

Diseño de un modelo de aprendizaje profundo para realizar operaciones de compraventa de activos financieros

Díaz García, Lucía

Master en Industria Conectada, Universidad Pontificia Comillas, Madrid

ldiazgarcia@alu.comillas.edu

Resumen— Diseño de un modelo de aprendizaje profundo basado en redes convolucionales en el que, a partir de las gráficas que muestran la evolución de las acciones de una compañía durante un periodo de tiempo determinado, se pueda estimar la operación a realizar más adecuada. La identificación de oportunidades de compraventa se hará en base a la técnica financiera de las Bandas de Bollinger. La transformación del enfoque clásico basado en un análisis numérico de series temporales a un problema de clasificación de imágenes resulta ser beneficioso a la hora de recuperar las señales con éxito.

Abstract— Design of a deep learning model based on convolutional networks in which, from images that show the evolution of the assets of a company during a certain period of time, it is possible to estimate the most appropriate operation to be carried out. The identification of buying and selling opportunities will be done based on the financial technique of the Bollinger Bands. The transformation of the classical approach based on a numerical analysis of time series to a problem of image classification proves to be beneficial in successfully recovering signals.

I. INTRODUCCIÓN

El mundo actual cambia a tan alta velocidad que es más indispensable que nunca ser capaz de detectar nuevas oportunidades en el mercado. La inteligencia artificial puede ser la herramienta necesaria para desarrollar estrategias financieras que previamente eran difíciles de predecir. Hoy en día muchas de las órdenes ejecutadas son realizadas por robots que toman decisiones basadas en algoritmos que reciben constantemente datos actualizados [1].

Más allá de utilizar algoritmos, la inteligencia artificial puede reunir datos de diferentes fuentes como periódicos, redes sociales o indicadores de intercambio para mejorar la toma de decisiones al conseguir una comprensión avanzada de las tendencias globales.

En este proyecto se explora una de las diferentes áreas de inteligencia artificial aplicada a mercados financieros. En concreto, a una compraventa de activos financieros inteligente, apoyándose en técnicas de aprendizaje profundo centradas en visión artificial. El objetivo principal será entrenar un modelo propio de Deep Learning capaz de identificar correctamente oportunidades tanto de venta como de compra de activos para

poder ser utilizado como una herramienta de inversión inteligente.

Este trabajo está basado en el artículo Trading via Image Classification (JP Morgan) [2]. Los autores de este artículo se basan en el hecho de que los agentes de inversión toman decisiones sobre la compraventa de activos mientras observan en una pantalla imágenes de gráficas de la evolución del valor de los activos. Partiendo de esta observación, formulan la hipótesis de que tratar los problemas de predicción de señales de compraventa de activos financieros como un problema de visión artificial en lugar de un problema de series temporales numéricas podría aportar valor y tener mayor éxito a la hora de recuperar dichas señales.

En su estudio, analizan los datos de todas las acciones del índice S&P 500 del periodo de 2010 a 2017. Comparan tres indicadores binarios diferentes conocidos, correspondiendo a cada uno una serie de normas algebraicas que determinan los diferentes momentos en los que habría una oportunidad compra, basándose únicamente en el valor de cierre diario de las acciones. Los tres algoritmos utilizados son: Bandas de Bollinger (BB), Convergencia Divergencia de la Media Móvil (MACD) e Índice de Fuerza Relativa (RSI).

Los datos utilizados corresponden a los valores de apertura, cierre, máximo y mínimo diarios (OHCL). En el estudio comparan los resultados de utilizar cinco tipos de representaciones diferentes de los datos, desde representar únicamente el valor del precio de cierre, hasta representar los cuatro valores OHCL incluyendo diferentes maneras de representar una noción del tiempo. De las cinco, la representación que incluye únicamente la curva del precio de cierre es la que obtiene mejores resultados, ya que aunque los otros tres datos del precio diario, así como los datos de los días anteriores, influyen en el valor de precio de cierre y por tanto podrían ser relevantes, el precio de cierre es el único valor que los algoritmos tienen en cuenta a la hora de determinar si un día presenta una oportunidad de compra o no.

Estos algoritmos tienen en cuenta los datos correspondientes a una ventana de tiempo de entre 20 y 27 días, dependiendo de la fórmula utilizada en cada uno. Por ello, las gráficas generadas incluyen la representación del día para el que se calcula el resultado del algoritmo y los correspondientes días anteriores que influyen en ese resultado.

Con las gráficas generadas, entrenan 16 modelos de aprendizaje supervisado diferentes con el objetivo de estudiar el rendimiento

global de todos los modelos, no siendo el objetivo elegir el mejor modelo. La resolución de imágenes óptima resulta ser de 30x30. Entrenan todos los modelos con un total de 10 000 muestras, 5 000 correspondientes a días que presentan oportunidad de compra, y 5 000 días en los que no hay ninguna señal. Este entrenamiento se realiza tres veces, una para cada algoritmo diferente, ya que los días que presentan señales serán en muchos casos diferentes para cada uno.

Para evaluar el rendimiento de los modelos una vez entrenados, para cada día del año 2018, generan una imagen con las curvas correspondientes a los datos de los valores diarios de las acciones de dicho día y de los días anteriores relevantes, igual que para las imágenes del entrenamiento. Para cada imagen predicen si a ese día correspondería una señal de compra o no. La precisión global obtenida a la hora de detectar las señales para los algoritmos de BB y RSI es superior al 90%, y entorno al 80% en el caso del algoritmo MACD.

II. OBJETIVOS

Se puede concluir a partir de estos resultados, que la transformación del análisis de series temporales en un problema de visión resulta beneficioso a la hora de trabajar con datos financieros para identificar oportunidades de compra de activos. Los resultados obtenidos demuestran que tiene sentido tratar este tipo de problemas, que en el día a día son resueltos visualmente por personas, como tareas de visión artificial, imitando así la realidad.

Partiendo de los conceptos y métodos descritos en este apartado, y del éxito demostrado, este trabajo se divide en cuatro objetivos principales:

En primer lugar, se buscará replicar los resultados del estudio. En concreto, por su utilidad para resolver problemas de visión artificial, se utilizarán modelos de redes neuronales convolucionales de entre todos los analizados en el artículo. Las imágenes que recibirá el modelo serán las correspondientes a la evolución del valor de las acciones de varias de las empresas del IBEX 35, en el periodo de tiempo de 2010 a 2017. Se evaluará la precisión con los datos de las mismas empresas para el año 2018. El algoritmo financiero escogido para la toma de decisiones de compraventa es el de las Bandas de Bollinger. Este algoritmo de compone de tres curvas, calculadas a partir del precio de cierre de cada acción. La primera curva es una media móvil, calculada para una ventana de tiempo de 20 días. A la media móvil, se suma y resta dos desviaciones estándar (calculadas para los mismos 20 días), calculando así las dos Bandas de Bollinger, una superior y una inferior. El corte de la curva del precio con la curva superior representará una oportunidad de venta, y con la curva inferior, de compra. En este trabajo, a diferencia del estudio realizado por los expertos de JP Morgan, se trabajará tanto con las oportunidades de compra así como las de venta, siguiendo los mismos principios.

Una vez conseguidos unos resultados similares, se realizarán diferentes ampliaciones al estudio, añadiendo complejidad para conseguir una aplicación más práctica, así como comprobar la eficacia y versatilidad de estos modelos para distintas tareas y configuraciones de los datos. Se realizarán dos cambios diferentes en los datos de entrada para evaluar el rendimiento del modelo en casos en los que se aporte menor información. En primer lugar, de las gráficas iniciales se eliminará el último día representado, al que corresponde la acción a tomar y por la cual

ha sido clasificada la imagen. De esta forma, se realizará una tarea de predicción, el modelo, conociendo los datos de los 19 días anteriores, deberá predecir la acción a realizar el día siguiente. La segunda variación consiste en eliminar de las gráficas las curvas correspondientes al algoritmo de las Bandas de Bollinger. En este caso se buscará que el modelo aprenda solo el algoritmo y sea capaz de clasificar las imágenes correctamente conociendo únicamente el valor del precio de cierre de las acciones.

En tercer lugar, se entrenará un modelo convolucional, que recibirá las mismas imágenes que el primer modelo, para realizar una tarea de regresión, con el objetivo de identificar el punto exacto de corte de la curva del precio con una de las Bandas de Bollinger.

Por último, se realizará una comparación entre los resultados obtenidos con el modelo convolucional, siendo los datos de entrada imágenes, y los resultados obtenidos con modelos de machine learning clásicos, que toman como entrada datos numéricos en forma tabular. El objetivo de esta comparación es evaluar la utilidad y viabilidad de convertir este problema financiero de análisis temporal en uno de visión artificial, así como destacar las diferencias entre unos modelos y otros, las ventajas y desventajas de cada uno de ellos.

III. METODOLOGÍA

El primer paso para poder entrenar los diferentes modelos hasta obtener los resultados buscados consiste en adquirir los datos necesarios, en este caso, los datos del precio de cierre diario de diferentes acciones del IBEX 35 para el periodo de tiempo de 2010 a 2018. Los datos serán procesados para su representación gráfica, consiguiendo así los datos de entrada que recibirán los modelos convolucionales. A partir del valor de la evolución del precio, mediante un algoritmo financiero, se clasificarán los diferentes días de dicho periodo de tiempo para cada acción según presenten una oportunidad de compra o venta, o ninguna de ellas. Esta clasificación será la salida de los modelos.

Una vez obtenidos y procesados los datos, se entrenarán diferentes modelos convolucionales según los datos de entrada, dependiendo del objetivo de cada uno, como ha sido descrito en la introducción. Para todos los modelos se partirá de una misma estructura, y se iterarán los diferentes hiperparámetros hasta obtener el mejor resultado para cada uno.

Asimismo, se entrenarán tres modelos de machine learning clásicos. Para entrenar estos modelos, en lugar de procesar los datos para conseguir imágenes, se utilizarán los datos numéricos adquiridos directamente.

Tanto el procesado de datos como el entrenamiento de modelos se realizarán con el lenguaje de programación Python.

Estos datos en un primer lugar se obtendrán en formato numérico, adquiriendo así el valor correspondiente para cada acción para cada día del periodo de tiempo indicado.

Para obtener estos datos, se empleará el paquete de Python `investpy` [3]. Este paquete permite extraer los datos históricos de la página web `Investing.com`. Los datos pueden ser de acciones, fondos, monedas o índices entre otros. Los datos obtenidos pueden ser guardados en variables de Python con las diferentes funciones con las que cuenta el paquete. En el caso de este trabajo solo se guardarán los datos correspondientes al precio de cierre, ya que es la evolución de estos valores lo único que se

tendrá en cuenta a la hora de identificar oportunidades de compraventa.

Una vez obtenidos los datos, el siguiente paso consistirá en identificar las oportunidades de compra y de venta en ese periodo de tiempo. Para ello se utilizará el conocido algoritmo de las Bandas de Bollinger. Esta herramienta fue diseñada por John Bollinger, y tiene como objetivo identificar cuando un activo está sobrecomprado o sobrevendido [4].

Las bandas se componen de tres curvas: una media móvil simple, y dos bandas, una superior y una inferior, que se sitúan a dos desviaciones estándar (negativa y positiva) del la media móvil. La media móvil suele ser calculada para un periodo de 20 días.

La fórmula para obtener las curvas se muestra a continuación:

$$\text{Band} = \text{Media}(\text{Precio}, 20\text{días}) + 2 * \sigma(\text{Precio}, 20\text{días})$$

La representación de las curvas para el periodo de 2018 para la acción BBVA es la siguiente:

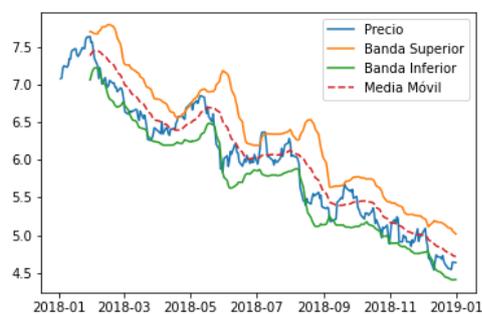


Ilustración 1. Ejemplo de representación de las Bandas de Bollinger para la acción BBVA durante el año 2018

Para identificar las diferentes oportunidades de compra o venta, este trabajo se basará en el concepto de reversión de la media [5]. Esta estrategia se apoya en la idea de que el precio siempre volverá a la media, por ejemplo, si el precio ha subido mucho, lo más probable es que vuelva al nivel medio. En el caso de las Bandas de Bollinger, el 90% del tiempo el precio se encuentra entre las dos bandas, por ello, el cruce del precio por encima de la banda superior o debajo de la banda inferior se considera un hecho importante. De acuerdo con la teoría de reversión a la media, estos cruces deberían ser seguidos por una vuelta a valores 'normales'.

Basándose en estos conceptos, las señales de compra y venta en este trabajo se calcularán de la siguiente manera: cuando la curva del precio corte la banda inferior por arriba, se generará una señal de compra, ya que cuando el precio se encuentre por debajo de la banda inferior, se puede considerar que el activo está sobrevendido, en el momento en que el precio vuelve a cruzar con la banda inferior, volverá a acercarse a la media. Las señales de venta se generan cuando el precio corta con la banda superior por debajo, siguiendo los mismos principios que las señales de compra, cuando el mercado esta sobrecomprado.

Estas señales son las que determinarán los datos que serán utilizados para entrenar los diferentes modelos. En primer lugar, para cada acción y durante todo el periodo de tiempo para el que se han extraído los datos, se calcularán las curvas de la desviación estándar y ambas bandas con las fórmulas indicadas

anteriormente. A continuación, se obtendrán todas las señales de compra identificadas, calculando los momentos en los que el precio cruza por arriba de la banda inferior, y se guardarán estos índices en un vector. Lo mismo para las señales de venta, cuando el precio cruza por debajo de banda superior. Para cada uno de estos índices, se generará una gráfica que posteriormente será guardada como formato de imagen .jpg. Cada gráfica tendrá una ventana de tiempo de 20 días, siendo el último día el correspondiente a la señal generada, representando también las curvas de los 19 días anteriores, ya que serán esos 19 días los que influyen en el valor de las bandas en el día correspondiente a la señal. En las imágenes se incluirá la curva del precio, la media, y las bandas. La Ilustración 2, muestran un ejemplo de imagen correspondiente a un día en el que habría una señal de compra, y uno con señal de venta, respectivamente.

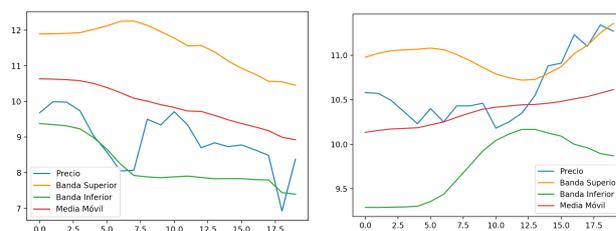


Ilustración 2. Muestra de imágenes correspondientes a una señal de compra y de venta, respectivamente

Las imágenes guardadas que serán utilizadas para entrenar los modelos no incluyen leyenda, y serán recortadas para no incluir el valor de los ejes. La resolución de las imágenes será de 50x50 DPI antes de ser recortadas, y finalmente, las imágenes que serán utilizadas tendrán una resolución de 37x37 píxeles tras recortar los ejes.

Una vez calculadas todas las señales de compra y de venta para todas las acciones y las han sido imágenes guardadas, se generarán las imágenes correspondientes a los días en los que no se identifica ninguna señal. Para obtener un set de datos de entrenamiento los más balanceado posible, se generará la mitad de imágenes del total de las correspondientes a ambas señales, para que los datos contengan aproximadamente un tercio de cada tipo de señal (o no señal). Los días para los que se generarán imágenes de no señal se elegirán al azar hasta llegar al número de muestras escogido.

En total se trabajará con 4212 muestras, 1354 serán señales de compra, 1196 señales de venta, y 1272 sin señal. Las imágenes servirán como datos de entrada para los modelos convolucionales, cuyo objetivo será clasificarlas según el tipo de señal que representan. Las imágenes serán clasificadas con un vector binario de tres posiciones, en el que la posición en que haya un 1 indicará el tipo de imagen. En la posición 0 será muestra sin señal, en la posición 1 señal de compra, y en la posición 2 señal de venta. El objetivo principal de los modelos será realizar una tarea de clasificación.

Además se añadirá una tarea de regresión; se entrenará los modelos para identificar el punto exacto del corte de la curva del precio con una de las bandas en las muestras en las que se haya identificado una señal de compra o venta. Para esta tarea de regresión, los datos de entrada serán las mismas imágenes que para los modelos de clasificación, cambiando el vector de salida. En este caso será un vector de dos posiciones indicando las

coordenadas X e Y del punto de corte, normalizándolas previamente, como se explicará más adelante en detalle.

En el caso de los modelos numéricos de machine learning, los datos de entrada no serán imágenes, si no un vector de 20 posiciones con el valor del precio durante los 20 días correspondientes a la imagen que reciben los modelos convolucionales.

A. Modelos neuronales convolucionales

En este apartado se analizarán diferentes modelos convolucionales, entrenados por separado para conseguir tres objetivos diferentes. Por un lado, replicando el trabajo realizado por los autores del artículo *Trading via Image Classification* detallado anteriormente, se entrenará un modelo para clasificar imágenes de 20 días según la señal correspondiente al último día representado. Las imágenes en este caso tendrán las mismas características que las representadas anteriormente, incluyendo todas las curvas.

Para estos mismos datos se entrenará un modelo para realizar una tarea regresión con el objetivo de identificar el punto de corte de las curvas, en el caso de que lo haya. Se entrenarán dos modelos de regresión diferentes, uno para cada tipo de señal.

Estos dos primeros tipos de modelo (clasificación y regresión) estarán relacionados de la siguiente manera: cada uno será entrenado por separado hasta conseguir buenos resultados, buscando maximizar la precisión en la clasificación y minimizar el valor de la función de coste en la regresión. Una vez entrenados los modelos, se realizará primero la clasificación de los datos del set de test, y según la clasificación, se empleará un modelo u otro de regresión para predecir las coordenadas del punto de corte. Es decir, si una imagen ha sido clasificada por el primer modelo como una señal de venta (pudiendo ser correcta o no la clasificación), la predicción del punto de corte de esta imagen se hará con el modelo de regresión entrenado con los datos correspondientes a imágenes de venta. Igual para las imágenes clasificadas como compra. En el caso de las imágenes clasificadas sin señal, el valor del punto de corte se establecerá directamente en cero, sin necesidad de haber entrenado un modelo para esta clase de imágenes.

En tercer lugar, se empleará un modelo diferente para realizar una tarea de predicción. En este caso, el modelo no conocerá el valor de las curvas del día que determina la clasificación de la imagen. Para este modelo, se eliminará de las imágenes utilizadas para los modelos anteriores la representación del último día, resultando en imágenes con una ventana de tiempo de 19 días.

Para ambos modelos de clasificación, se modificarán los datos para analizar los resultados de entrenar modelos con muestras que incluyan únicamente el valor del precio de la acción. Se eliminará de las imágenes la representación de las curvas de las Bandas de Bollinger así como de la media móvil.

El proceso de entrenamiento de los modelos será el mismo para todos ellos: se partirá de la estructura indicada en el artículo de JP Morgan, con alguna modificación para ajustarse a los requisitos de este proyecto, y se realizarán iteraciones tanto en los hiperparámetros (número de particiones en la validación cruzada, número de épocas...) como en la arquitectura de la red convolucional. La estructura base de las capas de la red será la siguiente:

- Zero Padding 3x3 en la primera capa, para

- Tres capas convolucionales de 32 filtros 3x3 con activación ReLU
- Max Pooling 2x2 después de cada capa convolucional
- Una última capa con activación Softmax

En cuanto al resto de hiperparámetros:

- Optimizador: Adam
- Función de coste: entropía cruzada categórica
- Tamaño de batch: 16 muestras
- 50 épocas

Para los modelos de clasificación, la activación de la última capa será una función softmax en lugar de una sigmoide como aparece indicado en el artículo en el que se basa esta estructura. Esto se debe a que en el estudio realizado por JP Morgan se distingue entre dos situaciones: oportunidad de compra o ausencia de oportunidad, siendo la clasificación binaria. En este trabajo se ha ampliado la clasificación a una tercera posibilidad, las señales de venta. La función sigmoide suele ser utilizada en problemas de clasificación en los que se distingue únicamente entre dos clases, mientras que la función softmax es utilizada para clasificación múltiple.

De este modo, la posición con la mayor probabilidad, será seleccionada como la clase predicha por el modelo.

Otro cambio respecto a la estructura original es la función de coste como entropía cruzada categórica en lugar de entropía cruzada binaria, por la misma razón por la cual se ha cambiado la función de activación de la clasificación, al ser un problema de varias clases en lugar de binario. En este caso, la clase no será representada por un único dígito, distinguiendo entre dos opciones según el valor sea cero o uno. El resultado de la predicción será un vector de tres posiciones, una por cada clase, por lo que la función de coste de entropía cruzada binaria no se ajusta al problema.

Todos los modelos serán entrenados con la librería Keras. Keras es una API para redes neuronales de código abierto escrita en Python. Se puede ejecutar sobre diferentes marcos de Deep learning, en este trabajo se utilizará TensorFlow. Esta API ofrece una manera intuitiva de entrenar redes neuronales de alto nivel, resultando más sencillo el desarrollo de modelos de aprendizaje profundo.

MODELO DE CLASIFICACIÓN DE SEÑALES DE COMPRAVENTA PASADAS

El primer modelo entrenado tiene como objetivo principal evaluar la efectividad de una red neuronal convolucional a la hora de recuperar las señales de compra y venta cuando los datos de entrada son imágenes. Este modelo busca clasificar correctamente imágenes que contienen datos históricos pasados. Este modelo no tiene como finalidad su uso en un entorno real, ya que se apoya en conocer de antemano el valor del precio de cierre de la acción del día para el cual se quiere identificar una oportunidad.

Como se ha detallado anteriormente, los datos que recibe este modelo consisten en un vector de 4212 muestras, cada muestra siendo una imagen de tamaño 37x37x3. Se entrenarán dos tipos de modelo diferentes: en uno de ellos, los datos que recibe el modelo incluyen la representación de todas las curvas que influyen en la generación de señales: precio de cierre, media

móvil y las bandas inferior y superior de Bollinger. El segundo modelo solo incluirá el precio de la acción.

La **Error! Reference source not found.** muestra los resultados de diferentes modelos entrenados para las imágenes que contienen la representación de las cuatro curvas, iterando diferentes hiperparámetros buscando conseguir la máxima precisión posible.

folds	epochs	ACCURACY					
		Total	Media	No Signal	Buy	Sell	
1	5	50	0,522	0,821	0,497	0,993	0,974
2	10	50	0,761	0,893	0,751	0,927	1
3	10	100	0,845	0,800	0,851	0,628	0,922
4	10	75	0,685	0,874	0,67	0,964	0,987
5	10	150	0,782	0,889	0,773	0,92	0,974

Tabla 1. Resultados de precisión para los modelos convolucionales de clasificación de señales pasadas, para imágenes con la representación de todas las curvas

Los dos hiperparámetros principales que se han iterado buscando mejorar el rendimiento del modelo son el número de particiones (*folds*) de la validación cruzada y el número de épocas (*epochs*). Otros hiperparámetros, como el tamaño de los filtros, al ser modificados respecto a la estructura base detallada anteriormente, presentaban resultados considerablemente peores, por lo que no se han incluido en la comparación.

Para cada modelo, se presentan cinco medidas de la precisión diferentes. La primera medida, 'total', es el valor de la precisión medida por el modelo, para cada muestra en el set de datos de evaluación, se convierte la predicción del modelo en un vector binario, tomando como predicción la posición del vector que presenta una mayor probabilidad. La medida de precisión se calcula como el porcentaje de muestras que han sido predichas correctamente. Las últimas tres medidas se han calculado para cada tipo de muestra por separado, por ejemplo, para las muestras que corresponden a días en los que no hay ninguna señal, se ha calculado el porcentaje de las muestras que se han predicho como no señal. Lo mismo para las señales de compra y venta. Separar la medida de la precisión en estas tres categorías resulta útil para conocer más información acerca de cómo actúa cada modelo, y poder comparar la precisión para un tipo de muestras y otras, y observar si existe una diferencia considerable entre ellas. Por último, a partir de las medidas de precisión para cada clase, se calcula la media, que no es equivalente al total ya que la proporción de cada tipo de muestra no está igualada, al ser la mayor parte de las muestras del tipo sin señal. Comparando esta última medida con el valor de la precisión total se puede intuir si el valor total de la precisión sirve como buena medida para conocer la precisión de todas las muestras (si ambas medidas son similares), o si está principalmente influenciada por un tipo de muestra concreto (si hay una gran diferencia entre ambas).

En todos los modelos, excepto para el modelo 3, la precisión conseguida para las muestras que representan algún tipo de señal es bastante más alta que para las muestras que no representan señal. Al ser la mayor parte de las muestras de set de evaluación del tipo no-sígnal, la precisión total se ve mayormente afectada por la precisión en la clasificación de este tipo de muestras. Hay muchas más señales de este tipo ya que como se ha comentado anteriormente, al representar las Bandas de Bollinger, el 90% de la actividad tiene lugar entre las bandas, por lo tanto, los días en los que se identifican oportunidades de compra o venta, son la minoría. Es por esta razón que tiene sentido estudiar la precisión de cada tipo de muestra por separado.

El modelo 3, entrenado con 10 particiones y 100 épocas, presenta la precisión total más alta, de un 84,5%. A su vez, precisión media de todas las clases es del 80%, por lo que se puede concluir que la precisión total es una representación adecuada del rendimiento del modelo para la mayor parte de las muestras, siendo el modelo que presenta una menor diferencia entre la precisión total y la precisión media.

De todas las clases, la que mejores resultados obtiene en todos los modelos, con una precisión mayor al 92% en todos los casos, es la correspondiente a oportunidades de venta.

Una vez entrenados varios modelos con diferentes hiperparámetros hasta obtener el mejor resultado, se entrenará un nuevo modelo partiendo de la estructura base detallada anteriormente. La diferencia entre este modelo y el anterior se encuentra en la representación de los datos. Con este modelo se pretende añadir complejidad a la clasificación, al no representar en las imágenes de entrada al modelo las curvas pertenecientes a las Bandas de Bollinger. Este modelo busca añadir un punto de complejidad a la aplicación; en el modelo anterior, la clasificación se realizaba en función de que hubiese o no un cruce entre dos de las curvas representadas el último día, por lo tanto, el modelo debía identificar si existía dicho punto de cruce. Este nuevo enfoque busca que la red neuronal sea capaz de intuir el algoritmo conociendo únicamente el precio. El modelo deberá aprender diferentes características de los datos, ya que en este caso no habrá un punto de corte que determine la clasificación de las imágenes.

La muestran la diferencia entre las imágenes que reciben un modelo y otro. En este caso, la muestra corresponde a una imagen clasificada como oportunidad de compra. Para la segunda imagen, el modelo deberá ser capaz de reconocer la oportunidad de compra basándose únicamente en la evolución del precio de cierre durante los 20 días representados.

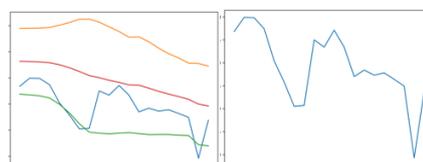


Ilustración 3. Ejemplo de muestra incluyendo la representación únicamente de la curva del precio de cierre

En la Tabla 2 se muestran los resultados del entrenamiento de diferentes modelos para este nuevo formato de los datos. Se puede observar cómo para estos nuevos modelos, la precisión alcanzada es superior a la conseguida en los modelos que han sido entrenados con las imágenes en las que se representaban

todas las curvas. En este caso, igual que en la tabla anterior, el número óptimo de particiones es mayor que cinco, obteniendo los mejores resultados con diez particiones.

	folds	epochs	ACCURACY				
			Total	Media	No Signal	Buy	Sell
1	10	50	0,853	0,899	0,850	0,861	0,987
2	10	100	0,813	0,913	0,806	0,934	1
3	5	50	0,706	0,845	0,535	1	1

Tabla 2. Resultados de precisión para los modelos convolucionales de clasificación de señales pasadas, para imágenes con la representación únicamente de la curva del precio de cierre

La precisión total más alta alcanzada es del 85,3%, en el caso del modelo 1, entrenado con 10 particiones y 50 épocas.

MODELO DE CLASIFICACIÓN DE SEÑALES DE COMPRAVENTA FUTURAS

En el apartado anterior se ha demostrado que las redes neuronales convolucionales son capaces de obtener buenos resultados a la hora de interpretar gráficas de la representación de series temporales financieras para identificar oportunidades de compra o venta en determinados días. Estos primeros modelos no tienen una aplicación práctica real, pero sirven como primer paso para evaluar la viabilidad del cambio de planteamiento de un problema numérico a uno visual.

El siguiente paso será ampliar el alcance del trabajo para conseguir desarrollar una herramienta que pueda ser útil y servir como apoyo para una estrategia de inversión efectiva. Para conseguir esto, se planteará desarrollar un nuevo modelo que sea capaz de predecir la presencia de una oportunidad de compra o venta el día siguiente al último representado. En este caso, conocido el precio de cierre de un día concreto y de los 18 anteriores, se podrá predecir que acción sería la más óptima tomar el día siguiente. De este modo, se podrían tomar decisiones con antelación, anterior consiste en el formato de los datos de entrada. Mientras que los datos de salida (la clasificación de cada muestra) permanece igual, en este nuevo modelo las imágenes que componen los datos de entrada al modelo sólo incluirán la representación de los 19 días anteriores al día para el cual se quiere conocer la acción a realizar. Los cambios en los imágenes son dos: la ventana de tiempo se reduce un día, y la información del día que determina la clasificación de la imagen no se conoce. En este caso, al contrario que en modelo anterior no hay un punto de cruce entre la curva del precio con una de las dos bandas, por lo que la clasificación deberá realizarse a partir de la información a cerca de la evolución de las curvas, en lugar de buscar si dicho cruce está representado o no.

Un ejemplo del cambio de una muestra de un modelo a otro se puede observar en la siendo la última la correspondiente al nuevo formato que servirá para la predicción.

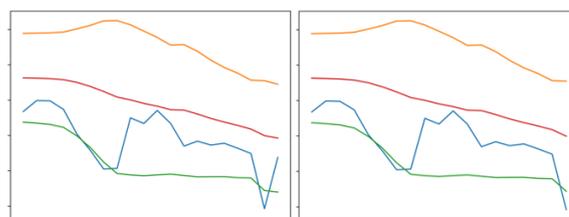


Ilustración 4. Ejemplo de muestra que incluye la representación de 19 días para todas las curvas

En la Tabla 3 se recogen los resultados de los diferentes modelos entrenados con estos datos.

	folds	epochs	ACCURACY				
			Total	Media	No Signal	Buy	Sell
1	5	50	0,433	0,700	0,409	0,978	0,714
2	10	50	0,504	0,789	0,481	0,898	0,987
3	100	150	0,535	0,774	0,516	0,883	0,922

Tabla 3. Resultados de precisión para los modelos convolucionales de clasificación de señales futuras, para imágenes con la representación de todas las curvas

El mejor modelo de este tipo a penas alcanza una precisión del 53,5%, significativamente inferior respecto al modelo equivalente para las imágenes de 20 días (84,5%). El modelo entrenado parece no ser lo suficientemente complejo para ser capaz de recuperar las señales de compra y venta correctamente, al clasificar erróneamente aproximadamente la mitad de muestras que no presentan ninguna oportunidad como señal de venta o de compra.

Igual que en el apartado anterior, se entrenará también un modelo con imágenes que contienen sólo la curva del precio. En este caso, las imágenes no incluirán la representación de las Bandas de Bollinger ni la información a cerca del día 20, que es el día para el cual se desea conocer la decisión óptima que tomar. De los diferentes modelos desarrollados a lo largo del trabajo, este será el que cuente con menor información para realizar la tarea de clasificación. Aumentando de esta forma la complejidad del problema no sólo convierte este modelo en una herramienta útil que pueda ser empleada a la hora de invertir, si no que también sirve para analizar la versatilidad y escalabilidad de este proyecto y de utilizar redes neuronales convolucionales para estrategias de inversión.

Los resultados de la precisión de los diferentes modelos de predicción entrenados se muestran en la Tabla 4. Estos modelos alcanzan una precisión mucho mayor a los modelos en el caso en el que se representan todas las curvas, con resultados muy similares a los modelos en los que el día 20 se incluía representado en las imágenes de entrada.

folds	epochs	ACCURACY					
		Total	Media	No Signal	Buy	Sell	
1	10	50	0,855	0,874	0,854	0,86	0,987
2	5	50	0,62	0,801	0,602	0,919	0,987
3	10	100	0,837	0,882	0,834	0,838	0,987

Tabla 4. Resultados de precisión para los modelos convolucionales de clasificación de señales futuras, para imágenes con la representación únicamente del precio

El modelo con el que mejor precisión se obtiene es el modelo 1, con diez particiones y 50 épocas. La precisión total es del 85,5%, y la media, 87,4%.

MODELO DE REGRESIÓN

El tercer tipo de modelo neuronal convolucional desarrollado tiene un objetivo diferente a los anteriores, cuya finalidad consistía en clasificar correctamente las imágenes. Este modelo realizará una tarea de regresión, posterior a la clasificación.

Con este modelo, se pretende identificar el punto exacto de corte, si es que lo hay, entre la curva del precio con una de las bandas.

En primer lugar, se calcularán las coordenadas del punto de intersección para las muestras que presenten una señal de compra o de venta. La coordenada en el eje X del punto de corte siempre tendrá un valor entre 18 y 19, ya que la intersección que determina la clase de cada muestra siempre se da en el último día (el último día corresponde al día 20, que es la posición 19 del vector). En el caso del eje Y, el valor de dicho punto dependerá del precio de cada acción en el día concreto. Como se ha mencionado anteriormente, las imágenes que recibe el modelo no incluyen la representación de los ejes, por lo que se normalizarán los datos.

Las imágenes que recibirá este modelo son las mismas que para los modelos anteriores, para los que se incluía la representación de las cuatro curvas. El cambio estará en los datos de salida, en este caso, será un vector de dos posiciones que contendrá las coordenadas normalizadas del punto de intersección para cada muestra. Para las imágenes en las que no se produce la intersección, y, por lo tanto, no presentan señal de ningún tipo, se fijará este dato como [0,0].

Se desarrollarán dos modelos diferentes, uno para cada clase de señales, es decir, un modelo con los datos entrenamiento únicamente pertenecientes a imágenes con señal de venta, y lo mismo para las señales de compra. En primer lugar, se clasificarán las imágenes con el modelo de clasificación entrenado previamente, y las imágenes pasarán posteriormente a un modelo de regresión u otro según la clase predicha. Por ejemplo, si una imagen ha sido clasificada como señal de venta, el punto de cruce será predicho por el modelo de regresión entrenado con los datos pertenecientes únicamente a muestras que presentan señal de venta, independientemente de si la clasificación es correcta o no.

En cuanto a la estructura de los modelos, la principal diferencia respecto a los modelos anteriores se encuentra en la última capa,

ya que este caso, el objetivo no es clasificar si no realizar una regresión. Al ser más compleja esta tarea, ya que se busca la máxima precisión buscando el punto exacto de corte, el modelo contará con más de una capa densamente conectada. En primer lugar, una o más capas cuya activación será lineal, que dará lugar a la función de regresión buscada. La última capa tendrá una activación de tipo sigmoide para asegurar que el valor predicho se encuentre entre 0 y 1 en todos los casos, ajustándose así a las coordenadas normalizadas.

Otro cambio importante en el modelo, será el cambio de la función de coste. En la clasificación, el dato más relevante a la hora de comparar los resultados de los modelos era la precisión. En este caso, lo más importante será como de cerca está el punto predicho del punto real, por lo tanto, al tratarse de una regresión, la función de coste pasará a ser el error cuadrático medio.

Con esta arquitectura, se obtiene el error cuadrático medio para ambos modelos (compra y venta). Los resultados se muestran en la Tabla 5. **Error! Reference source not found.**

MODELO	MSE
COMPRA	0,00097
VENTA	0,00272

Tabla 5. Resultados del error cuadrático medio de los modelos convolucionales de regresión

En esta aplicación en la que los datos son diarios, este punto de corte no representa un momento concreto de un día, ya que la curva del precio se representa uniendo al valor del precio de un día y del día siguiente, por lo que en esta recta se pierde la información de lo que pasa entre medias. Que el cruce se produzca más a la derecha en la imagen no implica necesariamente que el momento idóneo para operar sea la hora equivalente de este día. Es por esto que sólo se ha realizado la regresión para uno de los modelos de clasificación detallados anteriormente.

Esta técnica tendría más sentido aplicarla para datos intradiarios y así aplicarla a una estrategia de inversión de alta frecuencia. El precio de una acción en un mismo día puede variar significativamente, por lo que únicamente con el valor de cierre se pierde mucha información. Sin embargo, trabajando con datos intradiarios en intervalos de minutos o incluso segundos, el punto de corte representaría de forma más precisa el momento exacto en el que realizar una operación de compra o venta, ya que en esta caso no se perdería información tan relevante.

B. Modelos de machine learning

En el apartado anterior se han analizado los resultados de entrenar modelos de aprendizaje profundo con imágenes para resolver un problema financiero, en concreto, identificar oportunidades de compra o venta de una acción según un algoritmo financiero algebraico. Como se puede concluir de los resultados mostrados en las diferentes tablas que contienen la precisión de distintos modelos al realizar esta tarea, el uso de estos modelos demuestra ser beneficioso para conseguir recuperar las distintas señales de compraventa.

Estos modelos, al contar con numerosas capas y al ser los datos imágenes, tienen muchos más parámetros que un modelo clásico

numérico, por lo que tardan más tiempo en ser entrenados y tienen un coste computacional muy alto. Por esto, aunque presenten buenos resultados, resulta conveniente compararlos con modelos más sencillos, que cuentan con menos parámetros y para los cuales el coste computacional es mucho menor. Una vez demostrada la capacidad de los modelos convolucionales, comparándolos con modelos más sencillos, se analizará si estos últimos modelos son capaces de obtener resultados similares, necesitando menos parámetros y un tiempo de ejecución menor, para estudiar la utilidad de aumentar la complejidad de los modelos a entrenar para realizar la tarea en cuestión.

A continuación, se entrenarán tres modelos diferentes con datos de entrada numéricos, clásicos de machine learning. Estos modelos recibirán como datos de entrada un vector conteniendo el valor del precio de cierre de cada acción durante 20 días, equivalente a los días representados en las imágenes de los modelos convolucionales.

Los modelos entrenados serán los siguientes: regresión lineal, support vector machine y random forest.

Todos los modelos se entrenarán con validación cruzada de diez particiones. Por otro lado, se modificará el formato de los datos de salida. Por la naturaleza de la estructura de estos modelos, en lugar de un vector de tres posiciones, la salida será representada con un único número, que tomará un valor entre tres posibles, uno para cada clase. Este número es equivalente a la posición en el vector que en los modelos anteriores contenía un 1: será 0 para las muestras sin señal, 1 para las muestras con señal de compra y 2 para las muestras con señal de venta.

IV. ANÁLISIS DE LOS RESULTADOS

En total se han entrenado cinco redes neuronales convolucionales, según su objetivo y el tipo de datos que ha recibido cada una.

Los cuatro primeros modelos tenían como objetivo realizar una tarea de clasificación, con la finalidad de identificar las muestras para las cuales se presenta una oportunidad de compra o venta del activo financiero al que pertenece esa muestra. Esta clasificación se ha realizado para dos situaciones diferentes, en primer lugar, para identificar dichas oportunidades en el último día representado, asumiendo que se conoce de antemano la información del día para el cual se quiere saber si la acción a tomar debería ser de compra o venta, o ninguna. En segundo lugar, la clasificación se ha realizado a modo de predicción, con el fin de identificar la señal correspondiente al día siguiente al último representado, sin conocer información del precio de cierre de la acción de ese día.

A parte, para ambos modelos, se ha realizado una modificación en los datos de entrada, incluyendo únicamente la representación de la curva de la evolución del precio de cierre de la acción, eliminando de las imágenes las curvas correspondientes al algoritmo de las Bandas de Bollinger.

En la Tabla 6 se muestra la precisión alcanzada para cada uno de estos cuatro modelos. La precisión indica el porcentaje de las muestras que han sido clasificadas correctamente. Todos los modelos, excepto el modelo de predicción cuyos datos de entrada incluían la representación de todas las curvas alcanzan una precisión del 85% aproximadamente. De todos los modelos, el que mayor precisión ha obtenido es el modelo de predicción que únicamente incluye la representación del precio de cierre.

Este último modelo es el más interesante de todos ya que es el que menos información contiene, siendo por esto el más útil y práctico a la hora de ser utilizado como herramienta de inversión.

Para los dos tipos de modelo, clasificación y predicción, la precisión obtenida es mayor para los datos que únicamente incluyen la representación de precio de cierre, siendo la diferencia de a penas un 0,8% en el caso de la clasificación, y de un 32% en la predicción. En el caso de los modelos que incluyen la representación de todas las curvas, son necesarias más épocas en el entrenamiento de las establecidas en la estructura base, entre 100 y 150. Para los modelos entrenados con las imágenes eliminando la representación de las bandas de Bollinger, con el número de épocas de la arquitectura base, 50, es como se consiguen los mejores resultados. Para los cuatro modelos la precisión más alta se obtiene para una validación cruzada con 10 particiones.

MODELO	PRECISIÓN
Clasificación, representación de todas la curvas	84,5%
Clasificación, únicamente curva del precio	85,3%
Predicción, representación de todas las curvas	53,5%
Predicción, únicamente la curva del precio	85,5%

Tabla 6. Resultados de precisión finales de todos los modelos convolucionales

A parte de los diferentes modelos neuronales convolucionales, propios de Deep learning, se han entrenado tres modelos diferentes de machine learning: una regresión lineal, una máquina vector de soporte y un random forest. Estos modelos toman como datos de entrada un vector de 20 posiciones, con la información del valor del precio de cierre de cada acción durante 20 días. Estos modelos son entrenados con la misma información que el modelo neuronal convolucional de clasificación para el cual los datos de entrada eran imágenes con la representación del precio de cierre únicamente. La diferencia entre la información que reciben los modelos de machine learning respecto al modelo convolucional es que para los primeros el formato es numérico, mientras que para el segundo son imágenes. Por esto, los resultados de los modelos de machine learning se compararán con este modelo convolucional de los diferentes entrenados.

Los resultados de la precisión de estos modelos se muestran en la Tabla 7. Como se puede observar, la red neuronal convolucional presenta una precisión mayor que la de todos los modelos de machine learning, siendo entre un 34,5% y un 73,3% mayor.

MODELO	PRECISIÓN
Regresión lineal	12%
Support Vector Machine	50,8%
Random forest	28,8%

Red neuronal convolucional	85,3%
----------------------------	-------

Tabla 7. Comparación de los resultados de los modelos de machine learning frente a una red neuronal convolucional

De las tablas anteriores se pueden extraer dos conclusiones principales. En primer lugar, los modelos neuronales convolucionales, que toman imágenes como datos de entrada, para tres de los cuatro modelos diferentes entrenados, presentan una precisión alrededor del 85%. Los modelos son capaces de recuperar con éxito la mayor parte de las señales de compra y de venta, distinguiendo a su vez los días en los que no se presenta ninguna de estas señales. Con estos resultados, se puede confirmar que al transformar el planteamiento clásico de este problema financiero centrado en la compraventa de activos de un problema numérico a uno visual se consigue realizar la tarea de clasificación con éxito.

Por otro lado, comprando con los resultados obtenidos por los modelos de machine learning, se confirma que no sólo son los modelos neuronales convolucionales capaces de resolver este problema, si no que superan con creces los resultados de estos modelos más simples. Los modelos de machine learning demuestran no ser lo suficientemente complejos para clasificar las muestras correctamente, por lo que resulta beneficioso emplear modelos neuronales convolucionales.

V. CONCLUSIONES Y FUTUROS DESARROLLOS

Una vez analizados los resultados de los diferentes modelos entrenados, tanto las redes neuronales convolucionales como los modelos de machine learning, se puede concluir que el uso de los modelos convolucionales demuestra ser beneficioso para conseguir recuperar las distintas oportunidades de compra y venta de activos financieros.

Se han resuelto con éxito las ampliaciones propuestas, demostrando la versatilidad tanto de las redes neuronales convolucionales como del nuevo enfoque centrado en las imágenes como datos de entrada. Si bien la segunda red desarrollada (en concreto el modelo de predicción con información de las curvas tanto del precio como del algoritmo) a penas alcanza una precisión del 53,5%, el último modelo, que realiza la misma tarea con la misma finalidad pero con menos información de entrada, alcanza la mayor precisión de todos los modelos, del 85,5%. Este último modelo resulta ser el más práctico ya que es el que se ajusta más a una aplicación real, en la que se cuenta con la menor información posible.

Por último, la comparación con los resultados obtenidos para los modelos de machine learning, cuyos datos de entrada eran numéricos, permite comprobar que no solo son capaces las redes convolucionales de resolver las tareas propuestas en este trabajo, si no que consiguen alcanzar una precisión mucho mayor, confirmando la utilidad de utilizar modelos de aprendizaje profundo para aplicaciones complejas.

En este proyecto se ha trabajado con datos diarios. Los modelos convolucionales entrenados realizan una tarea de clasificación para días concretos, unos para un día pasado para el cual se conoce el precio de cierre y otros para el día siguiente, sin conocer información a cerca del precio para ese día. Este último modelo es el que tiene más sentido seguir desarrollando, ya que

en la realidad, no se conoce de antemano el precio que va a alcanzar un activo en el futuro.

Esta aplicación podría ser más útil aplicada a datos intradiarios, en los que la ventana de tiempo con la que se trabaja sea de 20 minutos o incluso segundos, en lugar de días. De esta forma, el modelo convolucional de regresión entrenado podría ser aplicado para calcular el modelo exacto del día en el que se debería comprar o vender una acción, para seguir una estrategia de inversión de alta frecuencia.

Por otro lado, como futuro desarrollo adicional, se propone aumentar el número de muestras con las que se entrenen los modelos para así conseguir una mayor precisión en la clasificación.

REFERENCIAS

- [1] "Polygant," [Online]. Available: <https://polygant.net/ai/artificial-intelligence-for-trading>.
- [2] N. Cohen, T. Balch and M. Veloso, "Trading via Image Classification," *JP Morgan*, 2019.
- [3] [Online]. Available: <https://github.com/alvarobartt/investpy>.
- [4] "Investopedia," [Online]. Available: <https://www.investopedia.com/terms/b/bollingerbands.asp>.
- [5] [Online]. Available: <https://decodingmarkets.com/mean-reversion-trading-strategy/#:~:text=A%20mean%20reversion%20trading%20strategy%20involves%20betting%20that%20prices%20will,develop%20strategies%20for%20both%20phases..>