neuronales.

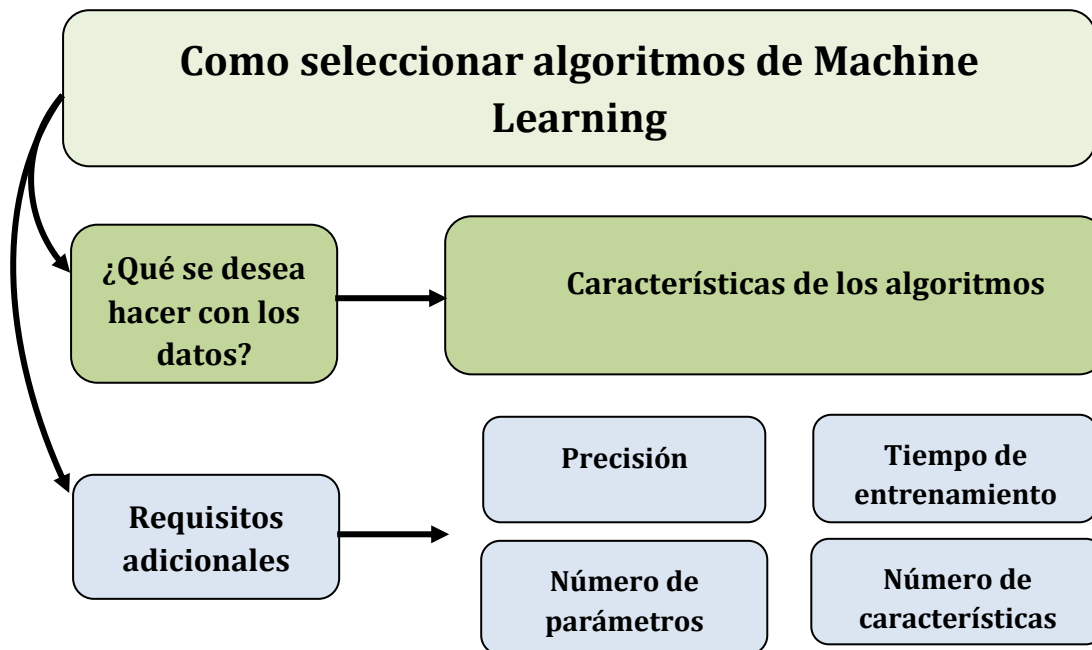


Figura 5-7. Proceso de selección de algoritmo de entrenamiento.

Algoritmo	Precisión	Tiempo de entrenamiento	Parámetros	Notas	Experimento asociado
Árbol de decisión ampliado de dos clases	Excelente	Moderado	5	Gran uso de memoria	Estrategia basada en posición de precios y medias móviles
Bosque de decisión de dos clases	Excelente	Moderado	6	Bloqueo de subprocesos en las predicciones de árbol acumuladas	
Red neuronal de dos clases	Bueno	Moderado	8		
Árbol de decisión ampliado multiclase	Excelente	Moderado	6	Tiende a mejorar la precisión a pesar de correr el riesgo de tener menor cobertura	Estrategias basadas en combinación de tres medias móviles y emociones surgidas de noticias
Bosque de decisión multiclase	Excelente	Moderado			
Red neuronal dos clases/multiclase	Bueno	Moderado	8		

Tabla 5-2. Comparativa de algoritmos de Azure Machine Learning.

A continuación, se explicará en detalle, para cada uno de los experimentos realizados, que descriptores han sido utilizados y cuales han sido los resultados obtenidos tras el entrenamiento del modelo en la fase de evaluación, así como el algoritmo que ofrece la mejor precisión.

5.1. Experimento basado en estrategias de posición de precios y medias móviles.

Para realizar este experimento, se ha seguido el esquema mostrado en la Figura 5-4. La Figura 3-12 muestra un gráfico de velas japonesas en el que se observa la posición de las distintas medias móviles utilizadas en esta estrategia, también se tiene en cuenta la posición del precio de cierre con respecto a cada media móvil.

Los descriptores utilizados para entrenar el modelo asociado a esta estrategia han sido los siguientes:

- **pos_ma20ma200**: posición de la media móvil de 20 con respecto a la media móvil de 200. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que la media móvil de 20 puede estar encima o debajo de la media móvil de 200.
- **pos_ma20ma50**: posición de la media móvil de 20 con respecto a la media móvil de 50. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que la media móvil de 20 puede estar encima o debajo de la media móvil de 50.
- **pos_ma50ma200**: posición de la media móvil de 50 con respecto a la media móvil de 200. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que la media móvil de 50 puede estar encima o debajo de la media móvil de 200.
- **pos_price_ma20**: posición del precio de cierre respecto de la media móvil de 20. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que el precio de cierre puede estar encima o debajo de la media móvil de 20.
- **pos_price_ma50**: posición del precio de cierre respecto de la media móvil de 50. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que el precio de cierre puede estar encima o debajo de la media móvil de 50.
- **pos_price_ma200**: posición del precio de cierre respecto de la media móvil de 200. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que el precio de cierre puede estar encima o debajo de la media móvil de 200.

El valor a predecir es la subida o bajada del precio de cierre con respecto al precio de cierre del día anterior:

- **price_behavior**: Los valores posibles pueden ser {**RISE, DROP**} indicando que el precio de cierre del día actual puede estar por encima del precio de cierre del día anterior (**RISE**), lo cual significa que ese día se pudo realizar una operación de compra; o que el precio de cierre del día actual puede estar por debajo del precio de cierre del día anterior, es decir que ese día se pudo realizar una operación de venta.

Como solamente existen dos valores a predecir, se han utilizado algoritmos de clasificación de dos clases.

5. Experimentación y resultados.

Después de realizar el entrenamiento con estos valores, se generan los resultados en una tabla dentro del módulo 'Evaluate Model' mostrado en la Figura 5-4. Estos resultados se muestran en la Tabla 5-3 utilizando el algoritmo 'Árbol de Decisión Ampliado de dos clases', en la Tabla 5-4 utilizando el algoritmo 'Bosque de Decisión de dos clases' y en la Tabla 5-5 utilizando el algoritmo 'Red neuronal de dos clases'.

	DROP	RISE
DROP	746	717
RISE	1609	1671

Tabla 5-3. Resultados utilizando algoritmo Árbol de Decisión Ampliado de Dos Clases.

	DROP	RISE
DROP	737	700
RISE	1618	1688

Tabla 5-4. Resultados utilizando algoritmo Bosque de Decisión de Dos Clases

	DROP	RISE
DROP	750	717
RISE	1605	1671

Tabla 5-5. Resultados utilizando algoritmo Red Neuronal de Dos Clases

La exactitud de estos modelos representa la proporción de las predicciones reales con respecto al número total de predicciones. Y se calcula a través de la siguiente fórmula:

$$Exactitud = \frac{(PR + NR)}{(PR + NR + FP + FN)}$$

Donde PR = Positivos reales, NR = Negativos reales, FP = Falsos positivos y FN = Falsos negativos.

Los resultados son muy parecidos en cada algoritmo y la exactitud de cada uno es la siguiente:

- Algoritmo Árbol de Decisión de Dos Clases: 0,5
- Algoritmo Bosque de Decisión de Dos Clases: 0,511
- Algoritmo Red Neuronal de Dos Clases: 0,51

Para que un modelo se considere válido debe tener una exactitud de más de un 50%.

El valor de predicción positiva o precisión es la proporción de casos positivos que el modelo ha identificado correctamente, y se calcula a través de la siguiente fórmula:

$$\text{Precisión} = \frac{PR}{PR + FP}$$

La precisión resultante aplicando cada uno de los algoritmos es la siguiente:

- Algoritmo Árbol de Decisión Ampliado de Dos Clases: 0,509
- Algoritmo Bosque de Decisión de Dos Clases: 0,511
- Algoritmo Red Neuronal de Dos Clases: 0,51

Para poder tomar una decisión sobre que algoritmo elegir es necesario confiar en estas métricas, por tanto, se ha decidido desplegar un modelo entrenado con el algoritmo red neuronal de dos clases.

5.2. Experimento basado en estrategias de tres medias móviles.

Este experimento está basado en la estrategia explicada en el [apartado 3.2.2](#). Al igual que el experimento anterior, se ha basado en el esquema mostrado en la Figura 5-4.

Los descriptores utilizados para entrenar el modelo han sido los siguientes:

- ***pos_ma20ma200***: posición de la media móvil de 20 con respecto a la media móvil de 200. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que la media móvil de 20 puede estar encima o debajo de la media móvil de 200.
- ***pos_ma20ma50***: posición de la media móvil de 20 con respecto a la media móvil de 50. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que la media móvil de 20 puede estar encima o debajo de la media móvil de 50.
- ***pos_ma50ma200***: posición de la media móvil de 50 con respecto a la media móvil de 200. Los valores posibles pueden ser {**ABOVE, BELOW**} indicando que la media móvil de 50 puede estar encima o debajo de la media móvil de 200.

La clase a predecir es un posible momento de compra o venta, o un valor neutral, que significa que no se debe realizar una operación. El valor de predicción ha sido obtenido aplicando la estrategia de manera programática a lo largo de varios días y con distintos activos (Microsoft, Tesla, Bayer y Amazon).

- ***three_ma_strategy_operation***: representa un momento de compra, venta o neutral aplicando la estrategia de tres medias móviles. Se considera que existe un momento de compra cuando la media móvil de 20 está encima de la media móvil de 50, y la media móvil de 50 se sitúa por encima de la media móvil de 200; y se considera que existe un momento de venta si la media móvil de 20 se sitúa por debajo de la media móvil de 50, y la media móvil de 50 está encima de la media móvil de 200. En cualquier otro caso se considera operación neutral. Los valores posibles pueden ser {**BUY, SELL, NEUTRAL**}.

5. Experimentación y resultados.

Para predecir esta clase se han aplicado algoritmos de clasificación multiclase.

Tras realizar el entrenamiento del modelo con estos valores, se generan los resultados en una tabla de decisión dentro del módulo 'Evaluate Model' mostrado en la Figura 5-3. Estos resultados se muestran en la matriz de decisión de la Tabla 5-6 utilizando el algoritmo 'Árbol de decisión ampliado multiclase', en la matriz de decisión de la Tabla 5-7 utilizando el algoritmo 'Bosque de decisión multiclase' y en la matriz de decisión de la Tabla 5-8 utilizando el algoritmo 'Red neuronal multiclase'.

BUY	100%	0.0%	0.0%
NEUTRAL	31.5%	54.3%	14.2%
SELL	0.0%	0.0%	100%

Tabla 5-6. Matriz de decisión usando algoritmo Árbol de Decisión Ampliado Multiclase

BUY	100%	0.0%	0.0%
NEUTRAL	31.4%	53.9%	14.6%
SELL	0.0%	0.0%	100%

Tabla 5-7. Matriz de decisión usando algoritmo Bosque de Decisión Multiclase

BUY	100%	0.0%	0.0%
NEUTRAL	31.5%	53.9%	14.6%
SELL	0.0%	0.0%	100%

Tabla 5-8. Matriz de decisión usando algoritmo Red Neuronal Multiclase

En este caso, para medir la exactitud del modelo de predicción hay que basarse en las distintas matrices de decisión, en cada caso la exactitud es superior a los resultados arrojados por la estrategia mostrada en el [apartado 5.1](#), ya que se aciertan los momentos de compra y venta un 100% de las veces, también ha disminuido la proporción de falsos positivos y falsos negativos, ya que en el caso anterior era de un 50%, y en este caso se ha reducido hasta un 19,5% en el caso de falsos positivos y hasta un 35,8% en el caso de falsos negativos.

Esto se debe a que se ha incluido una nueva clase neutral, que reduce el número de operaciones realizadas con esta estrategia, y esto hace que se reduzcan también los casos fallidos, aumentando los casos exitosos, ya que en los momentos en los que nuestro modelo predice que el valor es neutral no se puede operar. Además, se está utilizando una estrategia basada en medias móviles, lo cual también aumenta la probabilidad de éxito, como se explica en el [apartado 3.2](#), ya que las medias móviles ayudan a detectar tendencias alcistas, neutrales o bajistas.

En este caso se ha elegido el modelo entrenado con el algoritmo de decisión multiclase, ya que la exactitud es superior a los demás algoritmos.

5.3. Experimento basado en emociones surgidas de noticias.

Este experimento está basado en el análisis de emociones surgidas de noticias, explicado en profundidad en el [apartado 3.3](#), y al igual que los experimentos mostrados en los [apartados 5.1](#) y [5.2](#) se ha basado en el esquema mostrado en la Figura 5-4.

En este caso solamente se ha utilizado un descriptor para entrenar el modelo:

- **emotion**: representa la emoción surgida de un conjunto de noticias en un día concreto. Los valores posibles pueden ser {**POSITIVE, NEUTRAL, NEGATIVE**} indicando que el conjunto de noticias sobre una compañía y en ese día concreto en general han sido positivas, neutrales o negativas.

La clase a predecir es un posible momento de compra o venta, o un valor neutral, que significa que no se debe realizar una operación. El valor de predicción ha sido obtenido aplicando la estrategia de manera programática a lo largo de varios días y con distintos activos (Microsoft, Tesla, Bayer y Amazon).

- **emotion_operation_type**: representa un momento de compra, venta o neutral basado en las emociones surgidas de noticias en ese día. Por ejemplo, hoy se han emitido un conjunto de noticias relacionadas con Apple de las cuales 50 son negativas, y 20 son positivas, por tanto, en general, la emoción asociada a estas noticias es negativa, y el tipo de operación será de venta, ya que el precio de Apple bajará. Los valores posibles pueden ser {**BUY, SELL, NEUTRAL**}.

Para predecir esta clase se han aplicado algoritmos de clasificación multiclase.

Tras realizar el entrenamiento del modelo con estos valores, se generan los resultados en una tabla de decisión dentro del módulo 'Evaluate Model' mostrado en la Figura 5-4. Estos resultados se muestran en la matriz de decisión de la Tabla 5-9 utilizando el algoritmo 'Árbol de decisión ampliado multiclase', en la matriz de decisión de la Tabla 5-10 utilizando el algoritmo 'Bosque de decisión multiclase' y en la matriz de decisión de la Tabla 5-11 utilizando el algoritmo 'Red neuronal multiclase'.

5. Experimentación y resultados.

BUY	100%	0.0%	0.0%
NEUTRAL	3.2%	96.2%	0.7%
SELL	0.0%	0.0%	100%

Tabla 5-9. Matriz de decisión usando algoritmo Árbol de Decisión Ampliado Multiclase.

BUY	100%	0.0%	0.0%
NEUTRAL	3.2%	96.2%	0.7%
SELL	0.0%	0.0%	100%

Tabla 5-10. Matriz de decisión usando algoritmo Bosque de Decisión Multiclase.

BUY	100%	0.0%	0.0%
NEUTRAL	3.2%	96.2%	0.7%
SELL	0.0%	0.0%	100%

Tabla 5-11. Matriz de decisión usando algoritmo Red Neuronal Multiclase.

La exactitud arrojada por los resultados en este caso es superior a los resultados de la estrategia explicada en el [apartado 5.2](#), y muy superior a los resultados arrojados por la estrategia del [apartado 5.1](#), ya que se aciertan los momentos de compra y venta un 100% de las veces, y disminuye muy notablemente el porcentaje de falsos positivos y falsos negativos, reduciéndose hasta un 28,3% en el caso de falsos positivos y hasta un 13,5% en el caso de falsos negativos.

Esta reducción en el porcentaje de casos fallidos se debe a que se está utilizando un solo descriptor para predecir los momentos de compra o venta, lo que reduce aún más el número de operaciones que se pueden realizar.

La Tabla 5-12 muestra la exactitud obtenida en los resultados de los distintos experimentos llevados a cabo en los [apartados 5.1](#), [5.2](#) y [5.3](#), realizando una comparativa de las distintas estrategias utilizadas. En el caso de la estrategia basada en la posición de las medias móviles y los precios no se contempla la clase neutral, solamente compra (RISE) o venta (DROP).

	BUY	NEUTRAL	SELL
Estrategia basada en posición de medias móviles y precios	51%	N/A	49%
Estrategia basada en tres medias móviles	100%	54.3%	100%
Estrategia basada en emociones	100%	96.2%	100%

Tabla 5-12. Comparativa de precisión en cada estrategia utilizada.

La estrategia basada en emociones ofrece una mayor exactitud que las demás, ya que disminuye el porcentaje de casos fallidos. Aunque, con el objetivo de demostrar la eficacia de los distintos modelos de predicción, se han realizado pruebas a través del analizador de tendencias desarrollado como endpoint de la API Market Emotions, cuya implementación se explica con mayor detalle en el [apartado 4.1](#).

Los algoritmos utilizados para entrenar los modelos desarrollados han sido la red neuronal de dos clases, que ha servido para predecir momentos de compra o venta utilizando la estrategia basada en la posición de los precios y las medias móviles, y la red neuronal multiclasa para predecir momentos de compra o venta utilizando las estrategias basadas en emociones surgidas de noticias y la de tres medias móviles.

5.4. Resultados.

En el presente apartado se comentan los resultados de la experimentación realizada con el analizador de tendencias. Debido a la diversidad de activos disponibles, estos experimentos se han aplicado en activos de distintos sectores, y que sean diferentes a aquellos que se han utilizado para realizar el entrenamiento de los modelos de predicción (Microsoft, Tesla, Amazon y Bayer).

Por tanto, para realizar la experimentación se ha realizado diversos análisis de tendencias sobre los activos **Walmart Stores** (WMT), **Google** (GOOGL) y **Disney** (DIS) desde **marzo de 2019 hasta diciembre de 2020**.

La compañía Walmart Stores opera varias cadenas de grandes almacenes de descuento y es el mayor minorista de ultramarinos de los Estados Unidos. Google ofrece productos y servicios en el sector de las tecnologías de la información. Disney es la compañía de entretenimiento más grande del mundo.

Para cada uno de los activos, se han obtenido las ganancias resultantes de aplicar el analizador de tendencias, aplicando cada uno de los modelos entrenados en los apartados [5.1](#), [5.2](#) y [5.3](#), y una combinación de los resultados generados por los modelos que aplican la estrategia de tres medias móviles y las emociones surgidas de las noticias. Todo ello con el objetivo de reducir el riesgo de

5. Experimentación y resultados.

operar en un periodo de alta volatilidad (alta incertidumbre), como puede ser el año 2020, en el que se declaró la pandemia de coronavirus.

Para generar los gráficos de resultados se ha utilizado la herramienta *gnuplot*⁶, la cual permite a través de comandos en Linux, la generación de cualquier tipo de gráfico y su exportación a un formato imagen o PDF.

Primero, se muestran los datos asociados al activo Walmart durante el año 2019, los cuales se pueden ver en la Tabla 5.13.

PROFIT/LOSS

	MONTH	MA-PRICE- POS	THREE- MA	NEWS- EMOTIONS	THREE-MA-AND-NEWS- EMOTIONS
03/19	3	-0,81	-0,81	-0,87	-0,38
04/19	4	3,82	3,82	2,61	2,61
05/19	5	0,81	0,81	-0,92	-0,92
06/19	6	7,98	7,98	6,62	6,62
07/19	7	1,3	1,3	1,02	0,35
08/19	8	4,29	3,02	7,46	7,98
09/19	9	3,32	3,24	-0,3	1,4
10/19	10	0,21	0,21	-0,35	-0,35
11/19	11	0,96	0,96	0,91	0,91
12/19	12	0,25	0,25	1,13	1,13

Tabla 5-13. Ganancia de Walmart en 2019 aplicando cada estrategia.

PROFIT/LOSS

	MONTH	MA-PRICE- POS	THREE- MA	NEWS- EMOTIONS	THREE-MA-AND-NEWS- EMOTIONS
01/20	1	-1,98	-2,32	-3,04	-2,38
02/20	2	-3,38	0	-7,28	0
03/20	3	-3,22	0	-12,3	0
04/20	4	3,03	-4,95	11,91	2,6
05/20	5	0,62	0,62	0,11	0,11
06/20	6	-3,95	-2,25	-1,63	-0,79
07/20	7	8,71	-1,22	1,82	-1,22
08/20	8	8,5	8,5	5,01	5,01
09/20	9	-7,08	-7,08	-4,6	-4,6
10/20	10	-2,2	-2,2	-3,47	-3,47
11/20	11	7,97	7,97	6,33	6,33
12/20	12	-5,54	-5,54	-5,17	-3,79

Tabla 5-14. Ganancia de Walmart en 2020 aplicando cada estrategia.

⁶ <http://www.gnuplot.info/>

La Figura 5-8 muestra la ganancia resultante de las estrategias aplicadas, siendo junio y agosto los periodos donde se registran mayores beneficios. En el caso de junio un 7,98% de beneficio aplicando las estrategias basadas en tres medias móviles y la estrategia basada en las posiciones de los precios y las medias móviles.

En agosto se registra un 7,46% de beneficio aplicando la estrategia basada en emociones de mercado y un 7,98% de beneficio aplicando la estrategia combinando tres medias móviles y emociones de noticias.

La Figura 5-9 muestra la ganancia registrada en 2020 para Walmart, y los datos asociados se pueden ver en la Tabla 5-14. En este caso se registra una mayor volatilidad, ya que existen pérdidas y hay varias estrategias que fallan, registrándose la mayor pérdida en marzo de 2020 si se aplicase la estrategia que se basa en las emociones surgidas de noticias. Esto se debe a que en este periodo existe una gran incertidumbre entre compradores y vendedores, y esto hace que el mercado no se mueva en una dirección concreta y sea más difícil de predecir aplicando cualquier estrategia.

En este periodo de incertidumbre siempre es más seguro aplicar dos estrategias combinadas, ya que si ambas se ponen de acuerdo hay una mayor probabilidad de éxito. No obstante, la combinación de estrategias ofrece menos oportunidades de operar que las demás, solamente se debe usar para reducir el riesgo en periodos de alta volatilidad. La incertidumbre viene desencadenada por un evento, en este caso, la pandemia de Coronavirus.

La mínima pérdida total durante este año viene dada por la combinación de la estrategia de tres medias móviles y la estrategia basada en emociones surgidas de noticias.

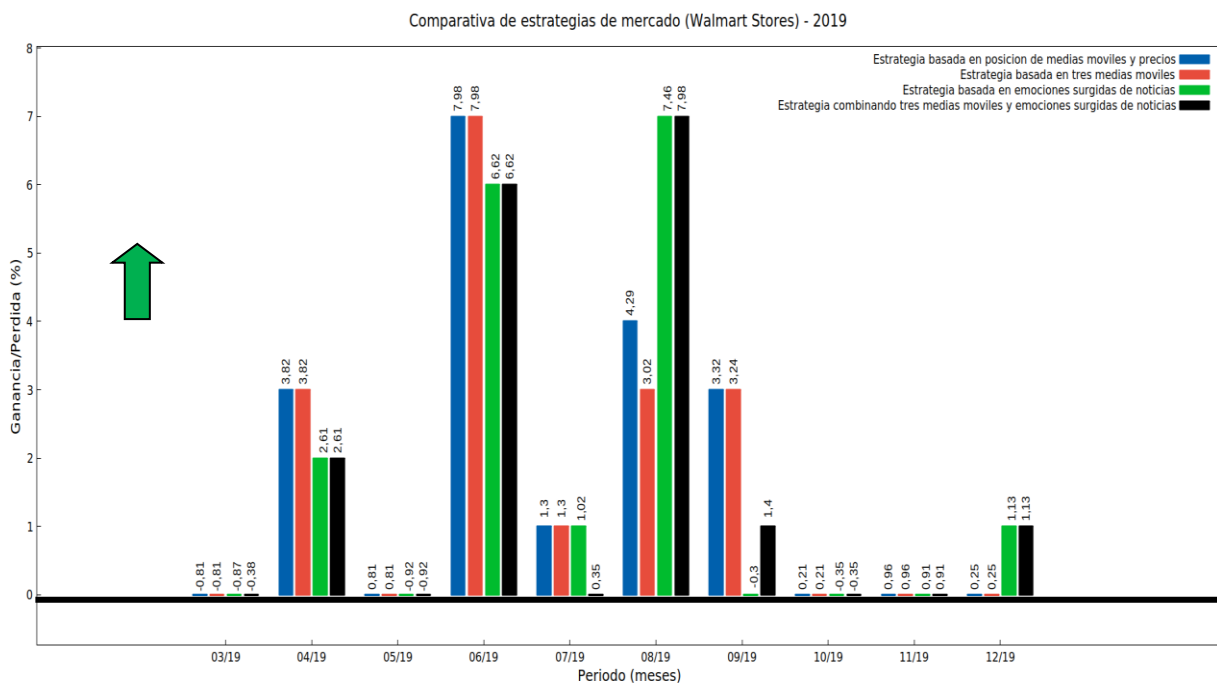


Figura 5-8. Análisis de tendencias de Walmart en 2019.

5. Experimentación y resultados.

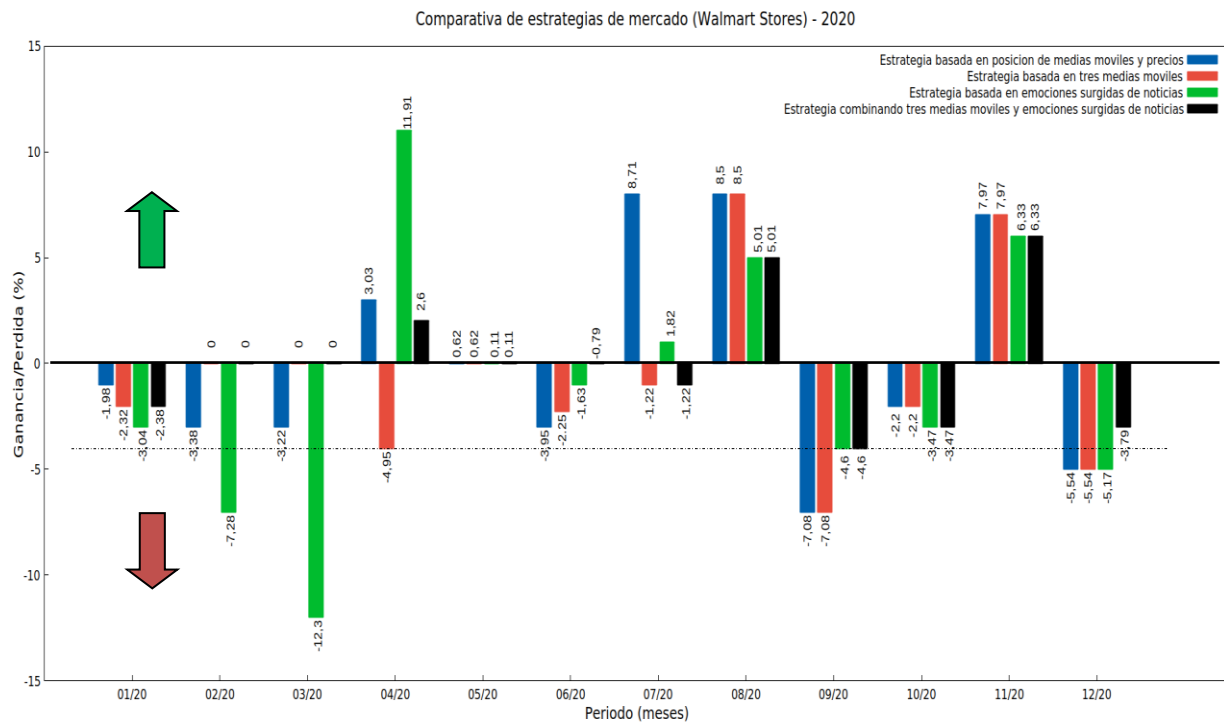


Figura 5-9. Análisis de tendencias de Walmart en 2020.

A continuación, se comentan los resultados obtenidos para el activo Google, los datos asociados a 2019 se pueden ver en la Tabla 5-15. La Figura 5-10 muestra pérdidas cercanas al 10% en los meses de mayo y julio de 2019 aplicando la estrategia basada en medias móviles y precios. Esta estrategia puede ser muy arriesgada, ya que siempre toma la decisión de comprar o vender y no existen tendencias neutrales. Al aplicar la estrategia basada en emociones, se detectan pérdidas en los meses de junio y septiembre, pero que se ven compensadas por las ganancias obtenidas los meses de abril y julio. Al igual que en el caso de Walmart en 2020, la menor pérdida en este caso, y por ende la reducción del riesgo asociado viene dada por la combinación de estrategias.

PROFIT/LOSS

	MONTH	MA-PRICE-POS	THREE-MA	NEWS-EMOTIONS	THREE-MA-AND-NEWS-EMOTIONS
03/19	3	0,16	0	1,74	0
04/19	4	8,1	8,1	7,97	7,97
05/19	5	-9,46	-2,44	-2,51	0,8
06/19	6	-3,51	0	-5,21	0
07/19	7	-9,94	1,1	4,01	0,17
08/19	8	5,03	0,44	-0,1	0,6
09/19	9	4,82	4,82	-6,11	
10/19	10	4,53	4,53	8,99	-1,16
11/19	11	3,13	3,13	0,95	-0,12
12/19	12	3,94	3,94	0,88	3,65

Tabla 5-15. Ganancia de Google en 2019 aplicando cada estrategia.

PROFIT/LOSS

	MONTH	MA-PRICE-POS	THREE-MA	NEWS-EMOTIONS	THREE-MA-AND-NEWS-EMOTIONS
01/20	1	6,25	6,25	0,66	0,66
02/20	2	-11,3	-11,3	9,29	-5,04
03/20	3	-10,29	-8,01	-3,59	-8,01
04/20	4	-12,04	-9,98	16,25	0
05/20	5	-7,11	0	3,53	0
06/20	6	-5,79	-3,78	-5,38	-5,34
07/20	7	6,68	6,68	-2,04	1,23
08/20	8	10,56	10,56	6,78	9,33
09/20	9	-11,42	-11,86	-4,21	-4,86
10/20	10	4,63	0	-7,42	0
11/20	11	10,01	10,01	3,45	5,82
12/20	12	-3,29	-3,29	4,09	-0,27

Tabla 5-16. Ganancia de Google en 2020 aplicando cada estrategia.

La Tabla 5-16 muestra los resultados asociados a Google en el año 2020 y la gráfica asociada se muestra en la Figura 5-11. Durante el mes de abril se registra una ganancia de un 16,25% empleando la estrategia basada en emociones, lo cual prueba su eficacia en los momentos en los que la estrategia de tres medias móviles no es capaz de detectar una tendencia.

En este caso, la menor pérdida viene dada por el uso de la estrategia basada en emociones surgidas de noticias.




Figura 5-10. Análisis de tendencias de Google en 2019.

5. Experimentación y resultados.

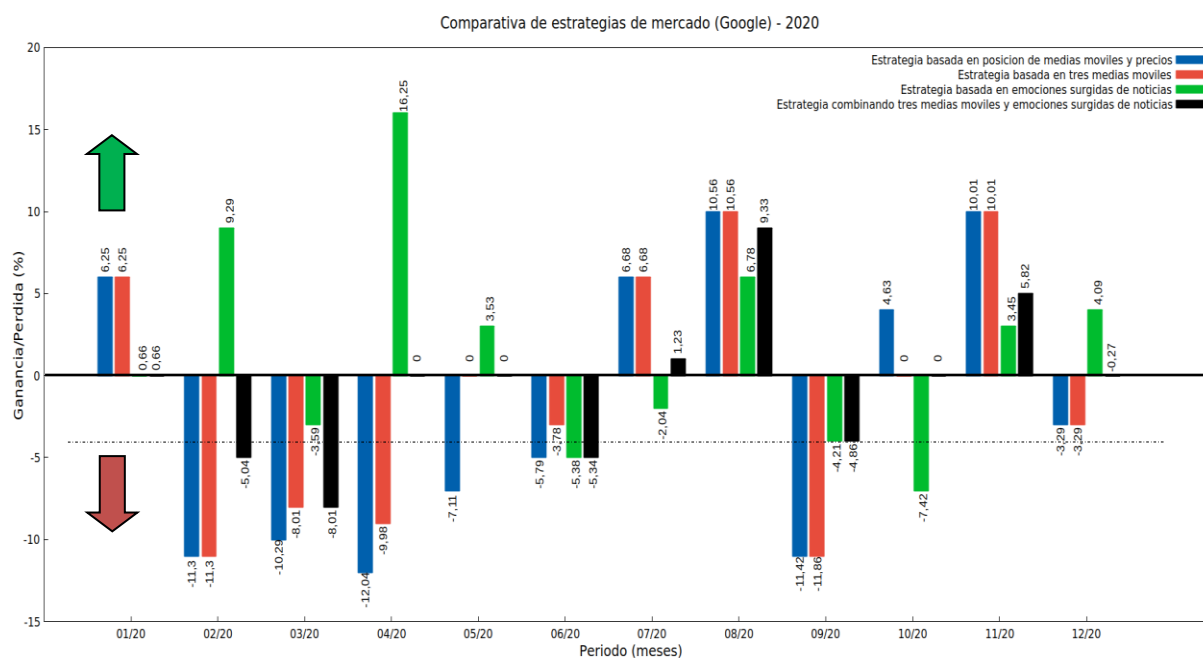


Figura 5-11. Análisis de tendencias de Google en 2020.

Finalmente, se comentarán los resultados asociados al activo Disney, los cuales representan los porcentajes de ganancia obtenidos a través aplicando el analizador de tendencias al activo Disney. La Tabla 5-17 muestra los resultados obtenidos en el año 2019, y la Tabla 5-18 muestra los obtenidos en el año 2020.

PROFIT/LOSS

	MONTH	MA-PRICE-POS	THREE-MA	NEWS-EMOTIONS	THREE-MA-AND-NEWS-EMOTIONS
03/19	3	-5,58	-2,89	-0,88	-1,79
04/19	4	23,81	5,5	23,81	5,5
05/19	5	-3,06	-3,06	-0,85	-0,85
06/19	6	5,15	5,15	5,91	5,91
07/19	7	2,31	2,31	0,27	0,27
08/19	8	-2,82	-4,68	5,05	1,14
09/19	9	-4,65	0	-0,41	0
10/19	10	0,03	0	-2,32	0
11/19	11	14,1	2,94	13,94	3,95
12/19	12	-4,54	-4,54	-2,62	-2,62

Tabla 5-17. Ganancia de Disney en 2019 aplicando cada estrategia.

PROFIT/LOSS

	MONTH	MA-PRICE-POS	THREE-MA	NEWS-EMOTIONS	THREE-MA-AND-NEWS-EMOTIONS	
	01/20	1	-5,34	-2,82	-5,23	-2,69
	02/20	2	-4,78	0	5,07	0
	03/20	3	2,23	11,68	38,89	21,71
	04/20	4	1,03	-15,43	-0,28	-3,76
	05/20	5	-0,79	4,57	-15,23	2,27
	06/20	6	-3,97	0	-10,25	0
	07/20	7	-1,61	3,25	3,03	1,2
	08/20	8	-5,04	-0,8	-4,53	-0,8
	09/20	9	-4,57	-5,86	-5,17	-5,02
	10/20	10	-1,43	-0,32	-2,33	1,63
	11/20	11	22,47	6,33	10,5	6,72
	12/20	12	21,23	21,23	21,23	21,23

Tabla 5-18. Ganancia de Disney en 2020 aplicando cada estrategia.

La Figura 5-12 muestra que aplicando las estrategias basadas en emociones y la estrategia que utiliza la posición de las medias móviles y el precio los beneficios totales obtenidos durante el año 2019 son muy superiores a las pérdidas. Si se aplica la estrategia basada en tres medias móviles o la combinación de la estrategia basada en tres medias móviles y la estrategia basada en emociones se registran menos tendencias, y por tanto, se registran también menos beneficios. Esta combinación solamente debe utilizarse durante aquellos periodos de mucha incertidumbre en el mercado.

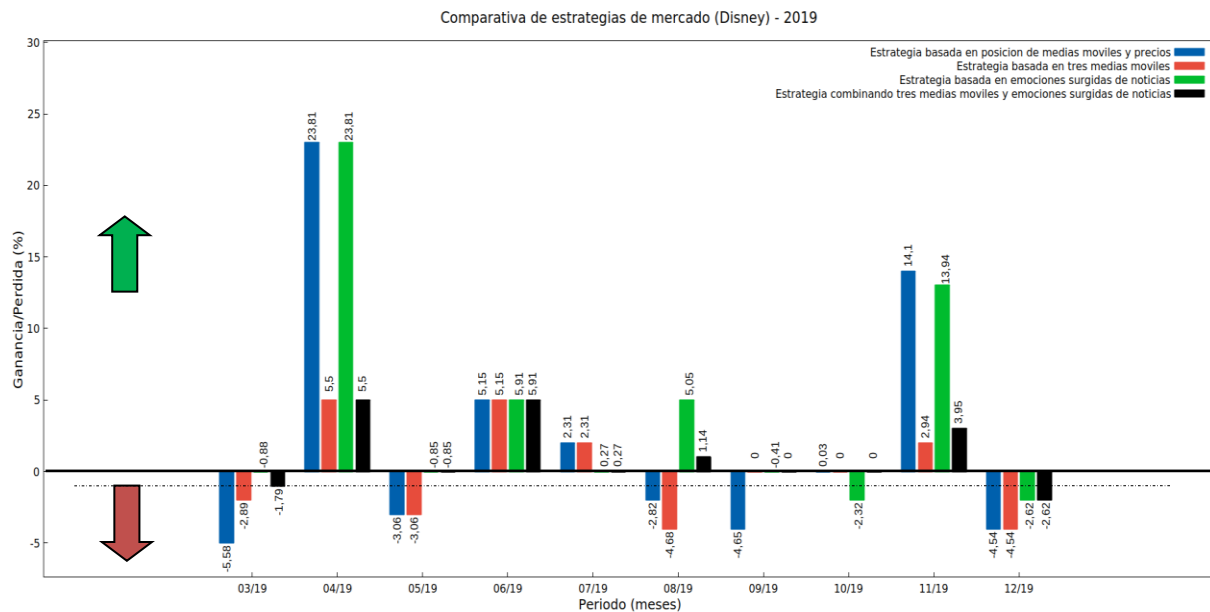


Figura 5-12. Análisis de tendencias de Disney en 2019.

5. Experimentación y resultados.

Durante el año 2020, mostrado en la Figura 5-13, el analizador de tendencias registra una pérdida del 15,43% aplicando la estrategia basada en tres medias móviles durante el mes de abril, y pérdidas del 15,23% y el 10,25% durante los meses de abril y junio aplicando la estrategia basada en emociones. El resto de meses no se aprecian pérdidas tan significativas, y además se aprecia un beneficio del 38,89% aplicando la estrategia basada en emociones durante el mes de marzo, lo cual refuerza la eficacia de esta técnica. No obstante, en este periodo, aun habiéndose obtenido este potencial beneficio, se recomienda la combinación de técnicas, ya que si fallase alguna de las estrategias la combinación con otra resultaría en una disminución del riesgo.

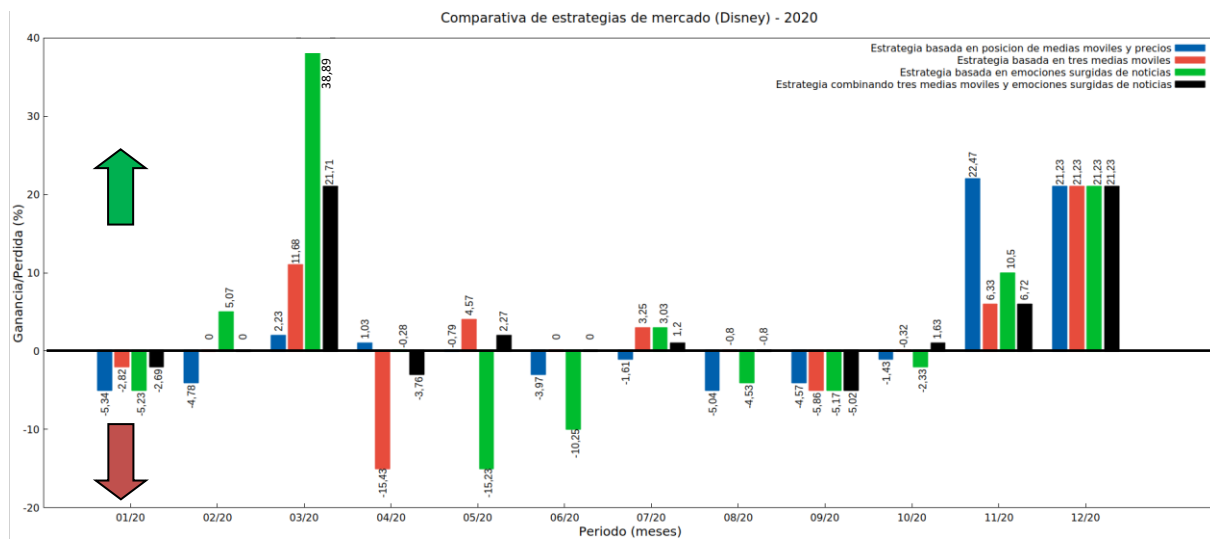


Figura 5-13. Análisis de tendencias de Disney en 2020.

Con el objetivo de realizar una comparativa más fiable para cada uno de los activos que se han analizado, se muestra a continuación el total de ganancia por operación de los años 2019 y 2020, el cual se ha calculado de la siguiente manera:

$$Ganancia/operación = \frac{Ganancia\ total\ obtenida\ durante\ un\ año}{N^{\circ}\ de\ operaciones\ realizadas\ durante\ un\ año}$$

La Figura 5-14 muestra la ganancia por operación para los activos de Walmart, Google y Disney recogidos durante el año 2019. Durante este año no se registraron pérdidas debido a que no hubo una alta volatilidad en el mercado. Las mayores ganancias se obtuvieron a través de la estrategia basada en la posición de precios y medias móviles y la estrategia de tres medias móviles.

Por último, en la Figura 5-15 se recoge el total de ganancia por operación realizada para cada activo durante el año 2020. El mayor porcentaje de beneficio por operación es el registrado por Disney, con un 2,18% de ganancia por operación aplicando la estrategia basada en tres medias móviles. No obstante, esta misma estrategia no funciona en el activo Google, con una pérdida de un 1,63% por operación realizada. Debido a la alta incertidumbre registrada, la única estrategia que permite obtener beneficio y no registra pérdidas es la estrategia combinada de tres medias móviles y emociones surgidas de noticias.




Figura 5-14. Ganancia por operación realizada en 2019.

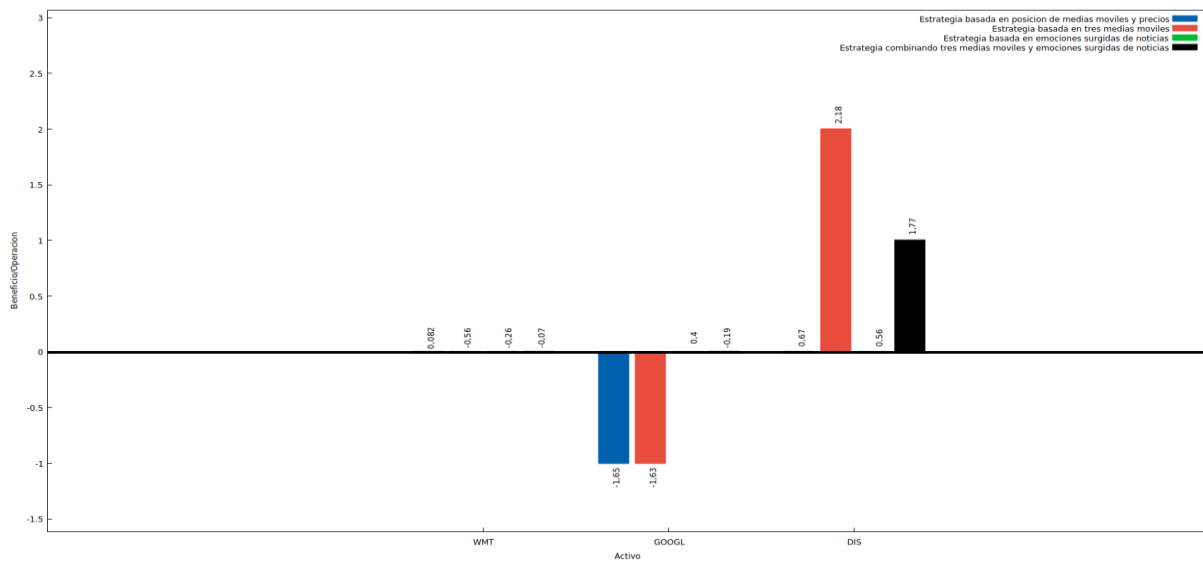


Figura 5-15. Ganancia total anual por activo.

Capítulo 6. Conclusiones y trabajo futuro.

Este es el último capítulo de la presente memoria, el cual muestra al lector las conclusiones que se han obtenido de la realización de este trabajo, así como las propuestas futuras que se pretenden realizar para ampliar la funcionalidad de la aplicación aquí propuesta.

6.1. Conclusiones.

En este trabajo se ha presentado una API que permite analizar tendencias de mercado que han ocurrido en el pasado basándose en estrategias relacionadas con el indicador de medias móviles, el cual proviene del análisis técnico, y se propone un nuevo indicador relacionado con las emociones que surgen de las noticias que se emiten diariamente. También permite obtener los indicadores de la fecha actual relacionados con las estrategias mencionadas.

Se concluye que, en el periodo de 2019, donde se registra una menor volatilidad, esto es, una menor incertidumbre entre compradores y vendedores, la aplicación de cualquier estrategia supone un riesgo controlado, excepto en la estrategia que utiliza la posición de los precios y las medias móviles, ya que esta estrategia debe tomar siempre una decisión de compra o venta, y no detecta periodos neutrales, por lo que es más arriesgada. Las demás estrategias, al detectar tendencias neutrales, no detectan tantos momentos de compra o venta, y por ello, a pesar de obtener un menor beneficio, permiten gestionar mejor el riesgo, ya que se controlarían mejor las pérdidas.

Si se decide utilizar la estrategia basada en emociones, se detectarán más tendencias de compra o venta, ya que las emociones influyen enormemente en el mercado.

En un periodo de mayor volatilidad, como el año 2020, se debe gestionar mejor el riesgo derivado de la incertidumbre, y por ello, se requiere combinar dos estrategias como son la estrategia de tres medias móviles y la estrategia basada en emociones, esto hará que se gestione mejor el riesgo, pero a costa de obtener un beneficio menor.

Los estudios realizados demuestran que el nuevo indicador basado en emociones ofrece resultados prometedores, sobre todo en periodos donde no existe una alta incertidumbre.

6.2. Ampliaciones futuras.

Como ampliaciones futuras se propone la ampliación del analizador de tendencias, añadiéndole varios rankings que permitan detectar aquellos activos que en un día concreto tienen más probabilidades de subir o bajar según una estrategia. Por ejemplo, que activos tienen más probabilidades de subir si se opera bajo una estrategia basada en emociones surgidas de noticias. Igualmente, se puede aplicar el analizador de tendencias a un bróker electrónico real para conocer el comportamiento de este analizador en condiciones reales y poder desarrollar un bot de trading

6. Conclusiones y trabajo futuro.

electrónico que permite operar de manera automática eligiendo una estrategia u otra según la volatilidad.

También es necesario, en la aplicación web, mostrar cada uno de los gráficos de velas japonesas asociados a las tendencias mostradas, e indicar de alguna forma (por ejemplo, a través de un color) que tipo de estrategia se está analizando en cada vela.

Bibliografía

- [1] Alphavantage API. Alphavantage Inc. URL: <https://www.alphavantage.co/documentation>. 2020.
- [2] V. Fontama. Introducing Microsoft Azure Machine Learning. In Berkeley, C.A, editor, *Predictive Analytics with Microsoft Azure Machine Learning 2nd Edition*, chapter 1, page 6. Apress. 2015.
- [3] S. Jansen. Market and Fundamental Data – Sources and Techniques. *Machine Learning for Algorithmic Trading*, chapter 2, paragraph 2. Packt Publishing. 2020.
- [4] S. Jansen. Market and Fundamental Data – Sources and Techniques. *Machine Learning for Algorithmic Trading*, chapter 3, paragraph 3. Packt Publishing. 2020.
- [5] D. Kotok. Stock Market Evolution. In Hoboken, N.J, editor, *Invest in Europe now: why Europe's markets will outperform the US in the coming years*, chapter 4, pages 54 - 58. Wiley. 2010.
- [6] E. Mike. Emotions, Emotional Intelligence, and the Trader. In Chichester, W.S, editor, *Financial Risk Taking: An Introduction to the Psychology of Trading and Behavioral Finance*, chapter 6, pages 170 - 176. John Wiley & Sons. 2004.
- [7] G. Mitra. News Data. In Chichester, editor, *The handbook of news analytics in finance*, chapter 1.2, pages 6 - 7. Wiley. 2011.
- [8] S. Mund. ML Studio Inside Out. In Birmingham, England, editor, *Microsoft Azure Machine Learning: explore analytics using step by step tutorials and build models to make prediction in a jiffy with a few mouse clicks*, chapter 2, paragraph 6. Packt Publishing. 2015.
- [9] R.V. Rajesh. Demystifying Microservices. In Birmingham, editor, *Spring microservices: build scalable microservices with Spring, Docker, and Mesos*, chapter 2, pages 12 - 17. Packt Publishing. 2016.
- [10] R. Rhoads. Working with Straightforward Single-Stick Patterns. In Hoboken, editor, *Candlestick Charting*, chapter 5, pages 74 - 79. John Wiley & Sons. 2008.
- [11] R. Rhoads. Getting to know Candlestick Charts. In Hoboken, editor, *Candlestick Charting*, chapter 2, pages 19 - 26. John Wiley & Sons. 2008.
- [12] B. Rockefeller. Introducing Technical Analysis. In Hoboken, editor, *Technical Analysis*, chapter 1, paragraph 1. For Dummies. 2020.
- [13] B. Rockefeller. Introducing Technical Analysis. In Hoboken, editor, *Technical Analysis*, chapter 2, paragraph 12. For Dummies. 2020.
- [14] A.B Schmidt. Technical Trading Strategies. In Hoboken, N.J, editor, *Financial Markets and Trading: An Introduction to market Microstructure and Trading Strategies*, chapter 10, pages 107 - 113. Wiley. 2011.

[15] Spring. Spring Cloud Config Server.

URL: https://cloud.spring.io/spring-cloud-config/multi/multi__spring_cloud_config_server.html.
2020.

[16] Stock News API. Snapi LLC. URL: <https://stocknewsapi.com/documentation>. 2020.

[17] M. Thomsett. Introducción. In Boston, editor, *Candlestick Charting: Profiting from Effective Stock Chart Analysis*, chapter 1, pages 31 - 32. De G Press. 2008.

[18] M. Thomsett. Spotting Trends and Using Trendlines. In Portland, editor, *Candlestick Charting: Profiting from Effective Stock Chart Analysis*, chapter 9, pages 252 - 253. De G Press. 2017.

[19] C. Walls. Creating REST APIs with Spring. In Breidenbach, R, editor, *Spring in Action*, chapter 16, pages 416 - 431. Manning Publications Company. 2014.

[20] R.T. Williams. Instruments. In Burlington, editor, *An Introduction to Trading in the Financial Markets: Trading, Markets, Instruments, and Processes*, chapter 3, paragraph 3. Elsevier Science. 2011.

[21] R.T. Williams. History. In Burlington, editor, *An Introduction to Trading in the Financial Markets: Market Basics*. Elsevier Science. 2011.

Glosario de términos

API - Application Programming Interface

CFD – Contrato por diferencia

CME – Chicago Mercantile Exchange

IT – Information Technologies

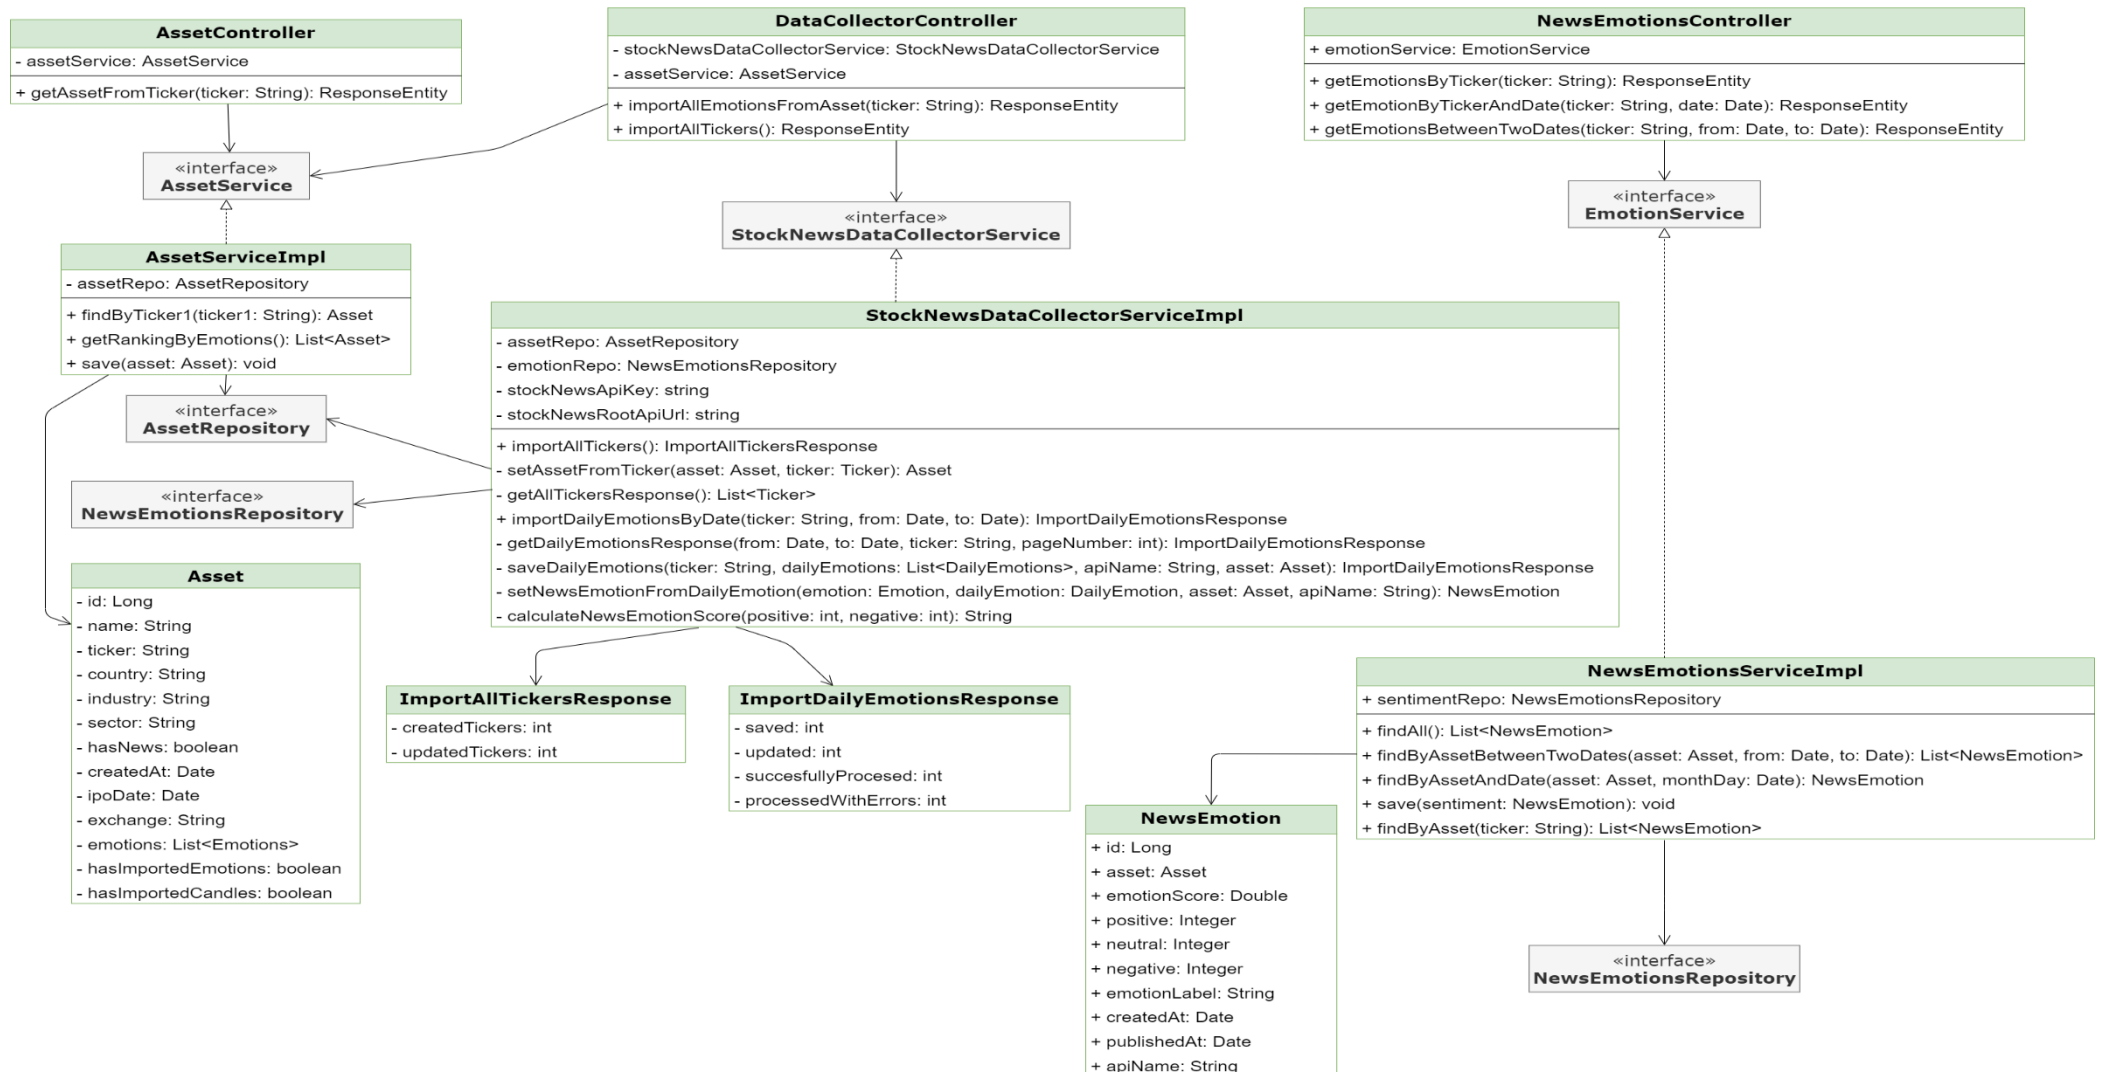
ML – Machine Learning

MVC – Modelo Vista Controlador

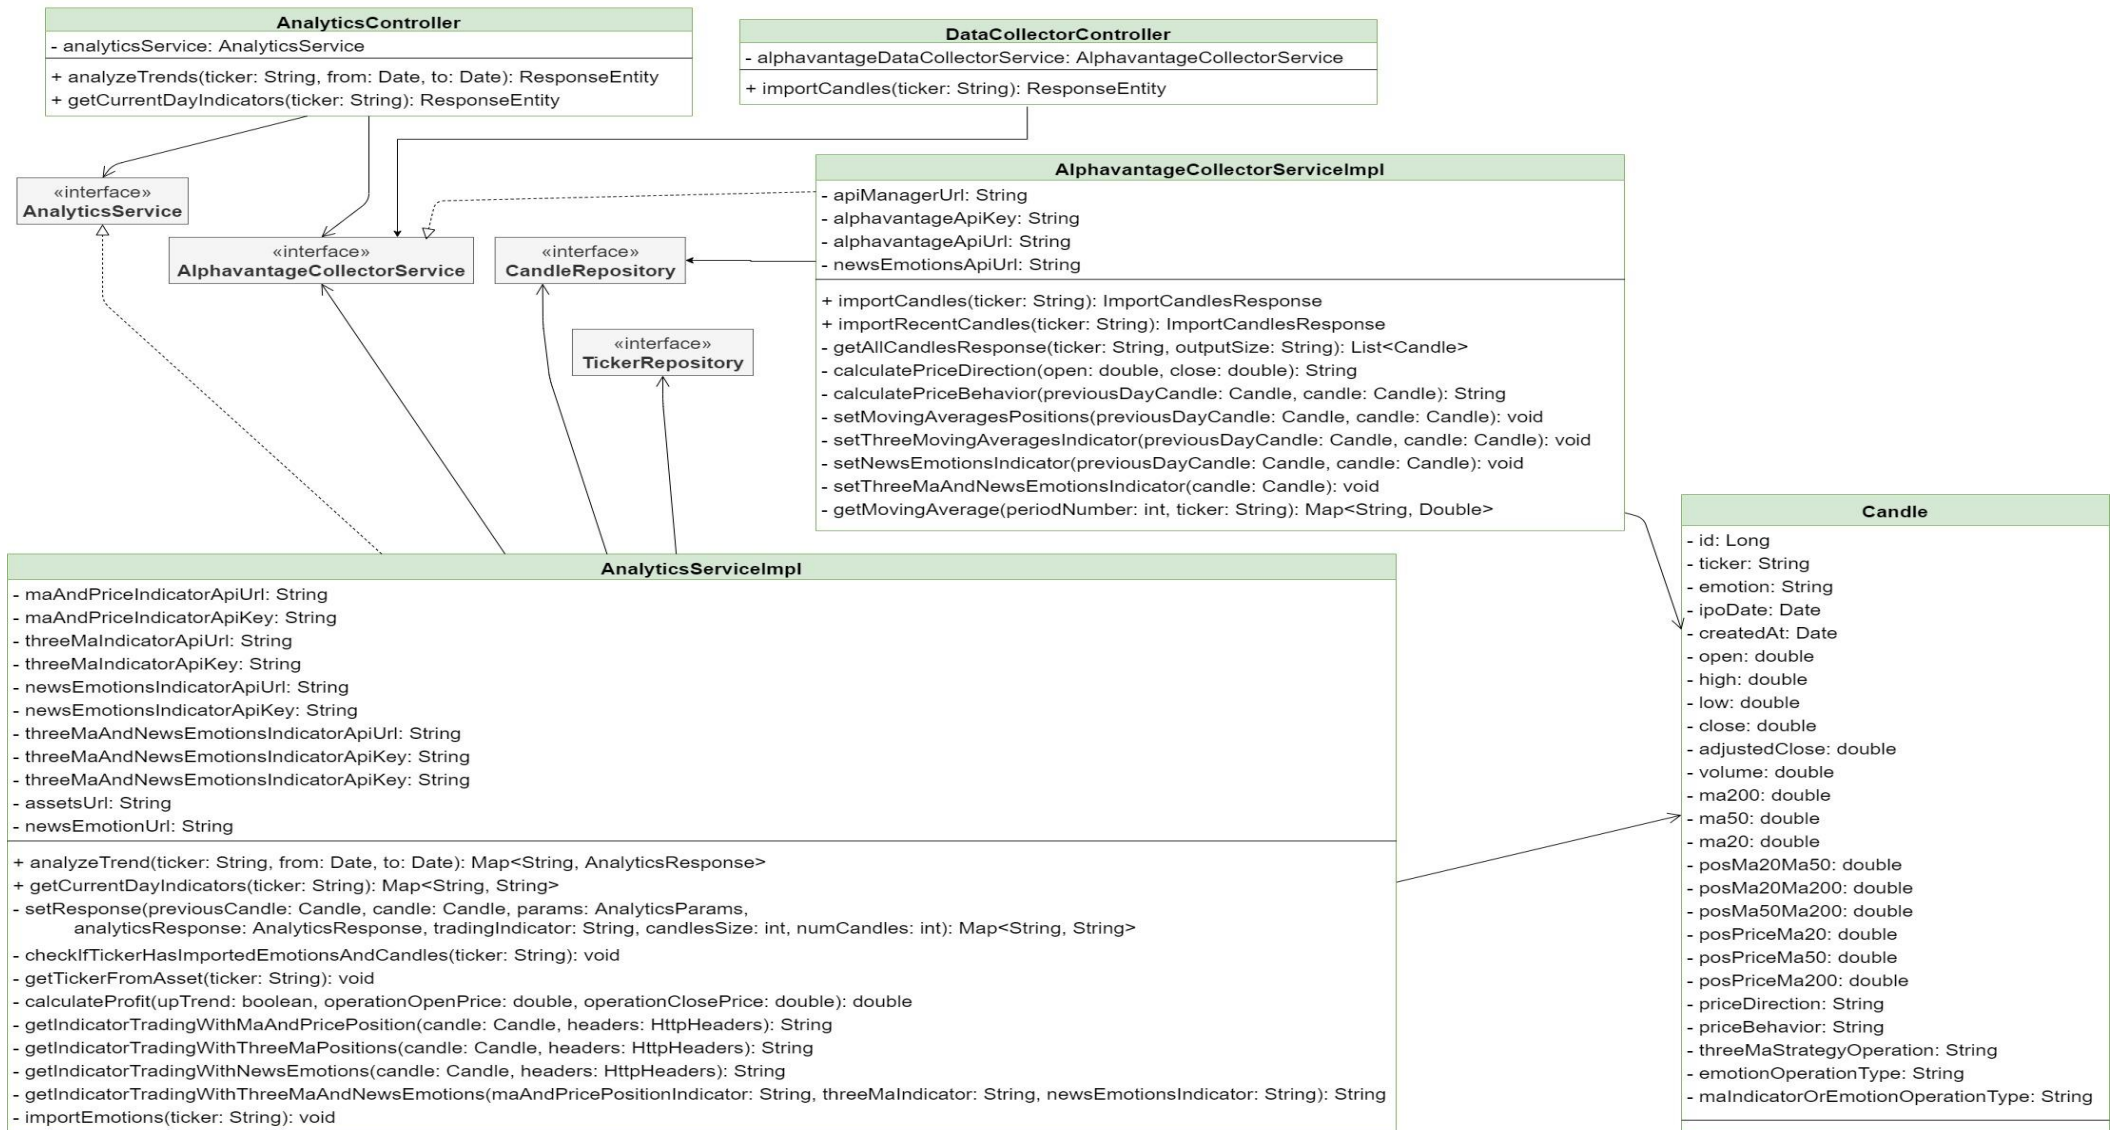
NASDAQ - National Association of Securities Dealers Automated Quotation

NYSE – New York Stock Exchange

Anexo I. Diagrama de clases de microservicio NewsEmotions.



Anexo II. Diagrama de clases de microservicio MarketEmotions.



Resumen/Abstract

En esta memoria se va a reflejar con detalle el proceso de realización de la aplicación “analizador de tendencias de mercado”, que utiliza varias estrategias de mercado basadas en indicadores técnicos y emociones surgidas de noticias. Para ello, se han aplicado técnicas de desarrollo basadas en microservicios, junto con experimentos realizados en Azure Machine Learning, con el objetivo de entrenar modelos predictivos que den soporte a la API de análisis de tendencias para poder predecir mejor el comportamiento del mercado. Todo el despliegue se ha realizado a través de Openstack en una infraestructura back-end basada en contenedores de Docker.

This report will reflect the development of the “trend market analyzer”. Which uses several market strategies based on technical indicators and emotions from the news. To this effect, several development techniques based on microservices have been applied. Among other experiments performed on Azure Machine Learning. In order to predict the market behaviour in a better way, several predictive models that support the trend analysis API have been trained. The deployment has been performed through Openstack on a based on Docker containers backend infrastructure.