



COMILLAS

UNIVERSIDAD PONTIFICIA

ICAI

MÁSTER UNIVERSITARIO EN INGENIERÍA INDUSTRIAL

TRABAJO FIN DE MÁSTER

APLICACIÓN DE TÉCNICAS CUANTITATIVAS EN EL ANÁLISIS DE COTIZACIONES EN MERCADOS ENERGÉTICOS

Autor: Alejo Márquez Larrea

Director: Alexandra Cifuentes Quintero

Co-Director: Antonio Bello Morales

Madrid

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título aplicación de técnicas cuantitavas en el análisis de cotizaciones en mercados energéticos en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el curso académico 2021/22 es de mi autoría, original e inédito y no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido tomada de otros documentos está debidamente referenciada.

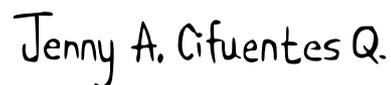


Fdo.: Alejo Márquez Larrea

Fecha: 1/06/2022

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO



Fdo.: Alexandra Cifuentes

Fecha: 18/07/2022

EL CODIRECTOR DEL PROYECTO



Fdo.: Antonio Bello

Fecha: 18/ 07/ 2022

Agradecimientos

A mis directores Alexa y Antonio, que a pesar de la distancia y los problemas que surgieron en el trabajo, no dudaron en regalarme parte de su tiempo para formarme y ayudarme.

Desde aquí un fuerte abrazo, espero algún día poder devolverles el favor.

AUTORIZACIÓN PARA LA DIGITALIZACIÓN, DEPÓSITO Y DIVULGACIÓN EN RED DE PROYECTOS FIN DE GRADO, FIN DE MÁSTER, TESIS O MEMORIAS DE BACHILLERATO

1º. Declaración de la autoría y acreditación de la misma.

El autor D. Alejo Márquez Larrea DECLARA ser el titular de los derechos de propiedad intelectual de la obra: Desarrollo y evaluación de estrategias automáticas de trading aplicadas a mercados energéticos globales, que ésta es una obra original, y que ostenta la condición de autor en el sentido que otorga la Ley de Propiedad Intelectual.

2º. Objeto y fines de la cesión.

Con el fin de dar la máxima difusión a la obra citada a través del Repositorio institucional de la Universidad, el autor **CEDE** a la Universidad Pontificia Comillas, de forma gratuita y no exclusiva, por el máximo plazo legal y con ámbito universal, los derechos de digitalización, de archivo, de reproducción, de distribución y de comunicación pública, incluido el derecho de puesta a disposición electrónica, tal y como se describen en la Ley de Propiedad Intelectual. El derecho de transformación se cede a los únicos efectos de lo dispuesto en la letra a) del apartado siguiente.

3º. Condiciones de la cesión y acceso

Sin perjuicio de la titularidad de la obra, que sigue correspondiendo a su autor, la cesión de derechos contemplada en esta licencia habilita para:

- a) Transformarla con el fin de adaptarla a cualquier tecnología que permita incorporarla a internet y hacerla accesible; incorporar metadatos para realizar el registro de la obra e incorporar “marcas de agua” o cualquier otro sistema de seguridad o de protección.
- b) Reproducir la en un soporte digital para su incorporación a una base de datos electrónica, incluyendo el derecho de reproducir y almacenar la obra en servidores, a los efectos de garantizar su seguridad, conservación y preservar el formato.
- c) Comunicarla, por defecto, a través de un archivo institucional abierto, accesible de modo libre y gratuito a través de internet.
- d) Cualquier otra forma de acceso (restringido, embargado, cerrado) deberá solicitarse expresamente y obedecer a causas justificadas.
- e) Asignar por defecto a estos trabajos una licencia Creative Commons.
- f) Asignar por defecto a estos trabajos un HANDLE (URL *persistente*).

4º. Derechos del autor.

El autor, en tanto que titular de una obra tiene derecho a:

- a) Que la Universidad identifique claramente su nombre como autor de la misma
- b) Comunicar y dar publicidad a la obra en la versión que ceda y en otras posteriores a través de cualquier medio.
- c) Solicitar la retirada de la obra del repositorio por causa justificada.
- d) Recibir notificación fehaciente de cualquier reclamación que puedan formular terceras personas en relación con la obra y, en particular, de reclamaciones relativas a los derechos de propiedad intelectual sobre ella.

5º. Deberes del autor.

- El autor se compromete a:
 - a) Garantizar que el compromiso que adquiere mediante el presente escrito no infringe ningún derecho de terceros, ya sean de propiedad industrial, intelectual o cualquier otro.
 - b) Garantizar que el contenido de las obras no atenta contra los derechos al honor, a la intimidad y a la imagen de terceros.
 - c) Asumir toda reclamación o responsabilidad, incluyendo las indemnizaciones por daños, que pudieran ejercitarse contra la Universidad por terceros que vieran infringidos sus derechos e intereses a causa de la cesión.
 - d) Asumir la responsabilidad en el caso de que las instituciones fueran condenadas por infracción

de derechos derivada de las obras objeto de la cesión.

6º. Fines y funcionamiento del Repositorio Institucional.

La obra se pondrá a disposición de los usuarios para que hagan de ella un uso justo y respetuoso con los derechos del autor, según lo permitido por la legislación aplicable, y con fines de estudio, investigación, o cualquier otro fin lícito. Con dicha finalidad, la Universidad asume los siguientes deberes y se reserva las siguientes facultades:

- La Universidad informará a los usuarios del archivo sobre los usos permitidos, y no garantiza ni asume responsabilidad alguna por otras formas en que los usuarios hagan un uso posterior de las obras no conforme con la legislación vigente. El uso posterior, más allá de la copia privada, requerirá que se cite la fuente y se reconozca la autoría, que no se obtenga beneficio comercial, y que no se realicen obras derivadas.
- La Universidad no revisará el contenido de las obras, que en todo caso permanecerá bajo la responsabilidad exclusiva del autor y no estará obligada a ejercitar acciones legales en nombre del autor en el supuesto de infracciones a derechos de propiedad intelectual derivados del depósito y archivo de las obras. El autor renuncia a cualquier reclamación frente a la Universidad por las formas no ajustadas a la legislación vigente en que los usuarios hagan uso de las obras.
- La Universidad adoptará las medidas necesarias para la preservación de la obra en un futuro.
- La Universidad se reserva la facultad de retirar la obra, previa notificación al autor, en supuestos suficientemente justificados, o en caso de reclamaciones de terceros.

Madrid, a ...1..... deJunio..... de ...2022...

ACEPTA



Fdo.....

Motivos para solicitar el acceso restringido, cerrado o embargado del trabajo en el Repositorio Institucional:

APLICACIÓN DE TÉCNICAS CUANTITATIVAS EN EL ANÁLISIS DE COTIZACIONES EN MERCADOS ENERGÉTICOS

Autor: Márquez Larrea, Alejo.

Director: Cifuentes Quintero, Alexandra.

Codirector: Antonio Bello Morales

Entidad Colaboradora: Instituto de Investigación Tecnológica.

RESUMEN DEL PROYECTO

Este trabajo trata de analizar e implementar estrategias algorítmicas de analítica de datos que permitan brindar soporte en el proceso de toma de decisiones en trading. A partir del estudio sobre algunas commodities energéticas, se identifica qué estrategias desempeñan mejores resultados en un ejercicio de clasificación y predicción.

Palabras clave: Commodities energéticas, predicción, redes neuronales y estadística.

1. Introducción

Las commodities energéticas tienen un gran peso en la economía afectando directamente al precio de los bienes de consumo y a los medios de producción. En los últimos meses esa influencia ha sido más notoria debido a los fenómenos geopolíticos, la volatilidad de los precios y la inflación en la economía.

A pesar de ser un mercado muy estudiado, el público general no conoce el funcionamiento de las materias primas energéticas ni su vulnerabilidad ante el cambio de precio de estas.

El creciente desarrollo de herramientas predictivas, la aplicación de técnicas que empleen inteligencia artificial y el uso de la estadística clásica hacen posible comprender mejor la evolución de los mercados.

Este proyecto se centra en dos commodities energéticas: el barril Brent y el TTF holandés; marcadores globales del precio del crudo de petróleo y el gas respectivamente; examina el estado del arte de herramientas predictivas, investiga cuáles de ellas son más apropiadas para los activos propuestos, teniendo como referencia:

- Estadística clásica: Profundiza en aquellos recursos empleados en la evaluación de funciones temporales, la clasificación de eventos y evaluación de métricas que ayuden no sólo a ver si existen patrones repetitivos en el progreso de los precios sino a posibles correlaciones entre ambas series; así la idea es presentar un análisis descriptivo que permita tener una caracterización preliminar de la naturaleza de los datos.
- Inteligencia artificial: Se especializa en las redes neuronales (ARN) y más concretamente en el Deep Learning. La capacidad de aprendizaje de las ARN y su adaptabilidad a entornos no lineales y poco predecibles son interesantes para el reconocimiento de patrones en series temporales. En los últimos años los resultados reportados en el campo de las redes neuronales han atraído el interés por este campo.

En este trabajo se presenta un descriptivo preliminar de los datos desde la perspectiva de la estadística clásica, así como el desarrollo de un caso de uso del machine learning. Esta aplicación es interesante de cara a abrir nuevas vías de investigación y de discusión sobre las ventajas y desventajas de su uso frente a modelos más tradicionales.

2. Definición del proyecto

Los objetivos fijados consisten en la aplicación de técnicas cuantitativas para la predicción a corto plazo de acciones bursátiles, presentando un caso de uso en los mercados energéticos.

El apartado de estadística tradicional se centra en analizar la correlación entre el precio del TTF y el barril Brent, así como las posibles correlaciones de los precios y volúmenes en bolsa.

El apartado de inteligencia artificial se centra en el desarrollo de ARN especializadas en clasificar y estimar el comportamiento de las bolsas en el futuro. Dentro de ellas, las técnicas desarrolladas son Long-Short Term Memory (LSTM), Multilayer Perceptron (MLP), Convolutional Neural Networks (CNN) y Autoencoders.

Una vez obtenidos los resultados, se pretende concluir acerca del desempeño de las técnicas implementadas, así como brindar un análisis de las futuras líneas de trabajo.

3. Descripción del modelo/sistema/herramienta

El software escogido para desarrollar los códigos es Python, que permite incorporar librerías abiertas para agilizar el proceso de programación. Los pasos a seguir independientemente de la técnica son:

- Obtención de los datos: Para que el proceso tenga el mayor grado de automatización posible se utiliza la técnica de web scraping, es decir, una vez escogida la plataforma web de la que se recogerán los datos, el programa descarga los datos y los adapta al formato que se desea.
La web de la que se recogen los datos es yahoo finance, aunque esta página posee una latencia de 15 minutos con respecto al valor real de los mercados, las escalas temporales con las que se van a trabajar sobrepasan los 30 días, (en donde para hacer predicciones de un día se requieren los datos de los 30 días anteriores) y no supone un problema.
Los datos históricos van de 2010 a 2020, un periodo lo suficientemente largo como para que los resultados recogidos sean válidos y no se vean alterados por eventos extraordinarios como el coronavirus o la invasión de Ucrania, que podrían distorsionar los modelos.
Cada activo recogido; TTF y el barril Brent; lleva referenciados los precios de apertura, cierre, máximos, mínimos, volumen y cierre ajustado de todos los días en los que las bolsas abrieron y comerciaron en el periodo descrito.
- Tratamiento de los datos: Una vez se tienen los datos, se deben organizar y estructurar para que no aparezcan problemas en la construcción de los modelos. Primero se comprueba que los datos recogidos no tengan celdas vacías en ninguna de las columnas, de ser así, todos los datos correspondientes a la fecha en la que se encuentre la celda vacía serán eliminados.

Según el modelo, es posible que además los datos requieran de redimensionamientos o escalas para poder ajustarse a los cánones de la estrategia empleada; esto sólo ocurrirá cuando se esté trabajando con ARN, que se deben ajustar a escalas 0-1 en el proceso de aprendizaje y ajustar sus datos en paquetes de diferentes dimensiones según la estrategia.

Además, las ARN realizan una división de los datos en dos subconjuntos: subconjunto de entrenamiento y subconjunto de prueba; el primero se emplea para que el sistema aprenda y el segundo, para validar su funcionamiento. La división de subconjuntos es crítica, porque el subconjunto de entrenamiento debe ser lo suficientemente grande para poder ser fiable pero no demasiado para no sesgar los resultados, en general se emplearán unos porcentajes para los subconjuntos de entrenamiento y prueba de 80 y 20 % respectivamente.

- Desarrollo de las herramientas: Este proceso es muy concreto de cada técnica y se basa en ajustar las restricciones de cada una y mirar en qué condiciones trabajan mejor. Para definir los datos se emplean técnicas estadísticas que exploren las características de las series y den una descripción clara sobre sus posibles usos. En la cointegración, por ejemplo, se busca que el spread entre los elementos analizados sea consistente a lo largo del tiempo y apruebe los exámenes de Granger y Dickey-Fuller.

Por su parte, con las Redes neuronales, se realiza la implementación de un conjunto de técnicas de predicción/clasificación y se evalúan diferentes configuraciones con el fin de identificar el conjunto de hiperparámetros que proveen el mejor desempeño. Para ello, se miden sus resultados por medio de errores como el Root Mean Square Error (RMSE), Mean Average Error (MAE) y métricas como la precisión, la sensibilidad y la especificidad. Aquí hay que tener presente que las ARN dividen sus datos en dos subconjuntos, de ser muy dispares los resultados entre sí, la herramienta corre el riesgo de estar siendo sobreentrenada, tener overfitting y no ser fiable en sus predicciones. Para solucionarlo, se deben cambiar los pesos del porcentaje de peso de cada subconjunto y utilizar técnicas de early stopping.

- Definición de la estrategia: Según el desempeño de cada técnica se debe ver cuáles son las que mejor funcionan, revisar los motivos y escoger aquella que tenga un mejor desempeño. También se pueden proponer nuevas versiones híbridas, que utilicen los beneficios de cada técnica.

A continuación, se hace un resumen de las técnicas empleadas:

- **Estadística clásica**: Dentro de esta categoría se profundiza sobre las siguientes aplicaciones para un análisis descriptivo de los datos:
 - Cointegración: Comprueba si se muestran correlaciones que perduren en el tiempo por medio de las pruebas de Engle-Granger y Dickey-Fuller aumentada. Algunos test como Johansen analizan si existen múltiples cointegraciones en las series, revisando un espectro más amplio que las pruebas de Engle-Granger y Dickey-Fuller aumentada. Si la diferencia de precios entre las commodities permanece constante, muchos estudios aseguran que en ciertos contextos están conectados, aunque este documento estudia su cumplimiento en una franja temporal de 10 años.
- **Inteligencia Artificial**: Se investigan distintos tipos de redes neuronales para tratar de identificar la configuración con el mejor desempeño con los mercados bursátiles:
 - Long-short term memory (LSTM): Técnica que recoge los datos de los 30 días previos de la bolsa y estima cuál será el precio de apertura del día siguiente. Es

muy popular y se basa en que, con unos datos de entrada, la herramienta es capaz de anticiparse a los próximos eventos. Hay que notar que cuanto más se alejen esos sucesos de los datos de partida, menos confiable será.

El funcionamiento de una LSTM consiste en el flujo de datos a través de capas que tienen puertas de memoria y de olvido, según los requisitos que se establezcan la red decidirá si la información que le llega es suficientemente relevante para recordarla para posteriormente mandarla a la puerta de salida.

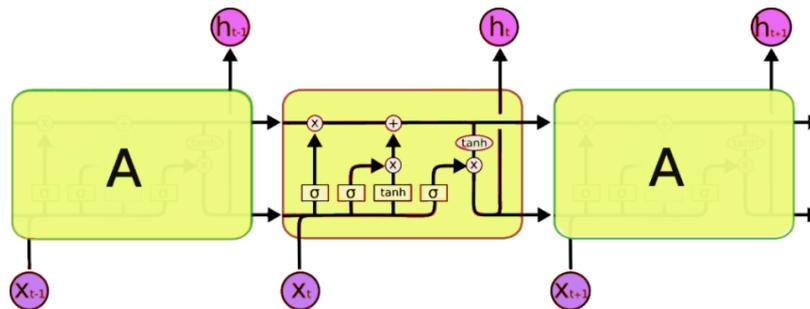


Ilustración 1 – Funcionamiento de una LSTM [1]

La Ilustración 1 muestra como la información fluye por distintas capas, cada una con puertas de memoria y olvido, hasta llegar a la puerta final.

Multilayer Perceptron (MLP): El MLP es un tipo de red neuronal compuesto por varias capas de perceptrones que pueden estar total o localmente conectadas. A diferencia del LSTM, el MLP se usa en este trabajo como un clasificador, en vez de estimar el precio que alcanzarán las commodities, recoge los datos de los 30 días anteriores y decide si el día siguiente será un día alcista o no.

Su composición consiste en tres tipos de capas: entrada, oculta y salida. En la capa de entrada se fijan un número de perceptrons o neuronas, a cada una se le asigna un peso diferente en su camino hacia las capas escondidas, donde por medio de una función de activación se definen los atributos que van a la capa de salida, que también tiene una función de activación antes de la salida final de la red.

¹ Grandic, I. “How LSTMs work”, Mayo 2010, [How LSTMs work. I've always been compared to a... | by Isabella Grandic | Medium.](#)

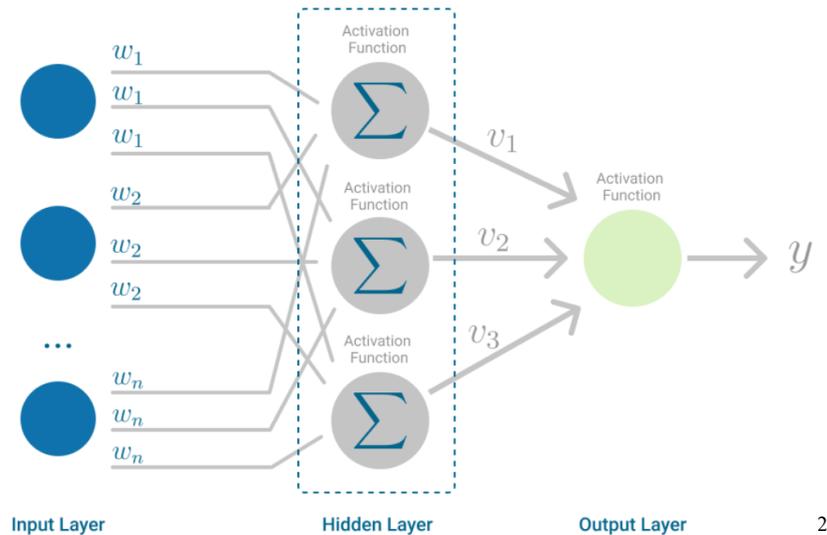


Ilustración 2 – Funcionamiento de un MLP [2]

- **Convolutional Neural Networks (CNN):** Al igual que en el caso del MLP, las CNN se emplean como clasificadores, que con los datos de los precios de las bolsas de los días anteriores trata de predecir si el día siguiente será alcista o no. Es muy empleado en reconocimiento de imágenes, de forma que en este caso se traduce la información de números a píxeles por medio de representaciones gráficas del comportamiento de los mercados. Las CNN tienen tres tipos de capas: convolutional, pooling y fully-connected layer. Los datos pasan por unos filtros hasta llegar al primer tipo de capa, donde se reconocen patrones dividiendo las imágenes por píxeles, de ahí va a la pooling layer, que abstrae la información, toma la información más importante y la envía a la capa fully-connected, que estima la predicción.

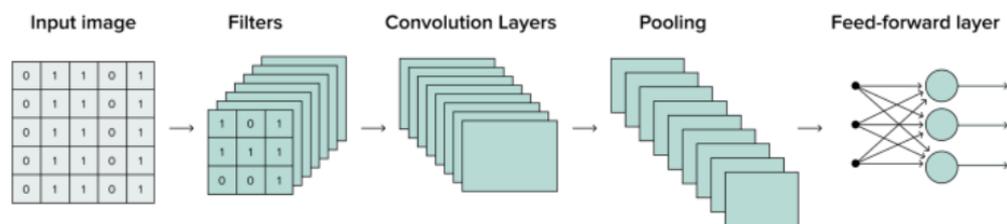


Ilustración 3 – Funcionamiento de una CNN [3]

- **Autoencoders:** La LSTM, como el autoencoder, trata de averiguar cuál será el precio de apertura de los mercados a partir de la evolución de los días anteriores. Se emplea ampliamente como solución híbrida junto a otros tipos de ARN.

En este trabajo se emplea como solución híbrida junto a la LSTM, luego su funcionamiento es muy parecido, salvo que en este caso se aplican funciones de activación y la librería Keras de Python.

² Bento, C. “Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis”, Towards Data Science, September 2021. Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis | by Carolina Bento | Towards Data Science

Los autoencoders y las CNN son dos técnicas más complejas que el LSTM y el MLP, que se han incorporado porque tal y como se detalla en el apartado 4 Resultados, presentan mejores métricas de desempeño.

4. Resultados

Según la metodología empleada, en primer lugar se realiza un descriptivo basado en la estadística tradicional. Los valores obtenidos en las pruebas de Granger y Dickey-Fuller muestran que son series con no linealidades, y con presencia de cambios estructurales.

Las diferencias entre los precios del barril Brent y el TTF tampoco son constantes en el tiempo y no se pueden considerar cointegrables. La Ilustración 3, refleja la diferencia de spreads en el tiempo:

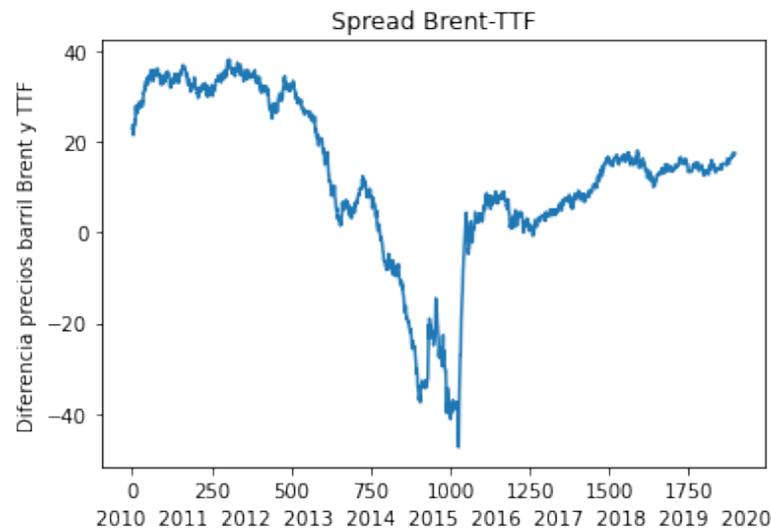


Ilustración 4 – Precio Barril Brent – Precio TTF en el tiempo

El precio del barril Brent y el TTF no están cointegrados en el margen temporal estudiado. Sin embargo, hay que notar que en algunos periodos esas diferencias de precios sí se mantienen constantes, de forma que se puede asumir que tal y como afirman algunos estudios, es posible que el precio de estos activos sí estén cointegrados en algunas ventanas concretas.

En cuanto a las redes neuronales, hay que hacer una diferencia entre las redes empleadas para roles clasificadores y las regresoras. En las redes entrenadas para clasificación, la CNN es el modelo que ha obtenido los mejores resultados con una exactitud notablemente superior al MLP. En las regresoras, la LSTM+ Autoencoders ha obtenido mejores resultados que la LSTM individual con errores RMSE más bajos.

Las CNN y los Autoencoders funcionan mejor que el resto de técnicas porque incluyen sistemas más complejos, capaces de identificar patrones y secuencias menos predecibles a través del reconocimiento de series por medio de funciones objetivo, de activación y optimizadores matemáticos; estas incorporaciones hacen que las ARN sean más flexibles y se adapten mejor a un entorno cambiante y complejo como la bolsa.

5. Conclusiones

Los mercados bursátiles analizados tienen una complejidad enorme de predecir que hacen que no todas las técnicas sean válidas. Cuanto más flexible sea una metodología,

más fácil es que sea capaz de adaptarse a este medio, de forma que en base a los resultados obtenidos se puede afirmar:

- La estadística clásica ha probado en numerosos estudios ser una buena herramienta para el estudio de series temporales, pero la literatura del estado del arte argumenta que las técnicas de Machine Learning reportan mejores métricas en su desempeño.
- El volumen y el precio están directamente correlacionados.
- Existen muchos tipos de ARN, cada una con sus ventajas e inconvenientes, las redes neuronales recurrentes, como las LSTM, tienen unas características adecuadas para la predicción de series temporales, mientras que las redes neuronales artificiales profundas, como la CNN, pueden utilizarse como clasificadoras eficientemente para esta aplicación específica.
- Los sistemas híbridos de CNN o Autoencoders con otra clase de ARN podrían mejorar los resultados respecto a lo que hicieran cada una por separado.
- Los algoritmos que proyectan la evolución de los precios en bolsa son funcionales, pero tienen ciertas limitaciones, se recomienda aplicar técnicas adicionales que corroboren sus predicciones.

6. Referencias

- [1] Grandic, I. “How LSTMs work”, izzygrandic ,Mayo 2010,
<https://izzygrandic.medium.com/how-lstms-work-263ac4e412ba#:~:text=LSTMs%20are%20a%20type%20of,can%20have%20a%20better%20memory.&text=Step%201%3A%20When%20the%203,forget%20gate%2C%20or%20learn%20gate.>
- [2] Bento, C. “Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis”, Towards Data Science, September 2021.
<https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis-cb408ee93141#:~:text=A%20Multilayer%20Perceptron%20has%20input,use%20any%20arbitrary%20activation%20function.>
- [3] Gavrilova, J. “Convolutional Neural Networks for Beginners”, Serokell, Agosto 2021.
<https://serokell.io/blog/introduction-to-convolutional-neural-networks.>

APPLICATION OF QUANTITATIVE TECHNIQUES IN THE ANALYSIS OF PRICES IN ENERGY MARKETS

Author: Márquez Larrea, Alejo.

Supervisor: Cifuentes Quintero, Alexandra.

Collaborating Entity: Instituto de Investigación Tecnológica.

ABSTRACT

This work tries to analyze and develop algorithmic strategies of advanced data analytics that allow to provide support in the decision-making process in trading. From the study on some energy commodities, it is identified which strategies perform better results in a classification and prediction exercise.

Keywords: Energy commodities, prediction, neural networks and statistics.

1. Introduction

Energy commodities have a great weight in the economy, directly affecting the price of consumer goods and the means of production. In recent months, this influence has been more noticeable due to geopolitical phenomena, price volatility and the inflation in the economy.

Despite being a well-studied market, the general public does not know how energy raw materials work or their vulnerability to price changes.

The growing development of predictive tools, the application of techniques that use artificial intelligence and the use of classical statistics make it possible to better understand the evolution of the markets.

This project focuses on two energy commodities: the Brent barrel and the Dutch TTF; global crude oil and gas price markers respectively; examines the state of the art of predictive tools, investigates which of them are more appropriate for the proposed assets, having as reference:

- Classic Statistics: Goes deeper into those resources used in the evaluation of temporary functions, the classification of events and the evaluation of metrics that help not only to see if there are repetitive patterns in the progress of prices, but also to see possible correlations between both series. Thus, the idea is to present a descriptive analysis that allows for a preliminary characterization of the nature of the data.
- Artificial intelligence: It specializes in Neural Networks (ARN) and more specifically in Deep Learning. The learning capacity of ARNs and their adaptability to non-linear and unpredictable environments are interesting for pattern recognition in time series. In recent years, the results reported in the field of neural networks have attracted interest in this field.

This paper presents a preliminary description of the data from the perspective of classical statistics, as well as the development of a machine learning use case. This application is interesting in terms of opening new avenues of research and discussion on the advantages and disadvantages of its use compared to more traditional models.

2. Project Definition

The objectives set consist of the application of quantitative techniques for the short-term prediction of stock market actions, presenting a use case in the energy markets.

The traditional statistics section focuses on analyzing the correlation between the price of the TTF and the Brent barrel, the possible correlations of prices and volumes on the stock market, as well as other existing patterns in the series.

The artificial intelligence section focuses on the development of ARNs specialized in classifying and estimating the behavior of stock markets in the future. Among them, the techniques developed are Long-Short Term Memory (LSTM), Multilayer Perceptron (MLP), Convolutional Neural Networks (CNN) and Autoencoders.

Once the results are obtained, it is intended to conclude about the performance of the implemented techniques, as well as to provide an analysis of future lines of work.

3. Model description

The software chosen to develop the codes is Python, which allows the incorporation of public libraries to speed up the programming process. The steps to follow regardless of the technique are:

- Obtaining the data: For the process to have the highest degree of automation possible, the web scraping technique is used, that is, once the web platform from which the data will be collected has been chosen, the program downloads the data and adapts it to the desired format.

The website from which the data is collected is yahoo finance, although this page has a latency of 15 minutes with respect to the real value of the markets, the time scales with which they are going to work exceed 30 days (to estimate the behaviour of the next day, the data required involves the 30 previous days) and it is not a major problem.

The historical data goes from 2010 to 2020, a period long enough for the results collected to be valid and not to be altered by extraordinary events such as the coronavirus or the invasion of Ukraine, which could distort the models.

Every asset collected; TTF and the Brent barrel; It references the opening, closing, maximum, minimum, volume and adjusted closing prices of all the days in which the stock exchanges opened and traded in the period described.

- Data treatment: Once the data is available, it must be organized and structured so that problems do not appear with the development of the algorithms. First, it is verified that the collected data does not have empty cells in any of the columns, if so, all the data corresponding to the date in which the empty cell is found will be therefore eliminated.

Depending on the model, it is possible that the data also require resizing or scaling to be able to adjust to the canons of the strategy used; this will only happen when working with ARN, which must be adjusted to scales 0-1 in the

learning process and adjust their data in packages of different dimensions according to the strategy.

In addition, the ARN perform a division of the data into two subsets: training subset and test subset; the first is used for the system to learn and the second, to validate its operation. The division of subsets is critical, because the training subset must be large enough to be reliable but not too large so as not to bias the results; in general, percentages for the training and test subsets of 80 and 20%, respectively, will be used.

- **Tool development**: This process is very specific to each technique and is based on adjusting the restrictions of each one and looking under what conditions they work best. To define the data, statistical techniques are used to explore the characteristics of the series and give a clear description of their possible uses. In cointegration, for example, the spread between the analyzed elements is expected to be consistent over time and to pass the Granger and Dickey-Fuller tests. On the other hand, with Neural Networks, the implementation of a set of prediction/classification techniques is carried out and different configurations are evaluated in order to identify the set of hyperparameters that provide the best performance. To do this, their results are measured by means of errors such as the Root Mean Square Error (RMSE), Mean Average Error (MAE) and metrics such as precision, sensitivity and specificity. Here we must bear in mind that the ARN divide their data into two subsets, if the results are very different from each other, the tool runs the risk of being overtrained, having overfitting and not being reliable in its predictions. To solve this, the weights of the weight percentage of each subset must be changed and early stopping techniques must be used.
- **Definition of the strategy**: Depending on the performance of each technique, it is necessary to see which ones work best, review the reasons and choose the one with the best performance. New hybrid versions can also be proposed, using the benefits of each techniques.

Below is a summary of the techniques used:

Classic Statistics: Within this category, the purpose of the following applications are set for a descriptive analysis of the data are deepened:

Cointegration: Checks whether correlations are shown that last over time by means of the Engle-Granger and augmented Dickey-Fuller tests. Some tests such as Johansen analyze whether there are multiple cointegrations in the series, reviewing a broader spectrum than the Engle-Granger and augmented Dickey-Fuller tests. If the difference in prices between commodities remains constant, many studies assure that in certain contexts they are connected, although this document studies whether it is fulfilled in a time frame of 10 years, not only in some situations.

- **Artificial Intelligence:** Different types of neural networks are investigated to try to identify the configuration with the best performance with the stock markets:
 - **Long-short term memory (LSTM)**: Technique that collects data from the previous 30 days of the stock market and estimates what the opening price will be the following day. It is very popular and is based on the fact that, with some input data, the tool can anticipate upcoming events. Note that the further these events are from the starting data, the less reliable it is. The operation of an LSTM consists of the flow of data through layers that have memory and forgetting gates, depending on the requirements established, the

network will decide if the information that arrives is relevant enough to remember it and then send it to the gate. out or forget it.

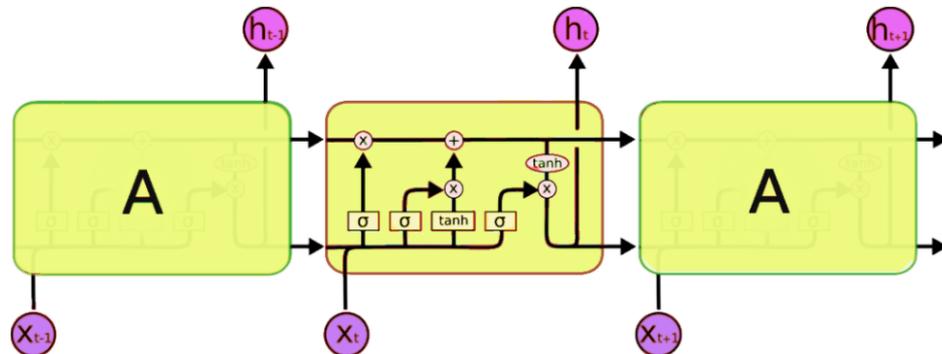


Figure 1 – Operation of a LSTM.

Figure 1 shows how information flows through different layers, each with memory and forgetting gates, until it reaches the final gate.

Multilayer Perceptron (MLP): The MLP is a type of neural network composed of several layers of perceptrons that can be totally or locally connected. Unlike the LSTM, the MLP is used in this work as a classifier, instead of estimating the price that the commodities will reach, it collects the data of the previous 30 days and decides if the next day will be a bullish day or not.

Its composition consists of three types of layers: input, hidden and output. In the input layer a number of perceptrons or neurons are fixed, each one is assigned a different weight on its way to the hidden layers, whereby means of an activation function the attributes that go to the output layer are defined, which also has an activation function before the final output of the network.

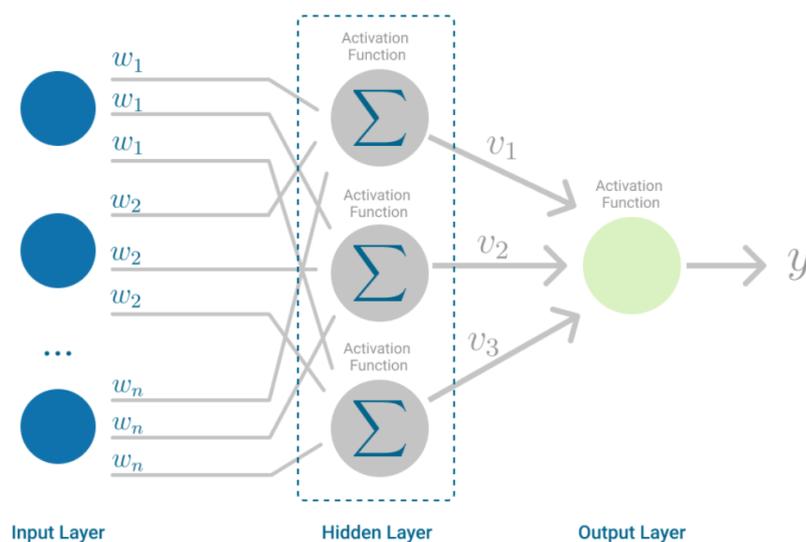


Figure 2 – Operation of a MLP

- Convolutional Neural Networks (CNN): As in the case of the MLP, the CNNs are used as classifiers, which with the stock price data of the previous days try to predict whether the next day will be bullish or not. It is widely used in image recognition, so that in this case the information is translated from numbers to pixels by means of graphic representations of the behaviour of the markets. CNNs have three types of layers: convolutional, pooling, and fully connected layers. The data goes through filters until it reaches the first type of layer, where patterns are recognized by dividing the images by pixels, from there it goes to the pooling layer, which abstracts the information, takes the most important information and sends it to the fully-fledged layer. connected, which estimates the prediction.

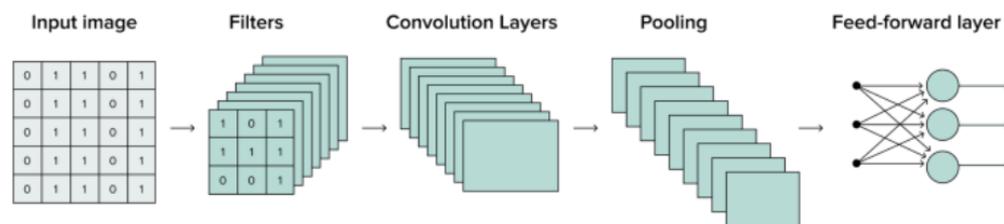


Figure 3 – Operation of a CNN

- Autoencoders: The LSTM, like the autoencoder, tries to find out what the opening price of the markets will be based on the evolution of the previous days. It is widely used for image recognition and as a hybrid solution together with other types of RNA. In this work, it is used as a hybrid solution together with the LSTM, so its operation is very similar, except that in this case activation functions and the Python Keras library, very popular for image analysis, are applied. Autoencoders and CNNs are two more complex techniques than LSTM and MLP, which have been incorporated because, as detailed in section 4 Results, they present better performance metrics.

4. Results

According to the methodology used, first a description is made based on traditional statistics. The values obtained in the Granger and Dickey-Fuller tests show that they are series with non-linearities, and with the presence of structural changes.

The differences between the prices of a Brent barrel and the TTF are also not constant over time and cannot be considered cointegrated. Illustration 3 reflects the difference in spreads over time:

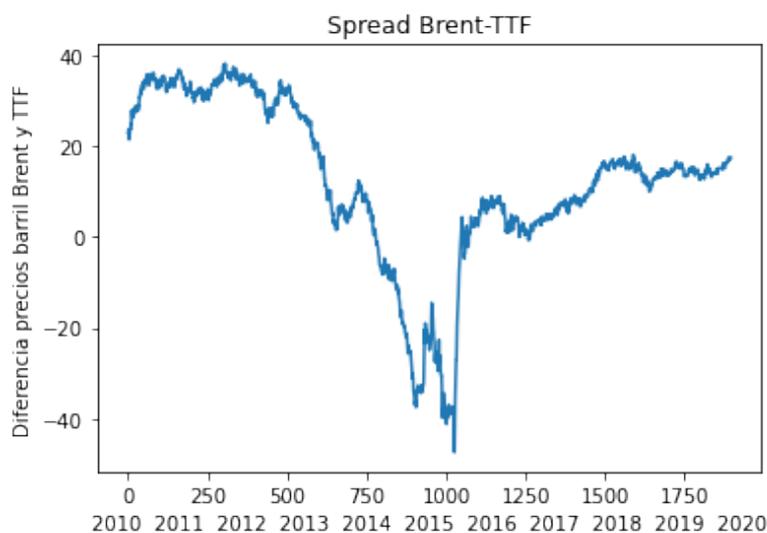


Figure 4 – Brent barrel's price – TTF's price in time

The price of a Brent barrel and the TTF are not co-integrated in the time frame studied. However, it should be noted that in some periods these price differences do remain constant, so that it can be assumed that, as some studies affirm, it is possible that the price of these assets are co-integrated in some specific windows.

Regarding the neural networks, a difference must be made between the networks used for classifying roles and the estimators. In the networks trained for classification, the CNN is the model that has obtained the best results with an accuracy notably superior to the MLP. In the estimators, the LSTM has obtained worse results than the Autoencoders + LSTM with significantly higher RMSE errors.

CNNs and Autoencoders work better than the rest of the techniques because they include more complex systems, capable of identifying patterns and less predictable sequences through the recognition of series by means of objective functions, activation functions and mathematical optimizers; these incorporations make the RNAs be more flexible and adapt better to a changing and complex environment such as the stock market.

5. Conclusions

The analyzed stock markets have an enormous complexity to predict, which means that not all techniques are valid. The more flexible a methodology is, the easier it is for it to be able to adapt to this environment, so that based on the results obtained, it can be stated:

- Volume and price are directly correlated, so all those techniques that are based on this combination have a mathematical basis behind them.
- Classical statistics have proven in numerous studies to be a good tool for the study of time series, but the state-of-the-art literature argues that Machine Learning techniques report better performance metrics.
- There are many types of ARN, each with its advantages and disadvantages, recurrent neural networks, such as LSTM, have characteristics suitable for time

series prediction, while deep artificial neural networks, such as CNN, can be used as classifiers sorters efficiently.

- Hybrid systems of CNN or Autoencoders with another class of ARN could improve the results with respect to what each one would do separately, as long as the counterparts of the models are compatible.
- The algorithms that project the evolution of stock prices are functional, but they have certain limitations. It is recommended to apply additional techniques that corroborate their predictions.

6. References

- [1] Grandic, I. “How LSTMs work”, izzygrandic ,Mayo 2010,
<https://izzygrandic.medium.com/how-lstms-work-263ac4e412ba#:~:text=LSTMs%20are%20a%20type%20of,can%20have%20a%20better%20memory.&text=Step%201%3A%20When%20the%203.forget%20gate%2C%20or%20learn%20gate.>
- [2] Bento, C. “Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis”, Towards Data Science, September 2021.
<https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis-cb408ee93141#:~:text=A%20Multilayer%20Perceptron%20has%20input,use%20any%20arbitrary%20activation%20function.>
- [3] Gavrilova, J. “Convolutional Neural Networks for Beginners”, Serokell, Agosto 2021.
<https://serokell.io/blog/introduction-to-convolutional-neural-networks.>

Índice de la memoria

Capítulo 1. Introducción	6
1.1 Mercados energéticos globales: gas y petróleo	9
1.2 Estrategias.....	12
1.3 Motivación del proyecto	15
1.4 Objetivos.....	16
Capítulo 2. Estado de la Cuestión	18
2.1 Conceptos elementales de métodos predictivos	18
2.2 Metodologías empleadas	21
2.2.1 Modelos estadísticos.....	21
2.2.2 Modelos de inteligencia artificial.....	25
2.2.3 Estado del arte.....	33
Capítulo 3. Descripción del modelo desarrollado.....	39
3.1 Descripción del modelo desarrollado	39
3.2 Datos.....	40
3.3 Algoritmos	46
3.4 Implementación numérica	47
3.4.1 Estadística tradicional.....	47
3.4.2 Deep learning	48
Capítulo 4. Análisis de los resultados	54
4.1 Resultados.....	54
4.1.1 Estadística tradicional.....	54
4.1.2 Deep learning	55
4.2 Observaciones.....	59
Capítulo 5. Conclusiones y Trabajos Futuros.....	61
Capítulo 6. Bibliografía.....	63
ANEXO I	65
ANEXO II	68

Índice de figuras

Ilustración 1. Declaración del interés de Goldman Sachs por programas predictivos [1].....	7
Ilustración 2. Resultados de Goldman Sachs con algoritmos predictivos en bolsa [1].....	8
Ilustración 3. Porcentaje de personas que pierden dinero en bolsa [2].....	9
Ilustración 4 Evolución Energía 2020-2021	10
Ilustración 5 Comparación de los precios del gas y la electricidad en España 20-21 ¡Error!	
Marcador no definido.	
Ilustración 6. Precio TTF 2011-2021 [3].....	11
Ilustración 7. Precio NBP 2007-2021[3]	12
Ilustración 8. Resultados de Goldman Sachs en comparación con el SP500 [1]	16
Ilustración 9. Ejemplo tratamiento de una imagen en una CNN [7]	32
Ilustración 10. Representación de un autoencoder.[8]	33
Ilustración 11. Representación gráfica de los datos del barril Brent.	42
Ilustración 12. Representación gráfica de los datos del barril Brent con velas japonesas. .	42
Ilustración 13. Diagramas de bigotes de los datos de los precios del barril Brent.	44
Ilustración 14. Diagramas de bigotes de los datos de los precios del TTF.....	45
Ilustración 15. Diferencia entre los precios del Barril Brent y el TTF holandés.....	54
Ilustración 16. Resultado código LSTM 2.....	56
Ilustración 17. Resultado código LSTM 1..... ¡Error! Marcador no definido.	
Ilustración 18. ODS número 8.....	65
Ilustración 19. ODS número 10.....	66

Índice de tablas

Table 1. Comparativa de estrategias.....	35
Table 2. Ejemplo datos recogidos.....	41
Table 3. Missing values de los datos recogidos.....	43
Table 4 Ficha del programa LSTM	49
Table 5 Ficha del programa LSTM 2	50
Table 6 Ficha del programa CNN.....	52
Table 7 Ficha del programa Autoencoder + LSTM.	53
Table 8 Resultados LSTM.....	57
Table 9 Resultados Autoencoder +LSTM.....	59

Índice de abreviaturas

ARN	Artificial Neural Network
TTF	Title Transfer Facility
IA	Inteligencia Artificial
DL	Deep Learning
MAE	Medium Average Error
RMSE	Root Mean Square Error
RMSD	Root Mean Square Deviation
ANN	Artificial Neural Network
LSTM	Long Short Term Memory
MLP	Multilayer Perceptron
CNN	Convulational Neural Network
SVM	Support Vector Machine

Capítulo 1. INTRODUCCIÓN

En los últimos años se ha experimentado una volatilidad en los mercados bursátiles que pocos han sido capaces de prever, el coronavirus y la invasión de Ucrania han sido dos acontecimientos que han pillado por sorpresa hasta a los analistas más experimentados.

Los volúmenes de acciones, derivados y resto de productos financieros han subido y bajado a velocidades vertiginosas, se ha tenido que llegar a cerrar bolsas enteras para frenar la avalancha de bajadas en los índices y los mercados centrales se han visto obligados a actuar para contener las economías.

Uno de los sectores que más se han visto afectado por estos movimientos son las commodities energéticas. La invasión de Ucrania ha tenido un papel muy importante en el encarecimiento de las materias primas energéticas, pero además existen otros factores que impactan directamente en su precio como la crisis de suministros, la transición ecológica y el aumento de la demanda de electricidad de países con altas tasas de crecimiento como China o la India.

La importancia de la evolución de los mercados energéticos está en su fuerte correlación con la economía, pues son muchos los estudios que afirman que existe una relación inversa entre la economía y los precios de las commodities energéticas. Norasyikin Abdullah Fahami profesor de la Faculty of Business Management MARA University of Technology Malaysia afirma en su trabajo “An Econometric Analysis between Commodities and Financial Variables: The Case of Southeast Asia Countries” que el valor de las commodities es proporcional a la evolución de la economía. En casos como el oro, la relación es directamente proporcional, mientras que, en otros como el petróleo, es inversamente proporcional.

Además, el impacto de la energía en los pequeños consumidores es directo e indirecto, pues su alcance llega desde la gasolina para repostar vehículos y la electricidad de uso doméstico, hasta el incremento de los bienes de producción por el incremento de los costes de operación. Ningún sector se salva de la influencia de estos activos. La suma de la impredecibilidad de los mercados y la importancia de la energía resulta en un cóctel inflacionario que afecta

directamente en el día a día de las personas. Donde hay un problema existe una oportunidad, o al menos eso es lo que han debido de pensar muchos bancos de inversión, hedge fund, fondos de inversión y académicos, pues en los últimos años han aparecido multitud de técnicas que tratan de pronosticar cómo será la evolución de los mercados.

Los análisis técnicos, los algoritmos de predicción y los complejos sistemas computacionales se han vuelto el pan de cada día para este tipo de instituciones. Sin ir más lejos, el conocido banco de inversión Goldman Sachs publicó este escrito en su reporte anual de 2020:

The growth of electronic trading and the introduction of new trading technology has increased competition.

Technology is fundamental to our business and our industry. The growth of electronic trading and the introduction of new technologies is changing our businesses and presenting us with new challenges. Securities, futures and options transactions are increasingly occurring electronically, both on our own systems and through other alternative trading systems, and it appears that the trend toward alternative trading systems will continue. Some of these alternative trading systems compete with us, particularly our exchange-based market-making activities, and we may experience continued competitive pressures in these and other areas. In addition, the increased use by our clients of low-cost electronic trading systems and direct electronic access to trading markets could cause a reduction in commissions and spreads. As our clients increasingly use our systems to trade directly in the markets, we may incur liabilities as a result of their use of our order routing and execution infrastructure.

We have invested significant resources into the development of electronic trading systems and expect to continue to do so, but there is no assurance that the revenues generated by these systems will yield an adequate return, particularly given the generally lower commissions arising from electronic trades.

Ilustración 1. Declaración del interés de Goldman Sachs por programas predictivos [1]

La utilización de estas tecnologías para el trading de alta frecuencia es una realidad, de hecho, se dice que la volatilidad de los mercados está causada en parte por el empleo de estos esquemas, que al estar programados para detectar cualquier patrón en las bolsas, en el momento que hay un movimiento vertical ya sea alcista o decreciente, estos programas lo detectan y hacen que esos impulsos se prolonguen más debido a la automatización de sus procesos.

El trading intradía está gobernado por ordenadores y no es de extrañar, volviendo al ejemplo de Goldman Sachs, de acuerdo con el mismo reporte anual de 2020, sus resultados son sólidos y llevan tiempo demostrándolo; sólo en 2020 sus beneficios atribuibles a esta

estrategia de inversión fueron de 253 millones de dólares, casi igual que el año anterior que fueron de 252 millones de dólares.

\$ in millions	Year Ended December	
	2020	2019
>\$100	50	16
\$75 - \$100	37	17
\$50 - \$75	48	45
\$25 - \$50	51	71
\$0 - \$25	43	72
\$(25) - \$0	11	26
\$(50) - \$(25)	8	5
\$(75) - \$(50)	3	–
\$(100) - \$(75)	2	–
Total	253	252

Ilustración 2. Resultados de Goldman Sachs con algoritmos predictivos en bolsa [1]

Además, tal y como se puede apreciar en la Figura 2, no es sólo que sea una técnica muy rentable, sino que su control del riesgo está minuciosamente calculado; siendo el número de días que se ha perdido dinero 24 en 2020 y 31 en 2019, con una tendencia a la baja según se va incrementando las cantidades perdidas, es decir, que la probabilidad de perder una gran suma de dinero es inferior cuanto más alta sea esa cantidad.

A la vista de los resultados, no es de extrañar el interés por estos sistemas modernos. Entre otras virtudes, estos modelos tienen la capacidad de analizar el comportamiento de los mercados en cuestión de milésimas de segundo, no se ven influenciados por emociones y resultan bastante económicos de crear a las entidades que los programan; basta con una serie de personas con altos conocimientos estadísticos y de programación para construir un modelo de este estilo; a estas personas se las suele conocer en el mundo de la bolsa como quantifiers, personas de perfil técnico y grandes conocimientos informáticos.

Por otra parte, el interés y el fácil acceso a los mercados hace que en el momento que se redacta este trabajo muchas personas se sientan atraídas en invertir sus ahorros por esta vía para canalizar sus ahorros. Sin embargo, el desconocimiento en técnicas de inversión y la inestabilidad de los mercados hace que más del 60% de las personas que invierten en bolsa pierdan dinero a la larga.

Broker	Porcentajes 2020	Tipo de Bróker
ATFX	67,67%	STP/ECN
IG	68,00%	Market Maker/ ECN
CMC Markets	75,00%	Market Maker
GKFX	75,00%	NND
IBroker	77,83%	DMA/STP
XTB	77,00%	Market Maker/ECN
Activtrades	69,00%	ECN
Admiral Markets	76,00%	ECN/STP
Pepperstone	76,5%	ECN/STP
AxiTrader	65,60%	STP
Plus 500	76,40%	Market Maker
Darwinex	59,00%	STP/DMA
ETORO	62,00%	Market Maker
CAPEX.com	78,83%	STP
Plus500	76,4%	Market Maker

Ilustración 3. Porcentaje de personas que pierden dinero en bolsa [2]

Tal es la situación que se han creado organismos políticos expresamente diseñados para controlar el auge de plataformas de inversión online. La ESMA o Autoridad Europea de Valores y Mercados, es el ente regulador que se encarga de proteger a los pequeños inversores de este tipo de brokers modernos, de hecho, hoy en día es necesario que todos los brókers hagan que sus usuarios firmen un documento por el cual aseguran que conocen los riesgos de invertir en estos medios y que se les ha mostrado el porcentaje de éxito de otros usuarios.

1.1 MERCADOS ENERGÉTICOS GLOBALES: GAS Y PETRÓLEO

Aunque el interés por las commodities energéticas haya aumentado notablemente en los últimos meses, no se puede decir que hay sido un tema menor en los círculos de inversión. Su impacto en la economía, las fuertes barreras de entrada y relación íntima con el pequeño consumidor hace que sea un tema interesante.

Una de las características más llamativas de estos mercados es su estacionalidad a diferentes escalas, según se puede apreciar en las ilustraciones 4 y 5; que muestra el precio de la energía en el mercado español; el precio de la electricidad cambia significativamente en los meses de invierno y verano:

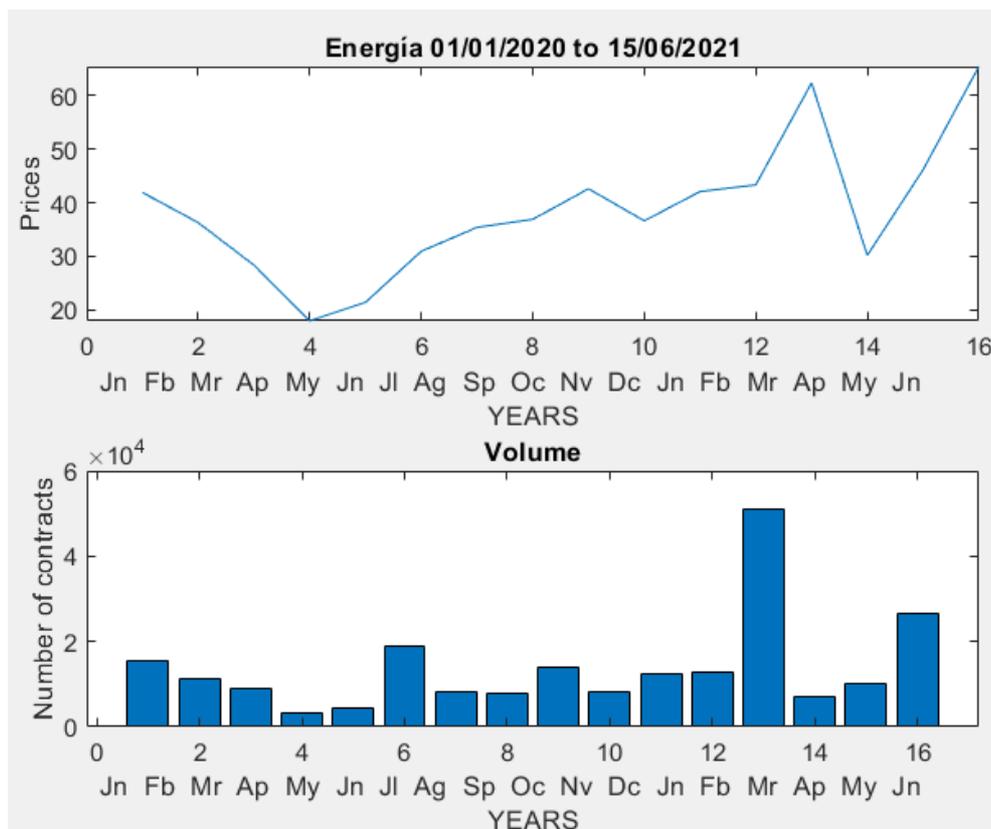


Ilustración 4 Evolución Energía 2020-2021

En el caso de España, la relación entre la energía y el gas es estrecha. Si se comparan los datos del precio de la energía, con los del gas, se puede observar una tendencia clara con relación directa para horizontes temporales lo suficientemente amplios.

En el estudio realizado por los investigadores de la universidad de Deusto Unai Casado y Macarena Larrea “Determinantes del precio de la electricidad en España”, aseguran que el mercado eléctrico español es complejo y sus resultados no logran las expectativas previstas. Sin embargo, sí logran comprobar que “ el gas y el carbón mantienen una relación positiva

con el precio de la electricidad, como era previsible debido al carácter marginalista del mercado eléctrico español.”³

Este fenómeno no es una excepción, sino que el mercado ibérico de gas tiene mucha dependencia del resto de mercados energéticos globales, y prueba de ello es la semejanza del precio del MIBGAS con otros productos de gas internacionales como el NBP británico, el TTF holandés o el mercado alemán.

Según los resultados obtenidos, el MIBGAS tiene cierto grado de correlación con el NBP británico, el TTF holandés, el VOB checo y el PSV italiano, aunque debido a las limitaciones de conexión y a la diferencia de temperaturas, el MIBGAS tiene más correlación con el índice negociado en Francia.

Se debe señalar que el TTF y el NBP evolucionan de manera parecida salvo en los meses de verano, ya que es esa época en donde el agente británico se encarga del mantenimiento. El TTF y el NBP son los dos Hubs de más liquidez y los que se utilizan como referencia en Europa y su mercado de futuros permite transacciones en todo el mundo con un movimiento idéntico a los de los mercados spot.

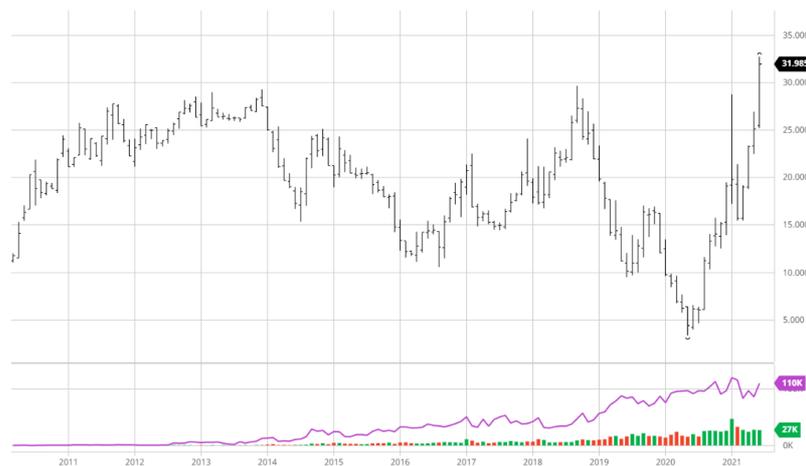


Ilustración 5. Precio TTF 2011-2021 [3]

³ Larrea, M y Casado U. “Determinantes del precio de la electricidad en España”. Volumen 59, número 194 / 2017, pp. 119-149.

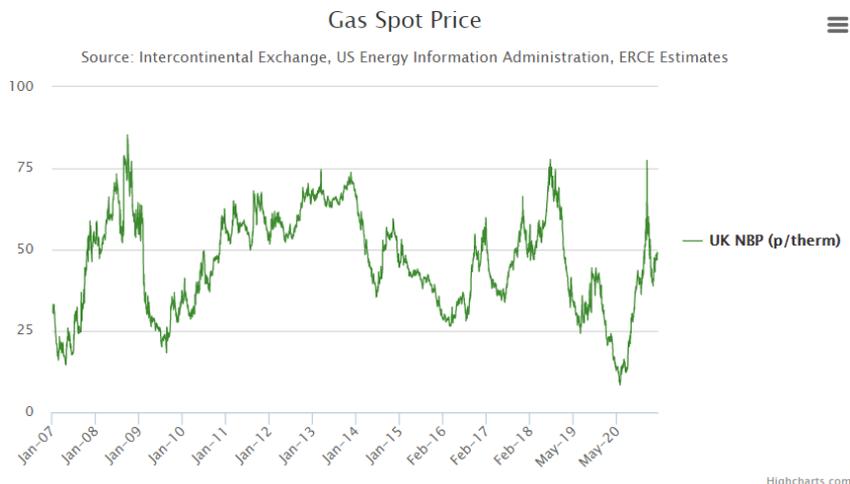


Ilustración 6. Precio NBP 2007-2021[3]

1.2 ESTRATEGIAS

Existen multitud de escritos y documentos que profundizan sobre métodos de inversión, algunos se basan en análisis fundamentales que profundizan sobre las características de cada activo, mientras que otros se centran en análisis técnicos con raíces estadísticas. Dentro de esta última vía se encuentran las estrategias multicommodity, que tratan de buscar influencias de unos activos sobre otros.

Las estrategias multi-commodity suelen ser concebidas para encontrar relaciones lineales entre commodities, pero dependiendo del grado de complejidad del algoritmo, se pueden encontrar relaciones no lineales. Dentro de las diferentes estrategias implementadas para la predicción de series de tiempo, es importante tener presente la definición de los siguientes conceptos:

- R2: Herramienta estadística que revisa cuánto se acercan unos datos a una línea de regresión ajustada. Su valor está entre el 0 y el 100% y permite evaluar el porcentaje de varianza de la variable dependiente que es explicada por la(s) variable(s) independiente(s).

- **Árbol de decisión:** Técnica de machine learning con un input y un output que es capaz de encontrar relaciones no lineales en el que existe un juicio binario donde cada opción está etiquetada con un nodo y las ramas corresponden a los valores que pueden tomar los literales. Se suele emplear para la toma de decisiones, estudia las probabilidades de las posibles acciones y revisa cuál es la que mejor se adapta para los objetivos buscados.
- **Teoría de Juegos:** Cada vez más popular, exige una simulación por fundamentales de todas las variables de entrada para comprobar cómo afecta al resultado final.

Dentro de este estilo se encuentra la simulación de Montecarlo, que se ha vuelto popular entre algunos directivos de Hedge Funds americanos como Cathie Wood por ser una técnica útil en la medición de riesgos.

- **Modelos ARIMA:** Autoregressive Integrated Moving Average, estrategia utilizada en la predicción de series a través de modelos estadísticos que se valen de medias móviles, regresiones y variaciones para encontrar secuencias de comportamiento.
- **Regresión dinámica:** Consiste en recoger datos atrasados de variables explicativas que se fundan en un proceso de transferencia para explicar el carácter de la serie.

Adicionalmente, existen infinidad de técnicas para operar en los mercados, sistemas basados en productos financieros o conceptos matemáticos, que tienen ciertas garantías y están ampliamente validados, como:

- **ETF:** Una opción muy común es escoger un fondo indexado que recoja los mercados en los que se está interesado. La complejidad de esta opción es que a pesar de ser un valor en cotización por sí mismo, se ve afectado por los distintos mercados que lo componen.

A la hora de escoger un fondo, los expertos recomiendan ser conservadores, es decir, evitar los ETF que han obtenido mayores retornos en los años anteriores, que a menudo suelen ser por casualidad, y optar por hacer un estudio exhaustivo acerca de aquellos valores que han obtenido buenos resultados a lo largo del tiempo con una

vida no inferior a los 10 años, que siempre hayan dado beneficios y cuyos rendimientos sean superiores a los del SP500.

- Teoría de los huecos: Este es un estilo de inversión e intradiario, es decir, las operaciones en las que se ve envuelto se abren y cierran en el mismo día. Se basa en que al cerrar los mercados, muchos inversores siguen queriendo invertir en bolsa, de modo que sus órdenes de compra o venta se guardan en el sistema hasta la apertura del día siguiente, ello genera una serie de huecos entre el último precio de un día y el primer precio del día siguiente que tiende a cerrarse. Estudios probabilísticos demuestran que se tiende a rellenar los huecos en un 70-80% de las ocasiones.
- Opciones: Es un estilo de inversión muy conservador, que requiere de unos conocimientos profundos sobre el objeto en el que se quiere invertir porque básicamente es el inversor quien decide el precio de la transacción. Se trata de llegar a un acuerdo con otra persona para comprar o vender un objeto cotizable a un precio determinado, de forma que se le paga a la otra persona una cantidad para asegurarse de tener una opción de compra o venta a un determinado precio sin tener que comprarlo o venderlo, de forma que si la cotización de dicho valor alcanza ese valor la opción se ejecuta de forma instantánea.
- Fibonacci: Es un estilo muy común en el trading, suele servir para análisis técnicos para medio y corto plazo. Se basa en un comportamiento del mercado proporcional, en donde según los impulsos de alcistas y de corrección se puede prever el comportamiento futuro.
- Noticias: Es una metodología que cada vez se está poniendo más de moda. Existen muchos trabajos sobre el tema y muchas maneras de enfocarlo, pero la más popular consiste en distinguir el valor de las noticias relevantes y las franjas temporales en las que trabajan y revisar cómo afectan al precio.
- Deep Learning: Emplea complejos algoritmos capaces de aprender por sí mismos. Se basa en la definición de unos hiperparámetros, que estudian las variables de entrada y dan una salida según sus estimaciones.

La inteligencia Artificial será el punto principal de este trabajo, enfocándose principalmente en el uso de redes neuronales (ARN). Las ARN tienen una fuerte capacidad de adaptación

y una sensibilidad especial para detectar relaciones no lineales en las series; estas características son interesantes de cara a analizar entornos cambiantes y poco previsibles como la bolsa.

1.3 MOTIVACIÓN DEL PROYECTO

Este proyecto nace con el propósito de conocer mejor el funcionamiento de los mercados energéticos globales, sobre todo el del gas y el petróleo. Existe una amplia conciencia colectiva que busca una transición energética hacia las energías renovables, pero en el momento que se escribe este trabajo sigue existiendo una importante influencia de recursos energéticos menos sostenibles.

Los recientes acontecimientos sólo son un toque de atención que expone una realidad, que hoy por hoy no es fácil de cambiar. El impacto del crudo de petróleo afecta en el día a día de las personas, empresas y gobiernos; conviene conocerlo y comprender la realidad detrás de todas las noticias que lo mencionan.

El impacto del petróleo, gas y resto commodities energéticas sobre la economía global es alto, existiendo regiones donde esta influencia es más fuerte que en otras. Actualmente, la crisis surgida a partir de la invasión de Ucrania y el retorno de la actividad comercial después del coronavirus hace que países como Alemania, que tenía una estrecha relación con el gas ruso, se vean directamente afectados. Esta clase de efectos geopolíticos no se limita a contextos bélicos, sino hay que mirar el ejemplo de España y el gas argelino, que se puede ver comprometido por el triángulo formado por Marruecos, Argelia y España.

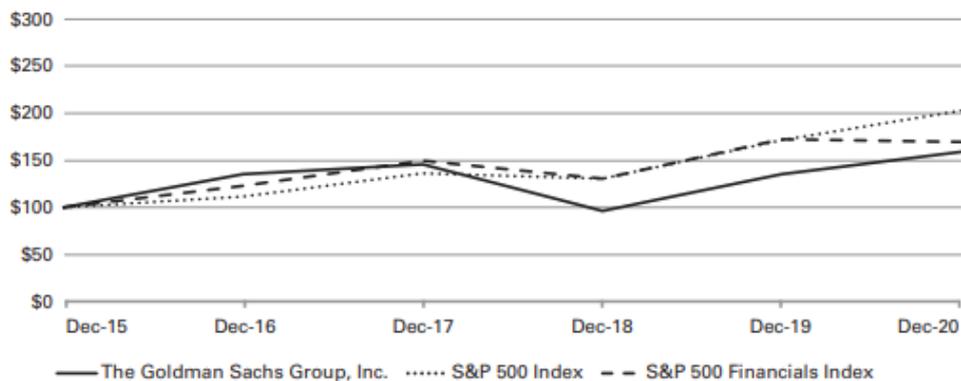
Por otra parte, la implantación de técnicas predictivas se impone día a día, lo que ayer se limitaba a estudios estadísticos hoy se extiende a la programación y complejos sistemas de Inteligencia Artificial. El conocimiento sobre este tipo de tecnologías, al igual que el de los mercados energéticos es cada vez más imprescindible para entender el mundo de hoy.

La globalización y la tecnología han logrado que la comunicación sea más ágil que nunca, aplicar sistemas predictivos basados en el flujo de información es más fácil que antes y desarrollar estrategias de valoración que ayuden a la toma de decisiones de inversión está al alcance de cualquiera.

No se trata de vencer al mercado (Generalmente en los fondos de inversión y los Hedge Funds se considera que superar al índice del SP500 es vencer al mercado por su amplio alcance) ni hacer rico a quienes empleen los programas diseñados, sino de una demostración de cómo la inteligencia artificial (IA) puede ayudar a las personas en sus decisiones y cómo su disrupción puede romper paradigmas.

1.4 OBJETIVOS

Conforme a la información revisada, los resultados de programas basados en algorítmicos automatizados requieren de una exactitud de al menos el 85% para considerar la implantación de un modelo; mientras en la bolsa apenas se logra que se sitúe en el intervalo $\in [40\%,60\%]$. Esto demuestra que la bolsa es un mundo confuso y volátil difícil de predecir.



	As of December					
	2015	2016	2017	2018	2019	2020
Group Inc.	\$100.00	\$134.91	\$145.35	\$ 96.63	\$135.73	\$159.45
S&P 500	\$100.00	\$111.95	\$136.38	\$130.39	\$171.44	\$202.96
S&P 500 Financials	\$100.00	\$122.75	\$149.93	\$130.38	\$172.21	\$169.18

Ilustración 7. Resultados de Goldman Sachs en comparación con el SP500 [1]

Goldman Sachs, uno de los mayores bancos de inversión del mundo, con multitud de personas encargadas de desarrollar esta clase de tecnologías, según sus datos publicados en el reporte anual del curso 2020-2021 mostrados en la Figura 8, no lograron batir al mercado. Un antecedente a los algoritmos actuales fue el del popular Hedge Fund LTCM, comúnmente conocido como el fondo de los genios. Su metodología se fundamentaba en esta clase de tecnología y sus resultados iniciales mejoraron a los de la industria con un holgado margen, pero con la crisis económica de finales del siglo XX, sus modelos demostraron no ser lo suficientemente sofisticados para protegerse frente a cambios en los ciclos económicos.

En este contexto, los objetivos de este trabajo no son crear programas informáticos que superen al mercado; sino que se propone unos hitos más realistas:

- Implementación de algoritmos automáticos basados en ARN para el análisis de un caso de estudio en la predicción de cotizaciones bursátiles.
- Profundizar acerca del funcionamiento del mercado eléctrico, gas y petróleo.
- Analizar los resultados obtenidos y discutir sobre las técnicas cuantitativas con mejor desempeño.
- Analizar los efectos de commodities energéticas en la economía.

Capítulo 2. ESTADO DE LA CUESTIÓN

El aprendizaje de cualquier materia se basa en pasar de no conocer nada, a poder saber lo suficiente de él como para utilizarlo. Dependiendo del grado de conocimiento que se desea alcanzar, la curva de aprendizaje se extenderá más o menos en el tiempo. Generalmente, se suele decir que se sabe lo suficiente de un hito cuando la persona que ha aprendido conoce las bases teóricas y empieza a distinguir distintas alternativas prácticas que le hacen partidario de una filosofía u otra.

Aunque el párrafo anterior no tenga demasiado que ver con las tecnologías que se van a tratar a continuación, se ha mencionado porque en los últimos tiempos ha surgido una explosión de conocimiento que ha trastocado los métodos que se empleaban hasta ahora en la predicción de series temporales.

Hoy hay más datos que ayer y menos que mañana, las nuevas tecnologías han hecho posible que la cantidad de información acumulada aumente exponencialmente y donde antes sólo se podía emplear la estadística tradicional, hoy se dispone de muchas herramientas para su estudio.

2.1 CONCEPTOS ELEMENTALES DE MÉTODOS PREDICTIVOS

Aunque este estudio se centra en los mercados del TTF y Brent, la predicción se emplea en una extensa variedad de campos comerciales, meteorológicos, científicos y analíticos. La ciencia de los datos no escapa a ningún campo, desde los pequeños hosteleros, que deben saber cuánta comida comprar para dar servicio a sus clientes, hasta las grandes multinacionales que deben pronosticar los retornos de sus inversiones.

Este capítulo trata de responder aquellas dudas que se planteen qué tipo de temas se pueden anticipar, qué alternativas de desarrollo de pronósticos existen y qué particularidades tienen cada una de ellas. Todo ello, de cara a los mercados energéticos globales.

Según Rob J. Hyndman y George Athanasopoulos; profesores de Business Statistics at Monash University, Australia; en su obra *“Forecasting: Principles and Practice”* el arte de predecir se basa en tres conceptos:

- Qué factores participan en un acontecimiento.
- Cantidad de datos históricos del acontecimiento.
- Grado de probabilidad de que la predicción afecte al devenir del acontecimiento.

De esta manera, que un pequeño hostelero disponga de una base de datos que especifique la cantidad de clientes que suele tener en función del día de la semana, no va a afectar a el volumen de su clientela. Sin embargo, que exista una enorme cantidad de ordenadores cuantificando los movimientos en bolsa en función de su desempeño, sí puede alterar su evolución.

Por su puesto, el grado de complejidad de unas estimaciones y otras no es el mismo; existen campos resilientes con características perdurables en el tiempo, y otros que dependen más de agentes externos como ciclos económicos, crisis de suministros y demás; es por ello, que no se deben sobrestimar las capacidades analíticas de los modelos de predicción, porque también cometen errores.

Según el horizonte temporal, los pronósticos se pueden dividir en distintas categorías según cuánto diste el evento de su análisis:

- Corto plazo: Procesos diarios que participan en las labores operativas de una cadena de valor.
- Medio plazo: Tareas de supervisión y planificación, que se encargan de anticipar los recursos necesarios de la cadena de producción.
- Largo plazo: Sobrepasan la barrera del año y se basan en estrategias y modelos de negocio.

Según la materia, se empleará un estudio u otro. En el caso de la bolsa, el grado de volatilidad es alto y se trata de un tema complejo, así que realizar estimaciones es arriesgado, más aún se analiza a medio o largo plazo, luego se incluiría en la categoría de corto plazo.

De manera somera se pueden distinguir dos tipos de predicción según el conocimiento y los datos disponibles:

- Sistema cualitativo: Basados en el conocimiento de la materia del investigador y al que se recurre cuando no existen datos disponibles.
- Sistema cuantitativo: Suelen tener criterios matemáticos por detrás. Dependen de la disponibilidad de datos y la existencia de secuencias, patrones o relaciones en las series.

Los sistemas cuantitativos son sistemas técnicos, requieren de un procesamiento de los datos cualificado y exigen unas salidas para sus modelos precisas. En este caso se va a trabajar con series temporales, con una base de datos de diez años y con aplicaciones de modelos cuantitativos.

Generalmente, las metodologías cuantitativas se componen de cinco puntos:

- Descripción del tema: Saber la finalidad del estudio, el grado de precisión y la exactitud exigida, además de métricas y marcas de modelos anteriores que sirvan de referencia.
- Recolección de la información: Fuentes de información, fiabilidad y latencia respecto al ejercicio real.
- Pretratamiento de los datos: Revisión de la calidad de los datos, estructura y análisis estadísticos como el valor de la curtosis, la asimetría, la desviación estándar, la media y la mediana.
- Metodologías aplicadas: Según las características de la serie, se aplicarán unos métodos u otros que ofrezcan mejores resultados.
- Valoración de los resultados: Una vez se hayan aplicado as metodologías anteriormente mencionadas, se debe revisar cuál es la mejor opción, las razones

detrás de ello y razonar qué aportaciones adicionales se podrían hacer para futuros modelos.

2.2 METODOLOGÍAS EMPLEADAS

En este punto se va a hablar de distintas técnicas de predicción de series temporales aplicadas a bolsa, sus características principales, sus fortalezas, debilidades y qué cualidades las hacen diferentes de otras alternativas.

Existen principalmente tres clases de modelos predictivos:

- Modelos estadísticos.
- Modelos de Inteligencia artificial.
- Modelos híbridos.

2.2.1 MODELOS ESTADÍSTICOS

De las tres opciones, ésta es la más tradicional, con muchos estudios y análisis sobre el tema. La estadística es una herramienta muy útil en el preprocesamiento y modelaje de los datos, que ayuda a comprender la naturaleza de la información con la que se trabaja.

La mayoría de los trabajos que tienen que ver con la ciencia de datos comienzan aplicando métricas que ayuden a contextualizar el carácter general de la información. Estas medidas suelen ser el valor de la curtosis, la asimetría, la desviación estándar, la media y la mediana. En ocasiones también se aportan gráficas como diagramas de bigotes, correlogramas o nubes de puntos, para dar una visión más clara de cómo se comportan. La misión de estos pretratamientos no es clave en su predicción, pero sí puede ser de gran ayuda para saber de dónde se parte y explorar distintas alternativas. Por ejemplo, si se observa una nube de puntos con una tendencia clara y que parece extenderse en el tiempo o los correlogramas con los gráficos de autocorrelación y autocorrelación parcial, puede que sea conveniente comenzar estudiando alternativas que se basen en la autorregresión de la serie, en vez de prestar atención a otras posibilidades.

Una vez superada la fase observación de los datos es conveniente puntualizar que dependiendo de qué herramienta estadística se desee usar, se deben cumplir ciertos requisitos como:

- La estacionariedad.
- La linealidad.
- Homogeneidad.

Además de estas, es posible que se necesiten más pruebas que verifiquen que se cumple con las condiciones para continuar con su análisis estadístico. Sin duda, este es un punto negativo de la estadística clásica, pues no siempre las series con las que se desea trabajar disponen de esas cualidades.

A pesar de los factores limitantes que puedan aparecer, la estadística clásica puede ser un método muy preciso; de hecho, se suele recurrir a la estadística cuando se buscan herramientas exactas. La causa de esto es, sobre simplificando, que la estadística funciona como un modelo matemático que trata de poner una fórmula que explique el comportamiento de los datos que dispone, es decir, busca unas relaciones funcionales, ya sea con variables explicativas o con la historia de la propia variable que se desea predecir.

A continuación, se mencionan algunas herramientas:

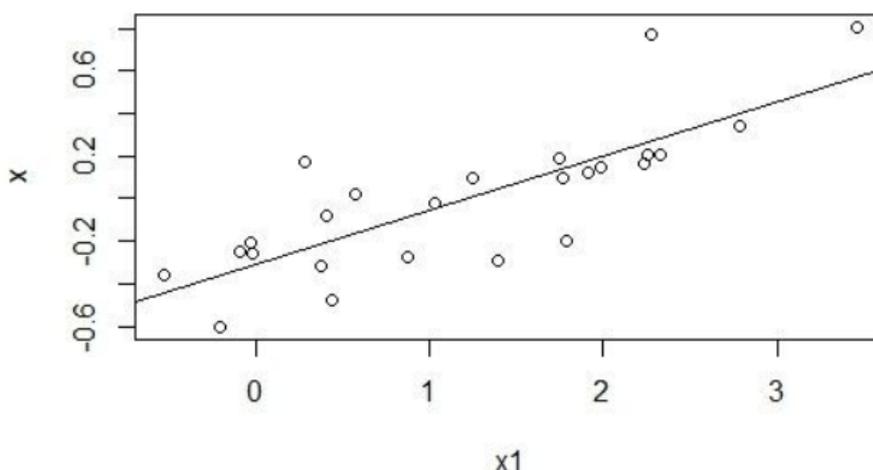
La cointegración

“La cointegración es una relación fuerte a largo plazo. Que dos variables estén cointegradas implica que, aunque crezcan o caigan, lo hacen de forma sincronizada y lo mantienen a lo largo del tiempo.

El concepto de cointegración surge por el problema de intentar saber si dos o más variables están en realidad relacionadas. Muchas relaciones entre variables pueden ser espurias, es decir, falsas. Espuria significa que, aunque estadísticamente parezca que tienen relación, es pura casualidad. A continuación, se ofrece un gráfico que relaciona dos variables (x y x_1).

Este gráfico está construido con dos series generadas aleatoriamente en R. Dado que las variables se han generado aleatoriamente, la más mínima relación existente es pura

casualidad. Sin embargo, al ver el siguiente gráfico podemos pensar que tienen una relación estable. Cuando x crece, x_1 crece también.



Además, al realizar un modelo de regresión lineal que explique el valor de x conforme el de x_1 , obtenemos la línea de regresión presente en el gráfico. Esta indica un R cuadrado de 0,62, es decir, x_1 es capaz de explicar el 62% de las variaciones de x .

El hecho de que estas dos series, que son totalmente aleatorias e independientes entre sí, puedan tener relación aparente, abre la puerta a un mundo de posibilidades infinitas en el que muchas variables sin relación puedan aparentar tenerla. En este sentido, los test de cointegración se encargan de determinar si esa relación es verdadera y tiene sentido, o es falsa. Al ser test estadísticos basados en fórmulas matemáticas no son infalibles. No obstante, son test muy exigentes que aseguran una probabilidad muy alta de evitar relaciones espurias.

Pasos para realizar un test de cointegración.

Para simplificar la explicación trataremos solo con dos variables (x y x_1). Por ejemplo, la inflación y los tipos de interés, o el PIB y la tasa de desempleo. Así, vamos a enumerar los pasos para determinar si una relación es espuria o no, mediante un test de cointegración.

Establecer la relación entre las variables.

La forma más potente de intuir la relación entre dos variables en economía es la lógica. La estadística, y más concretamente la econometría, solo tratan de poner los números. Pero debe ser el economista o econométra el que, a través de la teoría económica, establezca la lógica de la relación.

Extraer los datos y generar el modelo.

Una vez se extraen los datos, estos son fiables y carecen de errores de estimación, se generará el modelo. Aunque existen más situaciones, podemos encontrarnos, para simplificar, ante dos escenarios:

- x y x_1 son estacionarias. Se estima por Mínimo Cuadrados Ordinarios (MCO).
- Las series no son estacionarias, pero están cointegradas.

Test de cointegración.

La prueba de cointegración más famoso es el de Dickey-Fuller. La prueba se hace sobre la serie de los residuos. Es decir, realizamos el modelo. En nuestro caso, intentamos explicar x en función de los valores de x_1 . Y tenemos una estimación de los valores de x . La diferencia entre los valores reales de x y la estimación de x se denomina residuo. El test se hace sobre la serie de residuos. De esa manera, si puede confirmarse mediante el test que los residuos son estacionarios, las variables estarán cointegradas. De lo contrario, no lo estarán.

¿Para qué es útil la cointegración?

La cointegración es útil en economía para realizar modelos predictivos fiables. También en el caso del trading al utilizar técnicas de arbitraje estadístico como el trading de pares. O para realizar modelos basados en variables macroeconómicas que permitan estimar el valor de un activo en un momento dado. Un ejemplo claro de la utilidad de la cointegración está en el trading de pares. Si no nos aseguramos de que dos activos financieros tienen una relación estable a lo largo del tiempo, podríamos perder mucho capital invirtiendo con esa estrategia.”⁴

⁴ López, JF. “Cointegración”. Economipedia. Mayo, 2020.
<https://economipedia.com/definiciones/cointegracion.html>

2.2.2 MODELOS DE INTELIGENCIA ARTIFICIAL

La Inteligencia Artificial es un campo muy amplio, en el que existen varias ramas como el Deep Learning. El DL es una serie de algoritmos capaces de aprender automáticamente, de forma que son capaces de trabajar con series no lineales. El DL emplea las Redes Neuronales. Las ARN son una serie de unidades, denominadas neuronas artificiales, conectadas en forma de red, que se transmiten información entre sí. El funcionamiento de las ARN trata de replicar el que tendrían las neuronas en el cerebro humano.

En la práctica, las redes neuronales podrían definirse como una caja negra en la que una vez definidos unos hiperparámetros, se le alimenta con unos datos de entrada y proporciona unos resultados como salida.

En los últimos tiempos esta técnica se ha empleado mucho para la predicción de series temporales, su capacidad para trabajar con series no lineales y aprender por sí misma resulta de gran ayuda.

Las redes neuronales permiten el análisis de datos estructurados y no estructurados. Los principales conceptos a definir en esta estrategia son:

- Número de unidades: Número de neuronas artificiales.
- Batch size: Número de observaciones de entrenamiento por cada iteración.
- Epoch size: Número de aprobados de la base de datos que el algoritmo ha completado.

Lógicamente, el número de hiperparámetros aumentará en función del tipo de red neuronal que se quiera. Hay que notar que las ARN trabajan dividiendo los datos de entrada en dos subconjuntos:

- Subconjunto de entrenamiento: Normalmente denominado Training set. Se encarga de aprender los patrones de los datos y estudia cómo predecir datos futuros.

- Subconjunto de prueba: Normalmente denominada prueba set. Se encarga de aplicar lo aprendido en el subconjunto de entrenamiento.

La división de la información en estos dos subconjuntos esto de los hiperparámetros más generales. Se debe aportar más información al subconjunto de entrenamiento que al de prueba para que la herramienta obtenga mejores resultados. Poniendo un ejemplo, es como si un deportista dedicase más horas a entrenar que a competir en torneos. Sin embargo, hay que tener cuidado con no prestar demasiado porcentaje de los datos al subconjunto de entrenamiento, porque de ser así, se estaría sobre entrenando al modelo y no sería fiable; este fenómeno se denomina overfitting.

Para evaluar la eficacia de una red neuronal se deben comparar los resultados de los subconjuntos de entrenamiento y prueba. Los errores comúnmente aceptados son:

- Exactitud: Revisa si las estimaciones de las ARN concuerdan o no con los eventos reales.
- Median Average Error: Es robusto frente a datos poco comunes (datos atípicos). Se calcula tomando la media de todas las diferencias de las previsiones y los valores reales.

$$MAE = \frac{1}{n} \cdot \sum_{i=1}^n |x_i - x|$$

- Mean Squared Error: Cálculo muy parecido al del MAE, pero elevando al cuadrado la suma de las diferencias.

$$MSE = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - x)^2$$

- Root Mean Square Error: EL RMSE calcula la desviación típica de las predicciones respecto de los resultados reales, de hecho, también se le suele conocer como Root Mean Square Deviation.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\text{Valor estimado } i - \text{Valor real } i)}{n}}$$

- Matriz de confusión: Medida empleada para revisar aquellas metodologías basadas en la clasificación; se usa sobre todo en aquellos instrumentos que tienen salidas dicotómicas, capaces de revisar qué porcentaje de clasificaciones correctas han recogido.

La matriz de confusión se compone de 4 cifras: Verdadero Positivo, Verdadero Negativo, Falso Positivo y Falso Negativo. Aquellas cifras verdaderas son aquellas en las que el modelo ha acertado al asignarlas mientras que las falsas son las equívocas. Una vez se ha llegado a este punto se pueden introducir la especificidad y la sensibilidad; la primera consiste en la detección de los casos realmente positivos mientras que la segunda hace lo propio con los negativos:

$$\text{sensibilidad} = \frac{\text{Verdader Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}}$$
$$\text{especificidad} = \frac{\text{Verdader Negativos}}{\text{Falsos Positivos} + \text{Verdaderos Negativos}}$$

Estos errores son los más comúnmente aceptados, pero en función de la temática es posible que se añadan más tipos de errores. Al haber dos subconjuntos diferentes es posible que los errores de los resultados sean distintos, si la diferencia no es muy grande, no hay que preocuparse, pero si fuesen notables, habría que revisar el porcentaje de datos destinado a cada tipo de subconjunto porque se estaría incurriendo en un error de sesgo conocido como biased error.

A continuación, se explican los tipos de redes neuronales más empleados en esta clase de estudios:

LSTM

“Long-Short Term Memory(LSTM) son una extensión de las redes neuronales recurrentes, que básicamente amplían su memoria para aprender de experiencias importantes que han pasado hace mucho tiempo. Las LSTM son un tipo de redes neuronales recurrentes que pueden recordar sus entradas. Esto se debe a que LSTM contiene su información en la memoria, que puede considerarse similar a la memoria de un ordenador, en el sentido que una neurona de una LSTM puede leer, escribir y borrar información de su memoria.

Esta memoria se puede ver como una “celda” bloqueada, donde “bloqueada” significa que la célula decide si almacenar o eliminar información dentro (abriendo la puerta o no para almacenar), en función de la importancia que asigna a la información que está recibiendo.

La asignación de importancia se decide a través de los pesos, que también se aprenden mediante el algoritmo. Esto lo podemos ver como que aprende con el tiempo qué información es importante y cuál no.

En una neurona LSTM hay tres puertas a estas “celdas” de información: puerta de entrada (input gate), puerta de olvidar (forget gate) y puerta de salida (output gate). Estas puertas determinan si se permite o no una nueva entrada, se elimina la información porque no es importante o se deja que afecte a la salida en el paso de tiempo actual.

Las puertas en una LSTM son análogas a una forma sigmoide, lo que significa que van de 0 a 1 en la forma que hemos visto en capítulos anteriores. El hecho de que sean análogas a una función de activación sigmoid como las vistas anteriormente, permite incorporarlas (matemáticamente hablando) al proceso de Backpropagation. Como ya hemos comentado, los problemas de los Vanishing Gradients se resuelven a través de LSTM porque mantiene los gradientes lo suficientemente empinados y, por lo tanto, el entrenamiento es relativamente corto y la precisión alta.

Keras ofrece también otras implementaciones como es la Gated Recurrent Unit (GRU) [5]. Las capas GRU aparecieron en el 2014, y usan el mismo principio que LSTM, pero están simplificadas de manera que su rendimiento está a la par con LSTM pero computacionalmente son más eficiente.”⁵

[1] ⁵ Torres, J. “Redes Neuronales Recurrentes”. Jordi Torres AI, Junio 2021. [Redes Neuronales Recurrentes - Jordi TORRES.AI](#)

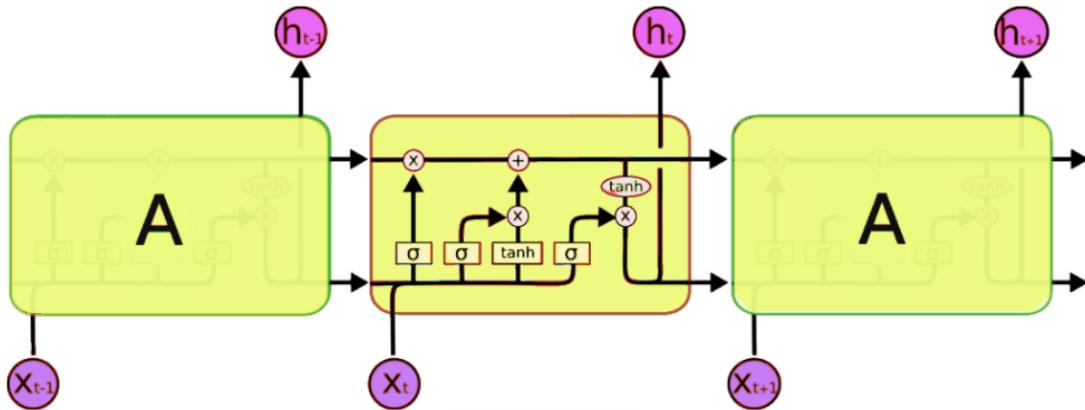


Ilustración 1 – Funcionamiento de una LSTM [1]

Según se puede apreciar en la figura, los datos de entradas llegan a la red, pasan por las puertas de olvido o recuerdo y continúan su travesía hasta la salida.

MLP

Multilayer Perceptron. El MLP es una estrategia que puede actuar en tareas de clasificación, como por ejemplo, en vez de estimar el precio que alcanzarán las commodities, recoge los datos de los días anteriores y decide si el día siguiente será un día alcista o no. Además de para clasificación y predicción de series, también se suelen utilizar para reconocimiento de imágenes.

Su composición consta en tres tipos de capas: entrada, oculta y salida. En la capa de entrada se fijan un número de perceptrones o neuronas, a cada una se le asigna un peso diferente en su camino hacia las capas escondidas, donde por medio de una función de activación se definen los atributos que van a la capa de salida, que también tiene una función de activación antes de la salida final de la red.

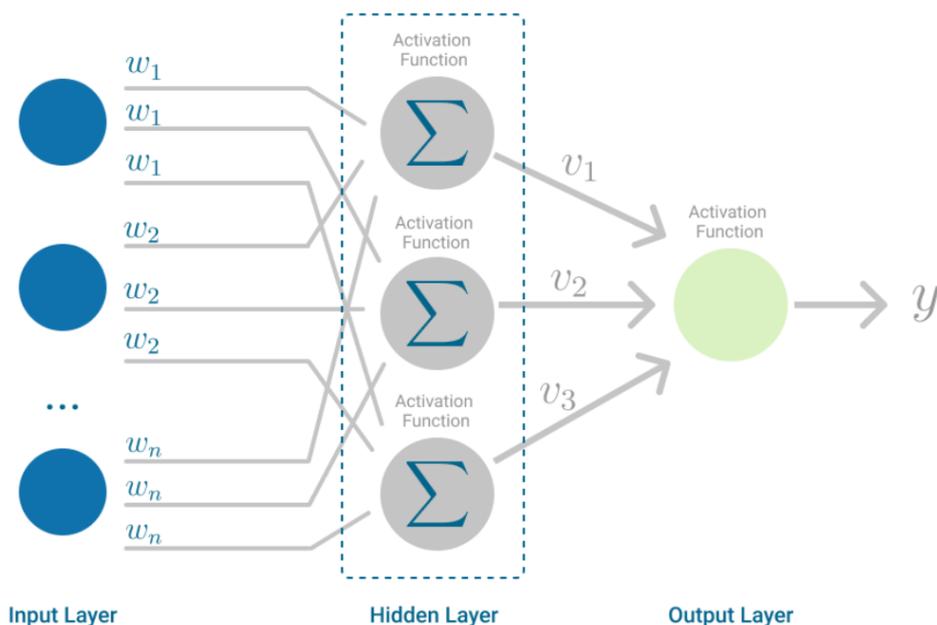


Ilustración 2 – Funcionamiento de un MLP [2]

Tal y como se puede ver en la ilustración las entradas llegan a la red y circulan por las distintas capas a través de pesos y vectores, pasando por el filtro de las funciones de activación.

CNN

Convolutional Neural Network. Se trata de una red neuronal que es muy empleada en la identificación y tratamiento de imágenes, aunque cada vez se emplea más en el estudio de series temporales. Al igual que el MLP, las CNNs también pueden trabajar como redes clasificadoras, sólo que, en vez de tener un solo tipo de capa clasificadora, la CNN dispone de una arquitectura con dos partes bien diferenciadas.

La primera parte es un segmento convolucional, es decir, la red recibe unos datos de partida y los hace pasar por una serie de filtros que le permiten identificar sus características más relevantes, una vez ha definido cuáles son los patrones más interesantes, recorta de los datos que menos le interesan y comprime los datos restantes en un vector denominado código

⁶ Bento, C. “Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis”, Towards Data Science, September 2021. Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis | by Carolina Bento | Towards Data Science

CNN. La capa encargada de hacer el corte de los datos originales y comprimirla posteriormente se denomina Max Pooling Layer.

Una vez enviado el vector código CNN se llega a la otra parte principal de una CNN, el segmento de clasificación. Esta parte es la más parecida al sistema de un MLP, que consiste en una capa llamada Fully Connected Layer que combina las características del código CNN para clasificar los datos.

A medida que las series introducidas son más complejas, es posible añadir más capas convolucionales que sean más sofisticadas en el proceso de detección de características. A continuación, se presenta una imagen con una representación de una CNN.

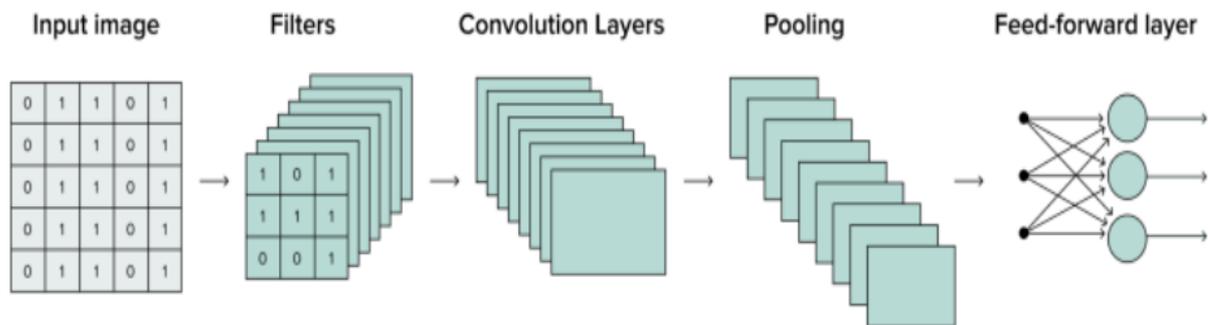


Figure 3 – Operation of a CNN

El proceso por el cual una capa convolucional detecta las características más relevantes se denomina abstracción. Para comprenderlo mejor se va a emplear un ejemplo con una imagen. La imagen llega a la capa convolucional y la CNN va píxel por píxel revisando su naturaleza, de esa manera es capaz de detectar figuras, colores, formas y patrones de forma automática. Una vez se haya revisado la imagen completa, la Max Pooling Layer se encarga de recortar toda aquella información innecesaria.

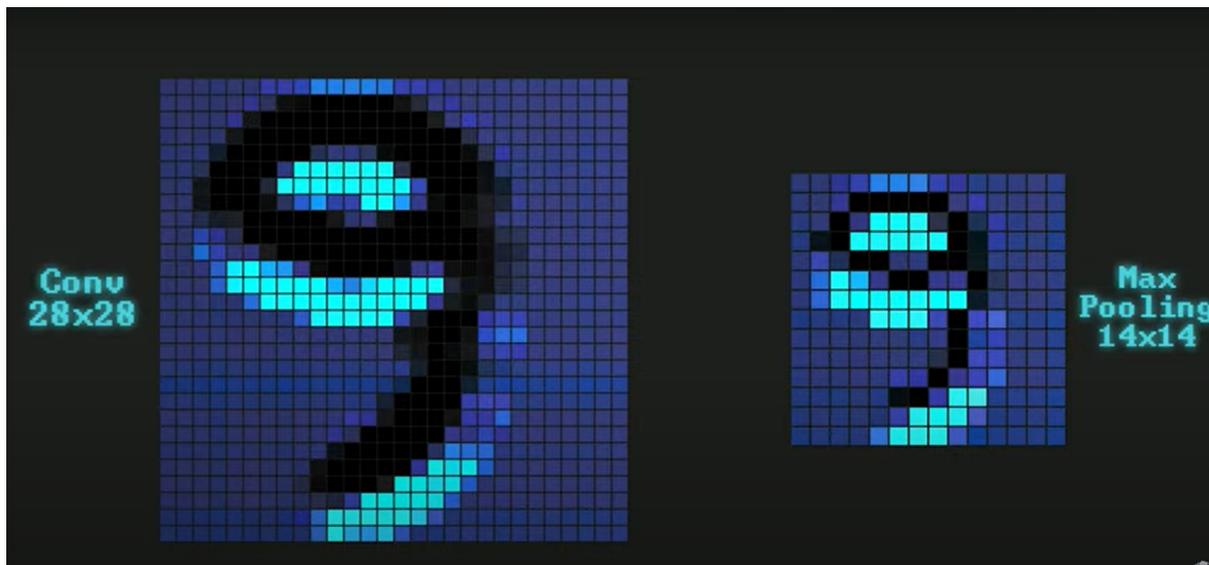


Ilustración 8. Ejemplo tratamiento de una imagen en una CNN [7]

Tal y como muestra la ilustración 9, la CNN recoge la información necesaria para representar la imagen de la forma más fiel y concisa posible.

Autoencoders

Los autoencoders son un tipo de red neuronal capaz de identificar información no etiquetada que reconoce patrones y secuencias.

Su funcionamiento consiste en comprimir unos datos de entrada, procesarlos y dar como salida una reconstrucción de los datos originales. La compresión de los datos lo realiza a través de un encoder, que recoge toda la información posible y trata de representarla matemáticamente con la menor pérdida de datos posible. Una vez los datos están comprimidos, los envía por medio de un embedding vector hacia el decodificador. El decodificador se encarga de representar la información de salida con aumentando su tamaño hasta alcanzar el tamaño original de la información de entrada. La diferencia entre la entrada y la salida está en que la salida ha retirado la información más irrelevante, minimizando el ruido de los datos.

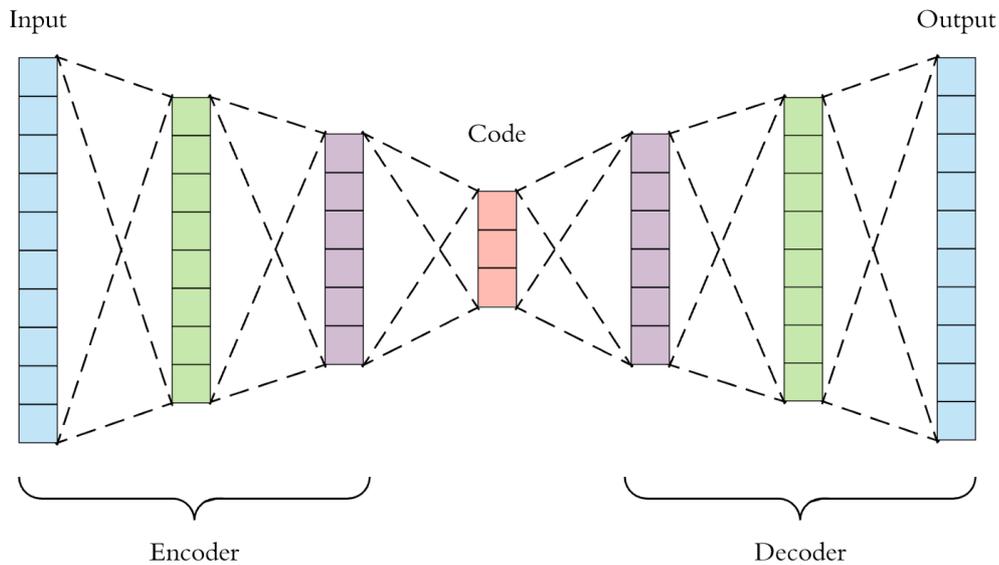


Ilustración 9. Representación de un autoencoder.[8]

Una vez se ha explicado el funcionamiento de un autoencoder puede aparecer la duda de para qué utilizarlo, si se va a obtener una salida con las mismas dimensiones de la entrada. La respuesta consiste en que el autoencoder es una técnica muy útil para retirar anomalías, clasificación, validación de datos e imputación de datos no recogidos. DE ahí que sea una técnica muy útil para concebir modelos híbridos. (Como Autoencoder + LSTM)

2.2.3 ESTADO DEL ARTE

La mayoría de la documentación revisada apuesta por estrategias de inversión basadas en redes neuronales, muchas utilizan una sola técnica, aunque también existen ejemplos de soluciones híbridas que mezclan distintos tipos de redes neuronales y, en algunos casos, estadística clásica.

A continuación, se mencionan una serie de técnicas no mencionadas en el apartado 2.2.2, que apuestas por desarrollar otra serie de programas como:

SVM: “Support vector machine (SVM) es un algoritmo de aprendizaje supervisado que se utiliza en muchos problemas de clasificación y regresión, incluidas aplicaciones médicas de procesamiento de señales, procesamiento del lenguaje natural y reconocimiento de imágenes y voz.

El objetivo del algoritmo SVM es encontrar un hiperplano que separe de la mejor forma posible dos clases diferentes de puntos de datos. “De la mejor forma posible” implica el hiperplano con el margen más amplio entre las dos clases, representado por los signos más y menos en la siguiente figura. El margen se define como la anchura máxima de la región paralela al hiperplano que no tiene puntos de datos interiores. El algoritmo solo puede encontrar este hiperplano en problemas que permiten separación lineal; en la mayoría de los problemas prácticos, el algoritmo maximiza el margen flexible permitiendo un pequeño número de clasificaciones erróneas.

Los vectores de soporte hacen referencia a un subconjunto de las observaciones de entrenamiento que identifican la ubicación del hiperplano de separación. El algoritmo SVM estándar está formulado para problemas de clasificación binaria; los problemas multiclase normalmente se reducen a una serie de problemas binarios.”⁷

CEFLANN: Computational efficient functional link artificial neural network. Se trata de una ANN con un componente de aprendizaje y otro de expansión funcional. En el bloque de expansión funcional aparecen varias funciones trigonométricas que ayudan a captar las entradas no lineales. A diferencia de otros tipos de redes neuronales, el uso de esta clase de funciones le permite no tener que emplear capas escondidas para captar esas relaciones sin gastar tanto coste computacional. Alguna de esas fórmulas es:

$$O_i = \tanh \left(a_{i0} + \sum_{i=1, j=1}^{i=n, j=d} a_{ij} \cdot x_j \right)$$

Garch modelling: En este caso se trata de una técnica estadística que consiste en una forma de interrelacionar la volatilidad de un mercado con el precio y los retornos de una commodity. Se basa en la búsqueda de arcos no constantes que se presentan en ciclos de tiempo alternativos, de forma que si aparece un volumen relevante en un tiempo t1 y poco

⁷ Mathworks. “Support Vector Machine (SVM)”. Mathworks, Junio 2018. [Support Vector Machine \(SVM\) - MATLAB & Simulink \(mathworks.com\)](https://www.mathworks.com/help/matlab/matlab_prog/support-vector-machine.html)

después aparece otro volumen relevante en un tiempo t_2 y en ambos casos se puede apreciar un aumento significativo del precio de la commodity significa que existe un arco y se puede predecir su retorno.

Una vez comentados todas estas herramientas, se muestra una tabla comparativa donde aparecen los resultados de trabajos previos. En esta tabla se incorporan columnas con la rentabilidad anualizada en vez de completa, división en categorías de la fiabilidad de los datos expuestos en alta, media y baja (Se considera alta cuando el estudio engloba más de 10 años, media si es 5 y el resto se toma como baja).

COMPARATIVA DE ESTRATEGIAS										
Autor	Técnica	Commodities	HorizonteTemporal	AñosEstudio	Accuracy	RentabilidadAcumulada	RentabilidadAnualizada	Fiabilidad	Column1	Evaluación
Rajashree Dash	Híbrido: EMA15 + SVM + CEFLANN	SP500 & SENSE_X	5 días	2010-2015	NA	24%	5%	BAJA	0,2	0,971
GERLEIN	OneR & C4.5 & Jrip & LMT & Kstar & NaiveBayes	FOREX	3 días	2002-2013	54%	147%	9%	ALTA	0,8	6,85
Tsantekidis	RNN + LSTM	NASDAQ	10 días	NA	61%	NA	NA	BAJA	0,2	0,00
Gu	RNN + LSTM	CDCE & SoyOil & SoyMeal	30 días	2010-2017	61%	63%	32%	MED	0,5	16,08
Dias Paiva	SVM & MVM	Ibovespa	75 días	2001-2016	40%	3810%	30%	ALTA	0,8	23,95
Naik	RNN + LSTM	NSE	5 días	2009-2018	58%	NA	NA	BAJA	0,2	0,00
Hongfang Lu	CEEMDAN-GWO-KNEA	Coal	NA	2013-2017	55%	NA	NA	BAJA	0,2	0,00
Ahmed Saied	Híbrido: RNN + Autoencoders	Gold	7 días	1970-2020	49%	NA	NA	BAJA	0,2	0,00
SharazadHaris	Granger	Gold & Oil	NA	1993-2013	NA	NA	NA	BAJA	0,2	0,00
Vahur Madisson	RNN autoencoders + LSTM	SP500	60 días	2006-2019	54%	436%	12%	MED	0,5	6,00
Farid Ullah	ARIMA+MLP	Pakistani, Indian and Sri Lankan Rupee	NA	NA	NA	NA	NA	BAJA	0,2	0,00
R. Arjun Raj	MLP & LTSM	BSE index	NA	2008-2018	0,0309	NA	NA	MED	0,5	0,00

Table 1. Comparativa de estrategias.

La Tabla 1 expone los resultados de los documentos revisados con mayor peso en el proceso de recolección de información, en donde aparecen tanto los modelos estadísticos como de ARN. Los datos expuestos en la tabla reflejan la información aportada en los documentos correspondientes salvo en el caso de las columnas de Rentabilidad Anualizada, Fiabilidad, Column1 y Evaluación. La Rentabilidad Anualizada se añadió para poner en igualdad de condiciones las rentabilidades de las propuestas expuestas, la Fiabilidad afecta a los valores expuestos en Column 1 según sea alta, media o baja; se considera que la fiabilidad es alta si el estudio ha empleado datos de diez o más años y se ha validado en operativas reales, media si los años estudiados están entre cinco y diez años y baja en el resto de los casos. Finalmente,

la Evaluación es el resultado de multiplicar la Rentabilidad Anualizada, la Fiabilidad y la Accuracy.

$$\text{Evaluación} = \text{Rentabilidad Anualizada} \times \text{Fiabilidad} \times \text{Exactitud}$$

Debido a que cada estudio toma en consideración diferentes tipos y tamaños de datos así como diversas métricas, no es posible determinar de forma definitiva cuál es el modelo con el mejor desempeño.

No obstante, se pueden sacar unas conclusiones fidedignas de acuerdo con el estado del arte, que impriman bien la dirección que debe tomar el TFM:

Existen estudios que afirman que los modelos híbridos podrían presentar mejores resultados que aquellos que se apoyen en una sola técnica, pero dado que los resultados reportados en el estado del arte de este trabajo no se diferencian demasiado; y en algunos casos no se tiene registro de todas las métricas; hay que mantener este enfoque como una idea de investigación para futuros trabajos. Lo que sí se puede afirmar es que las ARN, gracias a su capacidad de aprendizaje y adaptación a su entorno, son una propuesta muy interesante que puede ser de utilidad en la predicción de precios de activos.

La mayoría de las personas se centran en índices de valores y commodities bien asentadas, como son el Standard & Poors 500 (SP500), el oro y el trigo; esta predilección abre una oportunidad para estudiar un camino que a pesar de estar muy revisadas, han sido menos estudiadas por investigadores alrededor del mundo.

La geopolítica internacional ha hecho que tanto el gas como el petróleo acaparen gran parte del interés mediático, sin embargo, el número de personas que los tienen dentro de su círculo de competencia es menor y eso puede generar coyunturas positivas a quienes sí lo tengan. La combinación de herramientas algorítmicas automatizadas sumado a la experiencia y conocimientos del sector puede ser muy interesante.

Además, tanto en el caso del gas como en el del petróleo numerosos estudios como el de Sharazad Haris; profesor de Administración y Dirección de empresas de la Universidad Mara de Malasia; sentencian que son unos indicadores para analizar el estado de la economía global, siendo su precio inversamente proporcional al crecimiento del producto interior bruto mundial.

En cuanto a qué producto financiero a emplear, la complejidad del sector ha ido creciendo exponencialmente en los últimos años, lo que ha supuesto el nacimiento de una gran cantidad de derivados que permiten a bancos, hedge funds, analistas y ahorradores crear sinergias y estrategias alternativas. Algunas de ellas son:

Random Walk: Considera que es imposible predecir los movimientos de los mercados debido a su volatilidad, de forma que predecir subidas y caídas carece de lógica. Propone depositar dinero en índices y ETFs con recorridos históricos que garanticen ganancias a largo plazo.

Basket trading: Consiste en comprar o vender varios activos en una sola operación, es decir, un híbrido entre ETF e índice con varios activos integrados que base su rendimiento en función del peso de cada uno de los valores que lo componen. Es una técnica muy adecuada para inversores institucionales y tiene claras ventajas competitivas desde el punto de monitoreo de las acciones, dilución del riesgo y compra venta de varios activos. Suele ser un estilo más conservador. Existen varias técnicas de ARN para su aplicación que se centran sobre todo en el análisis de riesgos, pero no hay documentos ni trabajos que presenten trabajos específicos sobre sus resultados.

Spreads: Es un estilo que engloba varias categorías dentro de sí, desde las opciones que permitan realizar calls y puts, hasta estrategias multi-commodities que se buscan correlaciones. Es una postura interesante, pero requiere de estudios previos muy exhaustivos que monitoricen el grado de cointegración de sus miembros y no hay referencias bien definidas. La

Estrategias long-short: Se basan en derivados Contract For Difference (CFD), que permiten especular en futuros. Se suelen basar en una combinación entre medias exponenciales temporales, correlación entre el precios y volumen (Modelos de Garch) y operaciones intradías.

La naturaleza de los programas que se van a desarrollar en el trabajo y en análisis predictivo de los mismos, hace que de las opciones anteriores, la que mejor se le adapte sea la de long-short con futuros o derivados con una base parecida a los CFDs.

Capítulo 3. DESCRIPCIÓN DEL MODELO

DESARROLLADO

3.1 DESCRIPCIÓN DEL MODELO DESARROLLADO

Los mercados eléctricos siempre han sido un campo muy estudiado en el que se han empleado muchísimas técnicas y herramientas para tratar de predecir su evolución, su fuerte correlación con el desarrollo económico y sus barreras de entrada hacen de él un tema muy atractivo. En los últimos meses los acontecimientos geopolíticos han hecho que cobre aún más interés, su impacto en los precios y su desconocimiento por gran parte de la población hacen que profundizar sobre mercados como el gas natural en los Países Bajos TTF (Title Transfer Facility) y el barril de Brent tengan hoy más exposición que ayer.

Tanto en el caso del barril Brent como en el del TTF, se trata de series temporales basadas en mercados globales energéticos que cotizan en el mercado bursátil. El número de análisis y desarrollo de estrategias algorítmicas avanzadas que permitan brindar soporte en el proceso de toma de decisiones en trading es alto y con este trabajo se tratará de dar una visión que emplee distintas técnicas basadas en sus históricos.

La dificultad de la tarea exige distintos enfoques, por un lado, se usarán conceptos de la estadística tradicional para describir los datos de forma preliminar y por otro, una visión más moderna desde la perspectiva del Machine Learning. La primera tratará de usar los conceptos de la estadística tradicional con el fin de brindar una descripción general de los datos que se van a utilizar en el presente caso de estudio. Adicionalmente, dentro del Machine Learning, se buceará por el Deep Learning (DL) a través de varias técnicas que emplean Redes Neuronales (ARN) para tratar de anticiparse a los movimientos de los precios de los activos.

Asimismo, los objetivos del trabajo quedan resumidos en los siguientes puntos:

- Mayor comprensión de los mercados del gas y el petróleo.

- Análisis del estado del arte de la predicción de los mercados bursátiles con técnicas estadísticas y de Machine Learning.
- Correlaciones entre los datos de referencia de cada uno de los activos estudiados. (Precios de apertura, cierre, máximos y mínimos diarios, volumen y precio)
- Correlación de los precios del barril Brent y el TTF holandés.
- Comparación de los resultados reportados en la literatura sobre modelos estadísticos y basados en Machine Learning.
- Descubrir las posibilidades de la Inteligencia Artificial (IA) aplicadas a la predicción de series temporales.
- Implementación de algunas de las estrategias más usadas para la predicción y clasificación de series de tiempo, aplicadas en un caso de uso con cotizaciones en mercados de gas y petróleo.

La organización seguida presenta en el apartado 3.1 cómo y de dónde se han extraído los datos, la sección 3.2 detalla los algoritmos empleados, la sección 3.3 comenta cómo ha sido su implantación y finalmente los puntos 4 y 5 analizan y extraen conclusiones de los resultados respectivamente.

3.2 DATOS

La plataforma empleada para la obtención de datos es yahoo-finance por su gran cantidad de información disponible, y facilidad de acceso, que ha sido el programa utilizado para la generación de los códigos. Yahoo-finance tiene una latencia de aproximadamente 15 minutos respecto al valor en tiempo real de la bolsa, pero dado que esta herramienta tiene un horizonte temporal de predicción de un día y requiere de al menos treinta días para generar una respuesta, no supone un problema grave. Es importante señalar que las herramientas desarrolladas se podrían aplicar con cualquier otra fuente, sólo sería necesario adaptar el formato de los datos recibidos y que pudiesen ser almacenados en un formato .csv.

La automatización del proceso es un aspecto clave, luego la descarga de los datos se debe realizar utilizando web scraping, es decir, un software que extraiga información de sitios web de forma autónoma y que cumpla con los requisitos definidos de cubrir un horizonte

temporal de 10 años; de 2010 a 2020. Basándose en trabajos previos que trataban temas parecidos a este, se ha estimado que 10 años es un horizonte temporal adecuado para extraer conclusiones acerca del comportamiento de un mercado, además, se han escogido esas fechas para que no coincidiese con el impacto del coronavirus o la invasión de Ucrania en bolsa. No se han tenido en cuenta estos dos últimos eventos porque las bolsas han tenido comportamientos erráticos y volúmenes de trading muy superiores a la media, esta clase de mecanismos es muy sensible a los comportamientos históricos y podrían no ofrecer unos resultados concluyentes de haberse incluido. En contraposición, la franja temporal descrita resume más fielmente el comportamiento de estos mercados.

Tanto para el barril Brent como para el TTF se han recogido los precios de apertura, cierre, máximo, mínimo, volumen y cierre ajustado diario que sirven de entradas para los algoritmos propuestos. Como ejemplo, se presenta la tabla que representa los datos del barril Brent recogidos por el código desarrollado.

	Date	Open	High	Low	Close	Adj Close	Volume
0	2010-06-02	25.485001	25.615000	25.320000	25.590000	25.590000	26800
1	2010-06-03	25.715000	25.915001	25.420000	25.830000	25.830000	66800
2	2010-06-04	25.245001	25.245001	24.670000	24.700001	24.700001	12000
3	2010-06-07	24.799999	24.985001	24.565001	24.795000	24.795000	29000
4	2010-06-08	24.695000	24.850000	24.594999	24.690001	24.690001	65400
...
2408	2019-12-24	20.840000	20.959999	20.840000	20.920000	20.920000	37100
2409	2019-12-26	21.000000	21.160000	21.000000	21.120001	21.120001	71500
2410	2019-12-27	21.150000	21.230000	21.040001	21.180000	21.180000	105700
2411	2019-12-30	21.320000	21.360001	20.940001	21.080000	21.080000	156300
2412	2019-12-31	20.889999	21.139999	20.830000	20.850000	20.850000	103500

[2413 rows x 7 columns]

Table 2. Ejemplo datos recogidos

La **Tabla 2** representa la respuesta del código de web scraping diseñado con un gráfico de barras a la derecha que representa el volumen de transacciones y a la izquierda un gráfico de líneas que incluye los precios máximos, mínimos, de apertura y cierre.

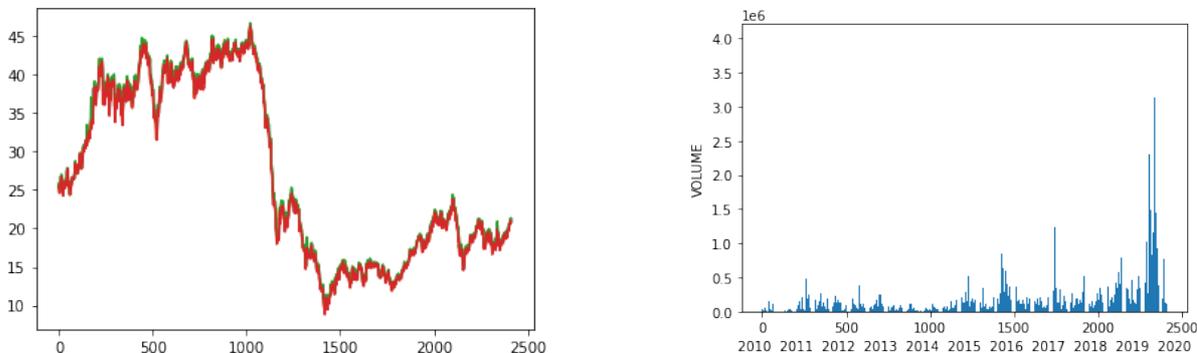


Ilustración 10. Representación gráfica de los datos del barril Brent.

Para poder observar mejor la representación gráfica de los datos del barril Brent se muestran en la Ilustración 12 los mismos datos que en la ilustración 1 pero en formato de velas japonesas. (Los huecos de la ilustración 12 está causado por los gaps diarios de los precios y la enorme cantidad de datos que Python se ha visto obligado a representar)

Evolución Barril Brent



Ilustración 11. Representación gráfica de los datos del barril Brent con velas japonesas.

Para evitar errores de procesamiento es necesario asegurarse que no hay celdas vacías en ninguna de las tablas de datos descargadas, el código del programa posee sentencias que desechan aquellas líneas de datos que posean alguna celda vacía o con valor cero. En el caso del barril Brent no han aparecido problemas, mientras que en el TTF se descubrieron tres fechas en las que no aparecía alguno de los datos; teniendo en cuenta que el estudio ha recogido datos de 10 años, se puede afirmar que Yahoo-finance tiene una plataforma fiable.

Missing Values	
TTF	3
Brent	0

Table 3. Missing values de los datos recogidos

Según la estrategia empleada, los datos requerirán de ser escalados, redimensionados o algún otro tipo de tratamiento; este es un punto que se abordará individualmente para cada herramienta.

Como análisis previo de los datos, se han calculado y representado a través de un programa de Python una caja de bigotes, la media y la desviación típica para el TTF y el barril Brent; con ello se pretende observar la simetría de los datos, analizar la cantidad de datos atípicos de cada serie y revisar las posibles diferencias entre una commodity y la otra.

Por cada ejercicio se han revisado los datos de entrada por separado, diferenciando entre los precios más altos, bajos, de apertura y de cierre; así, a la vez que se caracteriza cada serie, se pueden observar si existen comportamientos diferenciados entre las entradas de cada una.

Los resultados señalan que la diferencia entre los precios es mínima, tanto en la media como en la desviación típica, luego si se estudiase la evolución del precio del barril Brent conforme a distintas métricas, los resultados no deberían distarse significativamente unos de otros. Otra cosa que llama la atención es la desviación típica, que casi llega al 50% del valor de la media, por lo que es de suponer que la volatilidad y la variación de los precios es alta.

Para analizar la simetría de los datos se muestran a continuación los diagramas de bigotes para cada uno de los precios examinados:

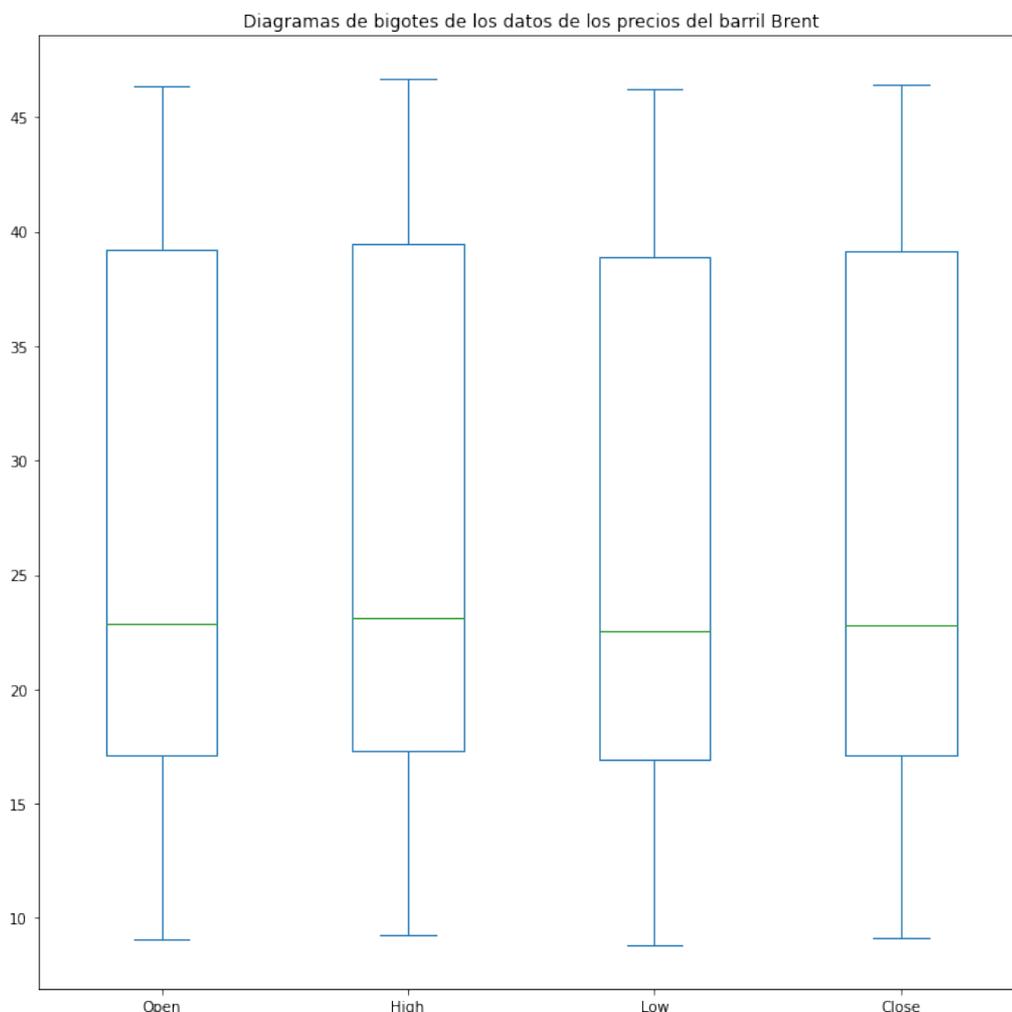


Ilustración 12. Diagramas de bigotes de los datos de los precios del barril Brent.

Al igual que ocurría con las medias y las desviaciones típicas, los diagramas de bigote a penas se diferencian entre sí.

En primer lugar, los números del TTF son significativamente superiores a los del barril Brent; luego, aunque a simple vista pueda parecer que las medias y las desviaciones típicas son más volátiles, la realidad es que a nivel porcentual son muy parecidas.

Una cosa que sí se diferencia del barril Brent, es que en el caso del TTF la desviación típica es porcentualmente mayor, sobrepasando el 70% del valor de la media; esto quiere decir que

la variabilidad de esta commodity es mayor, y tal y como confirman las cajas de bigotes que se muestran a continuación, la asimetría y presencia de outliers es superior:

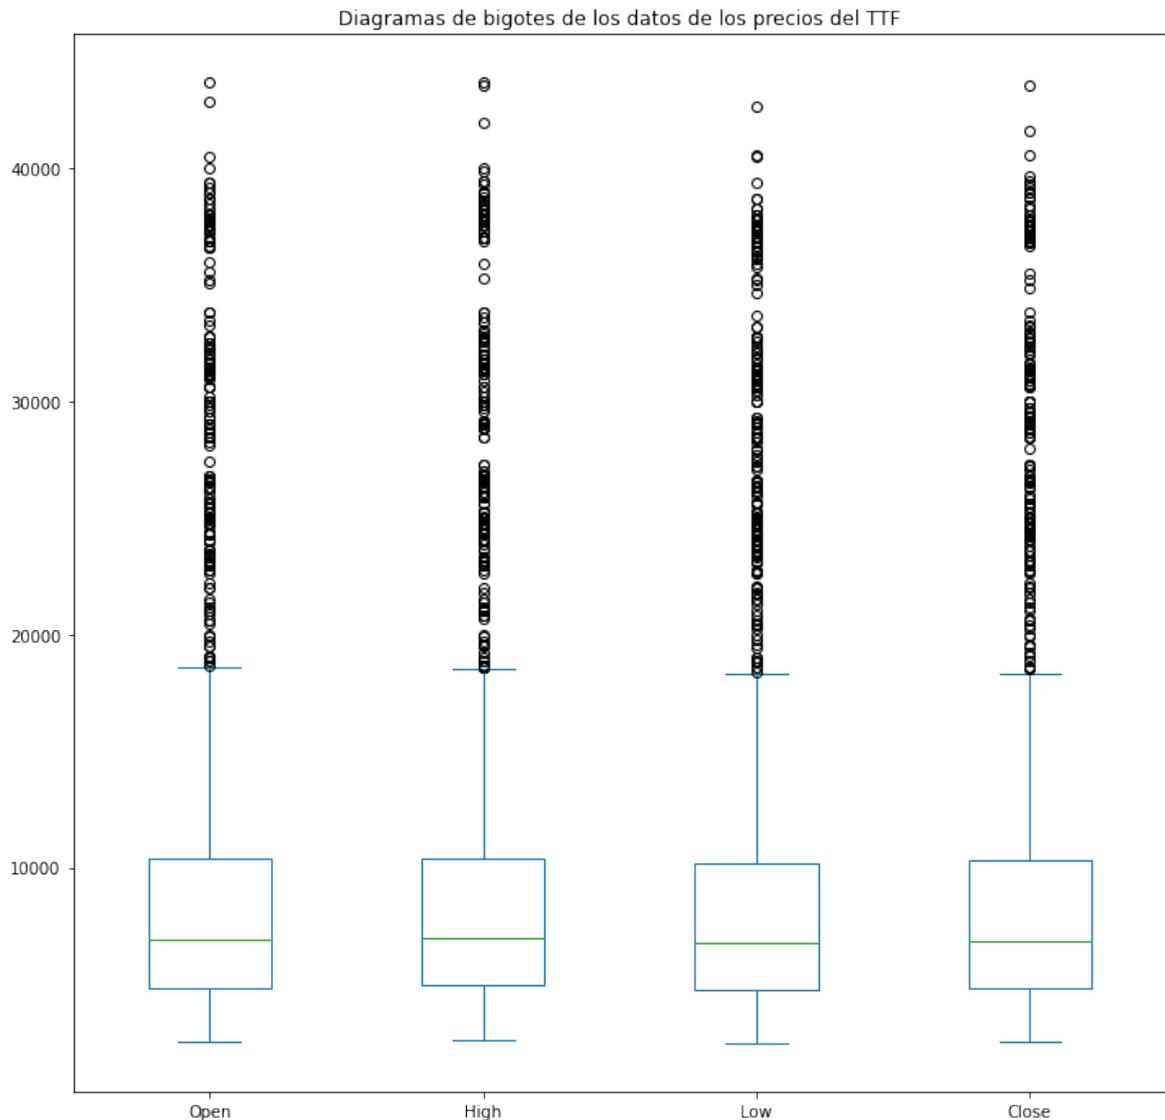


Ilustración 13. Diagramas de bigotes de los datos de los precios del TTF.

La ilustración 13, corrobora lo que se decía de los resultados de las desviaciones típicas, la asimetría del TTF es mayor que la del barril Brent, al igual que la presencia de datos atípicos y tal como ocurría con el barril Brent, los resultados entre precios no son significativamente diferentes unos de otros.

En suma, se puede asegurar que englobar todas las commodities energéticas como un mismo grupo, con características semejantes, no es coherente; se requiere un proceso de

diferenciación, con estudios separados que tengan en cuenta la individualidad de cada tipo de activo.

3.3 ALGORITMOS

En la sección 3.1 se comentaba que para abordar la tarea de predicción de los precios del barril Brent y el TTF se usarían dos filosofías distintas: La estadística tradicional y el DL. Las características de cada una de ellas no son excluyentes y en futuros trabajos se podría idear un modelo híbrido que agrupase las bondades de ambas.

En el punto 2 se comentaba que la principal diferencia entre la estadística tradicional y el DL es que mientras la primera debe contar con ciertos requisitos; véase la estacionalidad o la linealidad de los datos; las ARN son una especie de caja negra en la que una vez especificados los datos e hiperparámetros trabaja con autonomía. Esto hace que las ARN tengan menos limitaciones, no tratan de describir una serie a través de una fórmula, sino que son más flexibles y pueden adaptarse mejor a contextos menos previsibles.

En lo que a la **estadística tradicional** se refiere se han estudiado:

- La **estacionariedad** a través de la prueba de Dickey-Fuller
- La **cointegración** entre el precio del barril Brent y el TTF.
- La **cointegración** entre los datos de cada una de las series. (Precios de apertura, cierre, máximos, mínimos y el volumen)

Es importante destacar que el estudio se ha basado en los valores históricos de las series a lo largo de diez años, sin diferenciar épocas del año o eventos puntuales, de forma que de existir alguna relación estacional entre alguno de los atributos mencionados en los puntos anteriores, no se ha tenido en cuenta.

En cuanto al DL, se han probado distintas clases de ARN, que al contrario que en el caso anterior no están interrelacionadas entre sí, sino que cada uno compone una vía de estudio diferente:

- Long-Short Term Memory (**LSTM**). En este caso se han desarrollado dos códigos diferentes cuyas especificaciones se detallan en el apartado 3.4.2.1.

- Multilayer Perceptron (MLP).
- Convolutional Neural Network (CNN).
- **Autoencoders.**

Los conceptos que van detrás de cada tipo de Red Neuronal fueron explicados en el apartado 2, en el siguiente punto se aclararán las especificaciones propias de cada una de las estrategias seguidas.

3.4 IMPLEMENTACIÓN NUMÉRICA

Esta parte del trabajo aclara las características de cada una de las estrategias seguidas, justificando y detallando qué cosas han de tenerse en cuenta en cada una de ellas:

3.4.1 ESTADÍSTICA TRADICIONAL

Tanto para analizar la capacidad autorregresiva de las series como para mirar las posibles correlaciones entre ellas se han compartido estas características:

- Software: *Python*.
- Librerías: *Panda, Numpy, matplotlib, statsmodel, sklearn*.
- Entradas: *Precios de apertura, cierre, máximos, máximos, mínimos y volumen*.

3.4.1.1 Cointegración

En el apartado 3.1 se menciona que uno de los objetivos de este trabajo es encontrar posibles correlaciones entre el precio del barril Brent y el TTF holandés; de ser así, se podrían crear sinergias que se sirviesen de técnicas de spread para trading de multi-commodities.

Aunque no forma parte de las metas del trabajo, también se ha comprobado si existen correlaciones de los datos de los precios (De apertura, cierre, máximos y mínimos) entre sí y con respecto al volumen. Muchas estrategias de trading se basan en la relación previo/volumen, de ahí el interés por calcularlo.

Este examen se por medio de las pruebas de Granger y Dickey-Fuller. Cabe recordar que los resultados obtenidos tienen en cuenta los precios desde el 210 hasta el 2020 sin tener en

cuenta estaciones ni contextos subyacentes; esta aclaración es necesaria porque muchos expertos aseguran que los activos estudiados están relacionados bajo ciertas condiciones, este tema se deja como proposición para futuros trabajos (Aunque ya ha sido discutido en varias investigaciones).

3.4.2 DEEP LEARNING

Las redes neuronales son el eje principal de este documento, todos los códigos se han programado con Python; muchas de las librerías, sentencias y atributos son similares en estructura, sin embargo, cada red neuronal representa una estrategia distinta en la predicción de los mercados, de modo que por cada red neuronal desarrollada se detallan sus características principales: librerías empleadas, entradas, salidas, porcentaje del subconjunto de entrenamiento, porcentaje del subconjunto de testeo, tratamiento de los datos (redimensionamiento, escalas...) e hiperparámetros. (Optimizador, Medidas de error, Batch Size, Epochs, Activation function, número de neuronas o learning rate)

3.4.2.1 LSTM

El LSTM es una técnica muy útil para la predicción de series temporales, en este caso se han diseñado dos alternativas que buscan dados unos datos de entrada (Generalmente los precios y volúmenes de los treinta días previos), predecir el precio de apertura de los activos tratados al día siguiente.

Librerías	Time, datetime, pandas, numpy, matplotlib, MinMaxScaler, tensorflow, keras, math, sklearn.metrics.
Entradas	Precio de apertura, cierre, máximo, mínimo y volumen.
Salida	Precio de apertura del día siguiente.
% Subconjunto de entrenamiento	80%.
% Subconjunto de testeo	20%.
Hiperparámetros	Optimizador, Medidas de error (MAE), Batch Size, Epochs, número de unidades, número de capas ocultas, función de activación.
Pretratamiento de los datos	Escala y redimensionamiento.

Table 4 Ficha del programa LSTM

1º Programa: En este primer caso, el modelo precisa de un número de unidades (Neuronas en esa capa) variable, junto con la implantación de la función ReLu como función de activación y el diseño de las capas ocultas a través de Keras por su carpeta específica de LSTM.

La predicción del precio de apertura del día siguiente se realiza analizando los datos de los 30 días previos al mismo.

LSTM 2	
Librerías	Time, datetime, pandas, numpy, matplotlib, MinMaxScaler, tensorflow, keras, math, sklearn.metrics.
Entradas	Precio de apertura, cierre, máximo, mínimo y volumen.
Salida	Precio de apertura del día siguiente.
% Subconjunto de entrenamiento	80%.
% Subconjunto de testeo	20%.
Hiperparámetros	Optimizador, Medidas de error (MAE), Batch Size, Epochs, número de unidades, número de capas ocultas, función de activación.
Pretratamiento de los datos	Escala y redimensionamiento.

Table 5 Ficha del programa LSTM 2

El LSTM posee dos capas ocultas de 64 unidades y función de activación ReLu. La red neuronal funciona de forma que, una vez recogidos los datos, a través de la librería MinMaxScaler se escalan en una franja entre 0 y 1, se redimensionan para poder encajar en las capas ocultas, pasan por estas a través del optimizador Adam mientras se calcula su error MAE, se obtienen los resultados, se invierte la escala y finalmente se presentan los resultados. El proceso se lleva a cabo a partir de 100 epochs y un batch size igual a 100.

3.4.2.2 MLP

El MLP no tiene como salida una estimación del precio como el LSTM; que estima el precio de apertura de los mercados; sino que hace una dicotomía entre días alcistas o no alcistas; en términos aumento o disminución de los precios respecto al día anterior; basándose en los 30 días previos al día que se pretende estudiar.

MLP	
Librerías	Time, datetime, pandas, numpy, matplotlib, Pandas_datareader, sklearn.metrics, sklearn.neural_network, sklearn.pipeline, MinMaxScaler
Entradas	Precio de apertura, cierre, máximo y mínimo
Salida	Día positivo (1) o no positivo (0).
% Subconjunto de entrenamiento	80%.
% Subconjunto de testeo	20%.
Hiperparámetros	Medidas de error (Exactitud, Especificidad y Sensibilidad), función de activación y número de estados.
Pretratamiento de los datos	Escala y redimensionamiento.

Table5. Ficha del programa MLP

La red neuronal recibe los datos de entrada, los escala para poder trabajar con ellos, realiza una división entre los subconjuntos de entrenamiento y testeo, se ejecuta el MLP diferenciando entre días alcistas y días no alcistas; y finalmente muestra los resultados de las medidas de error expresados en la **Tabla 8**.

El diseño del MLP se realiza a partir de la librería de MLPClassifier que se encuentra en sklearn.neural_network.

3.4.2.3 CNN

Las CNN al igual que el MLP actúan como clasificadores estimando si un día será alcista o no. Su funcionamiento es más complejo que en el caso anterior y requerirá de la aplicación Keras para el aprendizaje de la red neuronal y de medias móviles para interpretar el movimiento de los mercados. Sus características principales son:

CNN	
Librerías	Time, datetime, pandas, numpy, matplotlib, Pandas_datareader, sklearn.metrics y Keras.
Entradas	Precio de apertura, cierre, máximo y mínimo
Salida	Día alcista (1) o no alcista (0).
% Subconjunto de entrenamiento	80%.
% Subconjunto de testeo	20%.
Hiperparámetros	Medidas de error (Exactitud, Especificidad y Sensibilidad), función de activación, Escala temporal de las medias móviles, batch_size, número de clases, epochs, número de filas y columnas por imagen, número de unidades, optimizador, Dropout
Pretratamiento de los datos	Escala y redimensionamiento.

Table 6 Ficha del programa CNN

La red neuronal recibe los datos, crea los subconjuntos de prueba y testeo conforme a las especificaciones de la **Tabla 6**, define dos medias móviles de 10 y 20 días respectivamente, añade una columna a los datos que muestra la diferencia entre los precios de apertura y cierre (Para ver si se trata de un día alcista o no), compara las medias móviles y si la media móvil de 10 días corta a la de 20 de forma ascendente se considerará que es un día alcista , incorpora el modelo de CNN; que consiste en un modelo secuencial de 3 capas en 2D, con funciones de activación ReLu, de 32, 16 y 10 neuronas respectivamente. Una vez ejecutada la red neuronal, se muestran los resultados según las medidas de error especificadas en la **Table 6**.

Adicionalmente, el número de epochs y batch size es de 100, el tiempo de ejecución 143 segundos y el tamaño del kernel es de 2.

3.4.2.4 Autoencoder

La red neuronal propuesta es una técnica híbrida que fusiona el LSTM más autoencoder, que al igual que la LSTM original trata de predecir el precio de apertura de las commodities del día siguiente teniendo en cuenta los resultados del mes anterior. De la misma forma que ocurre con la CNN, hay que aplicar keras, en el **capítulo 4** se comparan los resultados entre la LSTM y LSTM + Autoencoder para ver si mejora las predicciones originales. La **¡Error!** **No se encuentra el origen de la referencia.** profundiza sobre sus características:

Autoencoder + LSTM	
Librerías	Time, datetime, pandas, numpy, matplotlib, pylab, tensorflow, seaborn.
Entradas	Precio de apertura, cierre, máximo y mínimo
Salida	Precio de apertura del día siguiente.
% Subconjunto de entrenamiento	80%.
% Subconjunto de testeo	20%.
Hiperparámetros	Medidas de error (RMSE y MAE), función de activación, batch_size, número de clases, epochs, número de unidades, optimizador, Dropout y número de capas ocultas.
Pretratamiento de los datos	Escala y redimensionamiento.

Table 7 Ficha del programa Autoencoder + LSTM.

El funcionamiento y las características son casi las mismas que en el caso de la LSTM salvo en el caso del diseño de las capas ocultas, que incorporan keras y Dropout en vez de la función de activación ReLu. (Además del autoencoder, este código mezcla características de la primera y la segunda versión de LSTM)

La arquitectura de tipo secuencial se compone de 2 capas LSTM con 64 neuronas cada una, un Dropout rate de 0.2 y optimizador Adam. El número de epochs es 64 y el batch size 100, el tiempo de ejecución es de 92 segundos.

Capítulo 4. ANÁLISIS DE LOS RESULTADOS

4.1 RESULTADOS

Este capítulo se revisa el desempeño de cada técnica, se analizan los mejores resultados para el caso de estudio particular presentado y finalmente se brindan unas conclusiones sobre el desarrollo de este estudio.

4.1.1 ESTADÍSTICA TRADICIONAL

Los resultados de la prueba de Dickey Fuller señala que estos mercados no son estocásticos y se rechazan las hipótesis nulas con p-valores a niveles del cinco por ciento.

En cuanto a la cointegración, se estudia si existe alguna relación entre los precios del TTF y el barril Brent. De nuevo, se rechaza la teoría que estén correlacionadas. La diferencia de sus precios a lo largo de los diez años estudiados no muestra simbiosis perdurables en el tiempo.

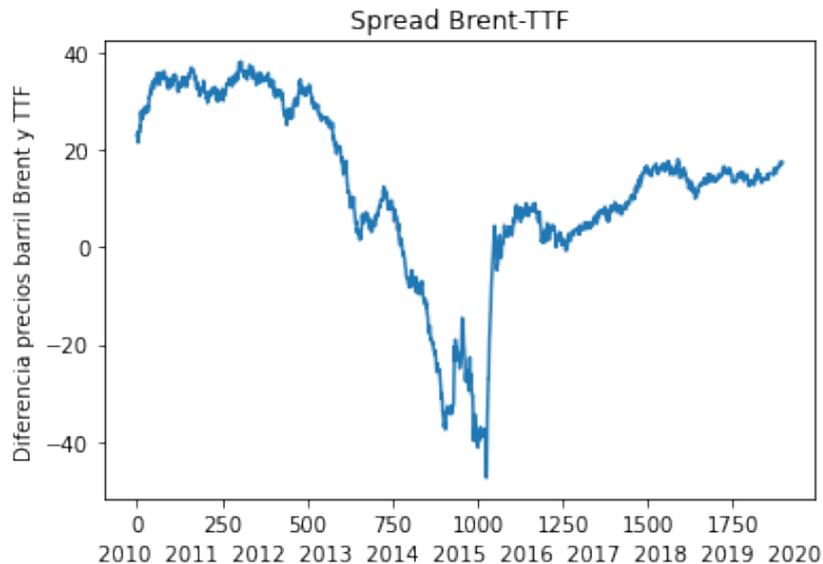


Ilustración 14. Diferencia entre los precios del Barril Brent y el TTF holandés.

La Ilustración 12 representa la diferencia entre los precios del barril Brent y el TTF holandés. Según se ve, existen breves periodos de tiempo; que pueden llegar a alcanzar varias semanas;

que muestran que el spread de precios entre un activo y otro se mantiene constante y podría representar niveles de correlación óptimos; las razones subyacentes de este fenómeno superan las expectativas de este documento y se deja como idea para futuros trabajos.

En cuanto a las relaciones precio de apertura-cierre, apertura-máximo, apertura-mínimo, cierre-máximo, cierre-mínimo, máximo-mínimo; tampoco ofrecen garantías que no rechacen la hipótesis inicial. No obstante, las observaciones que examinan el volumen y los precios muestran que sí existe cointegración tanto en el TTF como en el barril Brent, luego se puede afirmar que sí hay correlaciones entre el precio y el volumen.

El punto 4.1.1 muestra un análisis estadístico inicial, donde se pretende contextualizar el carácter de las series. Sin embargo, conforme a la literatura revisada, el Deep Learning presenta mejor desempeño, razón por la cual se ha decidido explorar más esta vía.

4.1.2 DEEP LEARNING

Evaluar una red neuronal es un proceso estándar: primero se describen los hiperparámetros que tienen mayor peso en los resultados, se detalla cómo deben tratarse para obtener las máximas prestaciones y finalmente se concluye las razones detrás de esos fenómenos. Algunos de los aspectos que hay que tener presente son:

- Diferencia entre subconjunto de entrenamiento y subconjunto de testeo. En un escenario ideal ambos obtendrían las mismas métricas, pero a menudo se suele sobreentrenar al subconjunto de entrenamiento, esto crea una distorsión en la red neuronal y aparece una diferencia notable en el resultado de los subconjuntos. Este fenómeno se denomina overfitting (o bias) y se debe evitar en cuanto se localice.
- Porcentaje de cada subconjunto. Entregar un mayor peso al entrenamiento que al testeo es una buena técnica, pero no se debe relegar el subconjunto de prueba a un porcentaje marginal. Minimizar en exceso al subconjunto de prueba puede presentar mejores resultados sobre el papel, pero se está incurriendo en un error de sobredimensionamiento que no muestra los resultados reales de la red y que omite el comportamiento de la herramienta frente a datos atípicos.

- Número de neuronas y hidden layers. Al definir el número de neuronas y hidden layers (En aquellos casos que corresponda) hay que tener cuidado con no sobredimensionarlo pues puede provocar overfitting.
- Clases de entrenamiento. Existen dos tipos de entrenamiento supervisado y no supervisado, en este documento se emplea el método supervisado que consiste en ajustar la red neuronal hasta mostrar la salida deseada, esta metodología permite evaluar los resultados por medio de su exactitud, error medio absoluto o error cuadrático medio.

4.1.2.1 LSTM

Para este enfoque, se han probado diversas configuraciones, variando número de neuronas, funciones de activación y el optimizador. Los mejores resultados se muestran para la siguiente arquitectura. sofisticado basado en la función de activación ReLu en vez de en la regularización Dropout. Las figuras 16 representa la estimación obtenida con el modelo basado en LSTM para el TTF:



Ilustración 15. Resultado código LSTM 2.

La línea roja representa la salida de cada una de las redes neuronales. Además de la diferencia notable entre una y otra configuración se deben destacar los siguientes puntos acerca del LSTM:

- A partir de dos capas escondidas (Hidden layers) la red no mejora sus resultados.
- A partir de las 64 neuronas la red comienza a sesgarse. (Overfitting)
- Cuando las dos capas escondidas tienen el mismo número de neuronas el desempeño de la red mejora.
- Los mejores resultados surgen cuando ambas capas tienen 32 neuronas.

Para evaluar el desempeño de la LSTM se han calculado los errores MAE de los subconjuntos de prueba y entrenamiento. La 8 presenta las métricas obtenidas una vez con las entradas y franjas temporales descritas en el capítulo 3; que representan las mejores condiciones posibles:

Nº hidden layers	Nº neurons 1º	Nºneurons 2º	Training	Test
2	32	16	0,368	0,578
2	32	32	0,355	0,501
2	64	16	0,418	0,594
2	64	32	0,375	0,48
2	64	64	0,413	0,5

Table 8 Resultados LSTM

La **¡Error! No se encuentra el origen de la referencia.**9 muestra cómo las cláusulas de las que se hablaban antes mejoran o empeoran las medidas obtenidas. Para el mejor caso (2 hidden layers, nº neuronas 1 de 32 y nº neuronas 2 de 32) se obtuvo un RMSE de 0,48.

4.1.2.2 MLP

Con la implementación de esta red se obtuvo el desempeño más pobre en términos de precisión, siendo sus errores muy elevados.

La mejor configuración de esta red propone una exactitud del 52%. Las sensibilidades y especificidades registradas son de 0,52 y 0,51 respectivamente.

Al contrario que el resto de las técnicas estudiadas este modelo funciona mejor cuantas menos entradas tenga; es decir actúa mejor cuando se le meten los precios de apertura, cierre, máximos o mínimos que con todos en conjunto. Además, los datos de cierre son los que funcionan mejor. Las comparaciones con el resto de las herramientas confirman lo expresado en el capítulo 2 sobre el estado del arte de la cuestión.

4.1.2.3 CNN

La técnica empleada en esta red es probablemente una de las más tradicionales dentro de la estrategia de trading, captura medias móviles, reconoce los movimientos del mercado, ajusta su estrategia a la volatilidad bursátil y replica el comportamiento de un trader real automatizando recursos teniendo en cuenta el histórico de los activos en su toma de decisiones.

Los mejores resultados se han obtenido a partir de medias móviles de 10 y 20 días; medio mes y un mes respectivamente por ser 5 días cotizados por semana; función de activación Relu, optimizador Adam, dropout de 0.2 en la pool layer y tres capas convolucionales de 32, 26 y 10 unidades respectivamente.

Las CNN son una herramienta que suelen utilizarse para el reconocimiento de imágenes, de ahí que el uso de keras sea tan importante en su implantación; no es necesario el uso de sistemas ARIMA o medias móviles, sin embargo, dado que en el contexto de trading su aplicación es habitual es adecuado. Podrían haberse realizado otra serie de alternativas como emplear un sistema híbrido entre CNN y LSTM, no utilizar medias móviles, experimentar con distintas franjas temporales en las medias móviles; pero salvo en este último caso no se han revisado debido a los resultados expuestos en el capítulo 2 donde se comprobaba que sus métricas no eran tan eficientes como la estrategia propuesta.

Para examinar la estrategia se han calculado la exactitud, la sensibilidad y la especificidad. La primera métrica fue del 62%; lo cual supone hasta ahora los mejores resultados obtenidos.

En cuanto a la sensibilidad y la especificidad, se obtuvieron unos resultados de 0,31 y 0,85 respectivamente.

4.1.2.4 Autoencoder

En este caso se ha optado por una estrategia híbrida que incluya Autoencoders más LSTM; las condiciones especificadas son muy parecidas a la de la LSTM luego puede ser un buen punto de partida para verificar si los autoencoders mejoran a la estrategia que emplea únicamente LSTM en este proceso.

Para revisar su funcionamiento se ha calculado el error RMSE y MAE, cuyas cifras se exponen en la :

	MAE	RMSE
Traning	0,34	0,28
Test	0,36	0,32

Table 9 Resultados Autoencoder +LSTM

Los resultados superan los obtenidos con la herramienta LSTM en solitario, luego se puede decir que la predicción de series temporales en mercados energéticos globales funciona mejor con LSTM más autoencoders que sólo con LSTM.

4.2 OBSERVACIONES

El punto 4.1 muestra que tanto los clasificadores como los regresores mejoran sus resultados cuanto más complejas son las técnicas aplicadas. (CNN frente a MLP y Autoencoders + LSTM frente a LSTM). Además, los resultados del Autoencoder + LSTM hacen pensar que de aplicarse más estrategias híbridas (Como CNN + LSTM) se obtendrían mejores resultados que con estrategias solitarias.

Existen dos herramientas que podrían ser interesantes a aplicar en un futuro, la primera es el transfer learning, es decir, coger datos de varias fuentes (Otros mercados, índices o bolsas) para entrenarlos y posteriormente volver a entrenarlos con el subconjunto de entrenamiento. La segunda es el empleo del Area Under the Curve (AUC), una métrica de error también empleada para el análisis del desempeño de estrategias basadas en Machine Learning.

Capítulo 5. CONCLUSIONES Y TRABAJOS FUTUROS

A la vista de los resultados se puede afirmar que las redes neuronales representan una vía útil para estudiar el desarrollo de los precios de commodities energéticas globales. La amplia gama de variedades que existe, ofrece una flexibilidad interesante, capaz de adaptarse a entornos cambiantes y volátiles. Además, en contraposición con lo que ocurre con la estadística, no requiere de ninguna condición para poder aplicarse.

Las redes neuronales empleadas han mostrado que sus desempeños mejoran cuanto más sofisticado se es el modelo; es decir, si se emplean modelos basados en redes convolucionales y LSTM, se analizan los patrones y secuencias que siguen sus comportamientos retirando aquella información no relevante y manteniendo la que es importante para la caracterización.

Las dos técnicas que mejor han funcionado han sido las Convolutional Neural Network para las ARN clasificadoras y el modelo híbrido de autoencoders más Long Short Term memory para las regresoras; su tratamiento de los datos de entrada, que revisa la calidad de su información para determinar que información mantener o no, es el punto diferencial respecto al resto de técnicas.

En próximos trabajos sería interesante aplicar modelos híbridos, conforme a lo visto con el modelo AUTOENCODER + LSTM, los sistemas duales pueden mejorar los resultados de aquellos que utilizan una sola técnica. De todas formas, se aconseja apostar por sistemas que junten técnicas cuyos desempeños individuales hayan sido probados anteriormente.

También sería interesante incluir en la metodología una serie de técnicas que puedan resultar útiles para el control de errores y trabajar con pocos datos. Los mercados energéticos globales suelen tener una accesibilidad de datos limitada si no se tiene experiencia previa o se trabaja en un entorno académico, de modo que aplicar una herramienta que ayude a ser más eficiente con la poca información de la que se disponga puede ser útil. El transfer learning, es una aplicación que trata de coger datos de varias fuentes (Otros mercados, índices o bolsas) para entrenarlos y posteriormente realizar una sintonización más fina de

los hiperparámetros con el subconjunto de entrenamiento, esta técnica es bien conocida por la industria por servir de primera fase de entrenamiento y mejorar el rendimiento de las ARN cuando la información disponible es reducida.

Capítulo 6. BIBLIOGRAFÍA

- [1] United States Securities and Exchange Commission. “Form 10-K The Goldman Sachs Group, Inc. Washington D.C.: printmgr file (goldmansachs.com)” Form 10-K. February, 2005. <https://www.goldmansachs.com/investor-relations/financials/current/10k/2020-10-k.pdf>.
- [2] Hernández, L. “Porcentaje de Traders que pierden dinero con CFDs “. Rankia. Marzo, 2020. <https://www.rankia.com/blog/bolsa-al-dia/3981222-porcentaje-traders-que-pierden-dinero-cfds>.
- [3] López, J.F. “Cointegración”. Economipedia. Mayo, 2020. <https://economipedia.com/definiciones/cointegracion.html>
- [4] Rodó, P. “Autorregresión”. Economipedia. Septiembre, 2020. [Autorregresión - Qué es, definición y concepto | 2022 | Economipedia](#).
- [5] Torres, J. “Redes Neuronales Recurrentes”. Jordi Torres AI, Junio 2021. [Redes Neuronales Recurrentes - Jordi TORRES.AI](#)
- [6] Futurology. “Convolutional Neural Networks Explained (CNN Visualized)”. Futurology, Diciembre 2020. [\(162\) Convolutional Neural Networks Explained \(CNN Visualized\) - YouTube](#)
- [7] Mathworks. “Support Vector Machine (SVM)”. Mathworks, Junio 2018. [Support Vector Machine \(SVM\) - MATLAB & Simulink \(mathworks.com\)](#)
- [8] Rajashree Dash, D. “A hybrid stock trading framework integrating technical analysis with machine learning techniques”. KeAi, Mayo 2016. <http://www.keaipublishing.com/en/journals/>
- [9] [Historical WTI Futures Curve Data | Energy Consultants London \(erce.energy\)](#)
- [10] Dias Paiva F. “Decision-making for financial trading: A fusion approach of machine learning and portfolio selection”. Elsevier, Octubre 2018. www.elsevier.com/locate/eswa
- [11] A. Gerlein E. “Evaluating machine learning classification for financial trading: An empirical approach”. Nottingham, Febrero 2016. www.elsevier.com/locate/eswa
- [12] Tsantekidis, A. “Using Deep Learning to Detect Price Change Indications in Financial Markets”. EUSIPCO, Octubre 2017. ISBN 978-0-9928626-7-1 © EURASIP 2017

- [13] Naik, N. “Study of Stock Return Predictions Using Recurrent Neural Networks with LSTM”. National Institute of technology of India. https://doi.org/10.1007/978-3-030-20257-6_39
- [14] Lu, H. “Carbon trading volume and price forecasting in China using multiple machine learning models”. Journal of cleaner production, Abril 2020. www.elsevier.com/locate/jclepro
- [15] Gu, Q. “A novel recurrent neural network algorithm with long-short-term memory model for futures trading”. Journal of Intelligent & Fuzzy Systems, Marzo 2019. ISSN 1064-1246/19.
- [16] Gerlein, E. “Evaluating machine learning classification for financial trading: An empirical approach”. ELSEVIER, Junio 2016. www.elsevier.com/locate/eswa.
- [17] Dash, R. “A hybrid stock trading framework integrating technical analysis with machine learning techniques”. KeAi, Diciembre 2016. <http://www.keaipublishing.com/en/journals/>
- [18] Pitarque, A. “Las redes neuronales como herramientas estadísticas no paramétricas de clasificación”. Psicothema. 2000.vol. 12, Supl n°2, pp 450-463.
- [19] Larrea, M y Casado U. “Determinantes del precio de la electricidad en España”. Volumen 59, número 194 / 2017, pp. 119-149.

ANEXO I

Alineación con los objetivos de desarrollo sostenible

El coste de la electricidad es un tema que le afecta a todas las personas en mayor o menor medida y los mercados financieros son lugares a los que muchos pequeños inversores recurren para rentabilizar sus ahorros, sumando una a la otra se obtiene como resultado una técnica que puede resultar de gran ayuda y reducir las desigualdades entre ricos y pobres. En ese sentido este trabajo contribuye con el objetivo de desarrollo sostenible de la organización de naciones unida número 8:



Ilustración 16. ODS número 8.

Además, los métodos utilizados para este documento se han basado principalmente en complejos algoritmos y desarrollo de códigos capaces de analizar el desarrollo de series temporales. El abanico de posibilidades que se abre para este tipo de tecnología no se limita al trading, sino que es aplicable a muchos campos en donde la inteligencia artificial se abre paso de forma subversiva, su uso es cada vez más común y es directamente responsable del aumento de la eficiencia en procesos de producción, mejor análisis de riesgos y aprovechamiento de los recursos, unos fines que se alinean con el objetivo número 10 de las naciones unidas acerca del trabajo decente y crecimiento económico:



Ilustración 17. ODS número 10.

ANEXO II

Pseudocódigos:

Programa 1 {Descarga de los datos}

Importar librerías:

Para manejo de datos

Para clasificación temporal diaria

Especificar qué información recoger:

Página web: [Yahoo finance](#)

Detallar datos del activo: [Fechas, ticker & formato csv](#)

Tratamiento de los datos.

Borrar: [Datos las celdas vacías & repetidos](#)

Programa 2 {Estudio previo de los datos}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para clasificación temporal diaria

Para cálculos matemáticos

Para cálculos estadísticos

Para representar gráficas

Realizar operaciones:

Calcular: Medias, desviaciones típicas y mediana

Representar gráficas:

Mostrar: Diagramas de bigotes y gráficos de velas

Programa 3 {Versión 1 LSTM}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

Para escalar los datos

Para insertar capas LSTM

Para identificar patrones y secuencias

Para hacer operaciones matemáticas

Para calcular errores

Procesamiento de los datos:

Definición tamaños de los subconjuntos: **Training & test set**

Escalar los datos: **En valores entre 0 y 1**

Definición de la estructura de ensayos:

Datos de entrada: **Precios de apertura, cierre, máximos y mínimos de las 4 semanas anteriores al día previsto**

Salidas: **Precio de apertura del día siguiente**

Definición del modelo predictivo:

Red Neuronal: **LSTM**

Función de activación: **ReLu**

Número de capas: **2**

Errores: Error cuadrático medio

Optimizador: Adam

Número de batches y epochs: 10 & 100

Ejecución del modelo:

En los subconjuntos de: Test y training

Deshacer la escala

Comprobación de los resultados:

Errores

Gráficas

Programa 4 {Versión 2 LSTM}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

Para escalar los datos

Para insertar modelos

Para identificar patrones y secuencias

Para hacer operaciones matemáticas

Para calcular errores

Procesamiento de los datos:

Definición tamaños de los subconjuntos: Training & test set

Escalar los datos: En valores entre 0 y 1

Definición de la estructura de ensayos:

Datos de entrada: Precios de apertura, cierre, máximos y mínimos de las 4 semanas anteriores al día previsto

Salidas: Precio de apertura del día siguiente

Definición del modelo predictivo:

Red Neuronal: LSTM

Sistema: Drop Out

Número de capas: 2

Errores: Error cuadrático medio

Número de neuronas: 32 y 16

Optimizador: Adam

Número de batches y epochs: 10 & 100

Ejecución del modelo:

En los subconjuntos de: Test y training

Deshacer la escala

Comprobación de los resultados:

Errores

Gráficas

Programa 5 {Cointegración}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

Para realizar cálculos matemáticos

Para operaciones estadísticas

Para cálculos de errores

Operaciones:

Calcular: Spread, test de Dickey Fuller

Revisar: Cumplen condiciones de cointegración

Definición de la estructura de ensayos:

Datos de entrada: Precios de apertura, cierre, máximos y mínimos de las 4 semanas anteriores al día previsto

Salidas: Precio de apertura del día siguiente

Representar

Resultados: Según los tests y mostrar gráficas

Programa 6 {Autorregresión}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

Para realizar cálculos matemáticos

Para operaciones estadísticas

Para cálculos de errores

Operaciones:

Calcular: p-valor, Augmented Dickey Fuller

Revisar: Cumplen condiciones de cointegración

Definición de la estructura de ensayos:

Revisar: La capacidad autorregresiva de todos los elementos que sean precios

Representar

Resultados: Destacar si pasan los requisitos para ser autorregresivos y mostrar gráficas

Programa 7 {MLP}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

- Para escalar los datos
- Para insertar capas MLP
- Para identificar patrones y secuencias
- Para hacer operaciones matemáticas
- Para calcular errores

Procesamiento de los datos:

Definición tamaños de los subconjuntos: **Training & test set**

Escalar los datos: **En valores entre 0 y 1**

Definición de la estructura de ensayos:

Datos de entrada: **Precios de apertura, cierre, máximos y mínimos de las 4 semanas anteriores al día previsto**

Salidas: **Precio de apertura del día siguiente**

Definición del modelo predictivo:

Red Neuronal: **MLP**

Función: **Random_state y shuffle**

Número de capas: **2**

Errores: **Error cuadrático medio**

Optimizador: **Adam**

Ejecución del modelo:

En los subconjuntos de: **Test y training**

Deshacer la escala

Comprobación de los resultados:

Errores

Gráficas

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

Para escalar los datos

Para insertar capas convolucionales

Para capas tipo Flatten

Para Dropout

Para identificar patrones y secuencias

Para hacer operaciones matemáticas

Para calcular errores

Para manejo de listas

Para manejo de fechas

Procesamiento de los datos:

Definición tamaños de los subconjuntos: Training & test set

Escalar los datos: En valores entre 0 y 1

Definición de la estructura de ensayos:

Datos de entrada: Precios de apertura, cierre, máximos y mínimos de las 4 semanas anteriores al día previsto

Salidas: Precio de apertura del día siguiente

Definición de varias medias móviles: De 10 y 20 días

Creación de pantallas tipo trader: Que contengan los precios, el volumen y las medias móviles

Ajuste de clasificación para días alcistas y no alcistas: En función de si la diferencia del precio de cierre es mayor o inferior al de apertura

Creación de matrices: Que recojan la información y lo relacionen con la media móviles

Definición del modelo predictivo:

Red Neuronal: CNN

Función: ReLu, DropOut, Flatten

Número de capas: 2

Errores: Exactitud

Optimizador: Adam

Ejecución del modelo:

En los subconjuntos de: Test y training

Deshacer la escala

Comprobación de los resultados:

Errores

Gráficas

Programa 9 {Autoencoders + LSTM}

Aplicar:

Programa 1

Importar librerías:

Para manejo de datos

Para representar gráficas

Para escalar los datos

Para insertar capas LSTM

Para procesos de Autoencoder

Para identificar patrones y secuencias

Para hacer operaciones matemáticas

Para calcular errores

Para manejo de listas

Para manejo de fechas

Procesamiento de los datos:

Definición tamaños de los subconjuntos: **Training & test set**

Escalar los datos: **En valores entre 0 y 1**

Definición de la estructura de ensayos:

Datos de entrada: **Precios de apertura, cierre, máximos y mínimos de las 4 semanas anteriores al día previsto**

Salidas: **Precio de apertura del día siguiente**

Definición del modelo predictivo:

Red Neuronal: LSTM + Autoencoders

Función: ReLu, DropOut,

Número de capas: 2

Errores: Mae, rmse

Optimizador: Adam

Optimizador: Adam

Número de batches y epochs: 10 & 100

Ejecución del modelo:

En los subconjuntos de: Test y training

Deshacer la escala

Comprobación de los resultados:

Errores

Gráficas