



*Facultad de Ciencias Económicas y Empresariales
ICADE*

***Influencia del Sentimiento de las Noticias
en los Retornos Anormales de ExxonMobil:
Un Análisis Comparativo entre el Financial
Times y el Wall Street Journal***

Autor: Francisco Javier Vázquez Visos

Director: Carlos Bellón Núñez-Mera

MADRID | Junio 2024

ÍNDICE DE CONTENIDO

ABSTRACT.....	4
CONTEXTO Y DECLARACIÓN.....	6
MARCO TEÓRICO.....	8
ESTADO DEL ARTE.....	15
ANÁLISIS.....	19
CONCLUSIONES.....	48
ANEXOS.....	52

ÍNDICE DE TABLAS

Tabla 1: Precios.....	21
Tabla 2: Factores.....	22
Gráfica 1: Evolución Exxon.....	23
Gráfica 2: Evolución Betas.....	26
Gráfica 3: Comparación retornos.....	28
Gráfica 4: Diferencias entre retornos.....	29
Tabla 3: Sentimientos.....	30
Gráfica 5: Comparación noticias FT.....	32
Gráfica 6: Desglose noticias FT.....	33
Gráfica 7: Gráfico violín FT.....	33
Gráfica 8: Posición eventos FT.....	35
Gráfica 9: Retornos Anormales FT.....	37
Tabla 4: Estadísticas eventos FT.....	39
Gráfica 10: Distribución retornos anormal FT.....	41
Gráfica 11: Comparación noticias WSJ.....	42
Gráfica 12: Desglose noticias WSJ.....	43
Gráfica 13: Gráfico violín WSJ.....	43
Gráfica 14: Posición eventos WSJ.....	44
Gráfica 15: Retornos Anormales WSJ.....	45
Tabla 5: Estadísticas eventos WSJ.....	46
Gráfica 16: Distribución retornos anormal FT.....	48

ABSTRACT

This study examines the influence of news sentiment on the abnormal stock returns of ExxonMobil, using data from the Financial Times and the Wall Street Journal. Employing ordinary least squares regression models based on the Fama-French model, daily returns and their relationship with the tone of the news were evaluated.

The analysis includes t-Student tests to examine the effects of news on event days compared to non-event days, as well as between news with positive and negative sentiments. The results indicate that positive or negative news have a significant impact on the abnormal returns of ExxonMobil's stock around the date of publication of such news, highlighting variations in market reactions based on the origin of the news.

This work contributes to the financial literature by demonstrating how perceptions of news can vary depending on the source and region, underscoring the importance of considering these factors in investment decision-making.

RESUMEN

Este estudio examina la influencia del sentimiento de noticias en los retornos anormales de las acciones de ExxonMobil, utilizando datos del Financial Times y del Wall Street Journal. Mediante el empleo de modelos de regresión de mínimos cuadrados ordinarios basado en el modelo de Fama-French, se evaluaron los retornos diarios y la relación con el tono de las noticias.

El análisis incluye pruebas de t-Student para examinar los efectos de las noticias en días de eventos comparados con días no evento, así como entre noticias con sentimientos positivos y negativos. Los resultados indican que las noticias positivas o negativas tienen un impacto significativo en los retornos anormales de las acciones de ExxonMobil alrededor de la fecha de publicación de esas noticias, destacando variaciones en la reacción del mercado según el origen de las noticias.

Este trabajo aporta a la literatura financiera al demostrar cómo las percepciones de las noticias pueden variar según la fuente y la región, resaltando la importancia de considerar estos factores en la toma de decisiones de inversión.

CONTEXTO Y DECLARACIÓN

En las últimas décadas, el entorno financiero ha sido testigo de una creciente relación bidireccional entre los mercados financieros y la información que se recibe por parte de los medios de comunicación. Ante este panorama, las grandes corporaciones se encuentran a menudo en el centro de atención mediática. La manera en que los medios de comunicación reportan sobre estas empresas puede tener influencias significativas en la percepción pública y, consecuentemente, en el valor de mercado de sus acciones (Ziyue, 2023).

OBJETIVOS Y PREGUNTAS DEL ESTUDIO

El propósito principal de este trabajo es explorar la relación entre la percepción mediática de ExxonMobil, medida a través de los *sentiment scores* de noticias importantes en el Wall Street Journal y el Financial Times, y los movimientos en el precio de sus acciones. De esta forma, se busca entender cómo estas percepciones influyen, de manera cuantificable, las decisiones de los inversores y, por ende, los valores de mercado. De manera más específica, el estudio intentará y observar si dichas noticias han tenido un impacto significativo en los retornos del mercado.

Así pues, se busca distinguir el impacto diferenciado de las noticias positivas frente a las negativas sobre el precio de las acciones. Esto permitirá analizar si la naturaleza del sentimiento provoca variaciones más agudas en la cotización bursátil. De esta forma, el estudio plantea diversas preguntas: ¿Cómo afectan las noticias con altos *sentiment scores* sobre ExxonMobil al precio de sus acciones en el periodo de publicación de dichas noticias? ¿Cómo difiere la respuesta del mercado ante noticias positivas comparadas con noticias negativas? ¿Se perciben diferencias entre el trato que recibe ExxonMobil por un periódico estadounidense y uno británico?

JUSTIFICACIÓN

Este trabajo aporta valor al ámbito de estudio ya que proporciona una comprensión más profunda de cómo las noticias influyen las decisiones de los inversores y pueden modificar el valor de mercado. Comprender esta dinámica no solo es relevante para los inversores y analistas financieros que buscan optimizar sus estrategias de inversión, sino también para la gestión corporativa de empresas como ExxonMobil. Además, amplía la literatura en finanzas comportamentales y análisis de medios, explorando cómo la percepción pública moldeada por los medios puede impactar la estabilidad financiera de grandes corporaciones y, por extensión, de los mercados en general.

MARCO TEÓRICO

Introducción

En la era digital en la que vivimos, la información y el dato se han convertido en uno de los activos más valiosos que puede haber, especialmente si hablamos del campo de las finanzas, donde decisiones cruciales pueden depender de una correcta y precisa interpretación de estos datos masivos. Dentro de este extenso universo del dato, el texto juega un papel primordial, ofreciendo perspectivas únicas y detalladas sobre los mercados financieros, el comportamiento de las empresas y las tendencias económicas. Así pues, el presente marco teórico busca establecer cierto contexto sobre la investigación, así como explorar y desglosar los fundamentos del análisis de texto en finanzas, un campo interdisciplinario que se sitúa en la intersección del procesamiento de lenguaje natural (PLN), la estadística y las finanzas.

Para empezar, la empresa a analizar en el presente estudio, ExxonMobil (oficialmente conocida como Exxon Mobil Corporation) es una de las mayores empresas públicas y privadas de petróleo y gas del mundo. Fundada en 1999 tras la fusión de Exxon y Mobil, ambas descendientes de la Standard Oil Company de John D. Rockefeller, ExxonMobil tiene su sede en Irving, Texas. La compañía opera en todas las áreas del negocio del petróleo y gas, incluyendo la exploración, extracción, refinación, transporte y venta de petróleo y productos derivados del petróleo y gas natural (ExxonMobil, s.f.).

A lo largo de los años, ExxonMobil ha establecido una notable presencia global, operando en numerosos países y explotando grandes reservas de recursos energéticos. Se destaca también por su participación en investigaciones de energías renovables y su implicación en desarrollos de nuevas tecnologías para mejorar la eficiencia energética (ExxonMobil, s.f.).

Event Studies

Para comprender el enfoque del trabajo, es fundamental conocer el método conocido como análisis de eventos, o *event studies*. Iniciado en el ámbito de la contabilidad y las finanzas, se usa para realizar estudios empíricos a través de técnicas estadísticas. Con el tiempo, esta técnica ha encontrado aplicaciones en una amplia variedad de campos, que incluyen, entre otros, economía, historia, derecho, administración de empresas, marketing y ciencias políticas. La clave de su amplia adopción y del interés continuo de la comunidad académica en este enfoque se debe a su flexibilidad y capacidad de innovación, lo cual se refleja en las constantes discusiones sobre sus avances metodológicos y la evaluación de sus beneficios en diferentes áreas de investigación (Corrado, 2011).

Presentados inicialmente en dos estudios clave por Ball y Brown (1968) y por Fama, Fisher, Jensen y Roll (1969), los estudios de eventos emergieron como una metodología fundamental para analizar los mercados de capitales. Estos trabajos se basaron en el "modelo de mercado", que a su vez fue influenciado por el modelo CAPM creado por Sharpe (1964), haciendo uso intensivo de los datos proporcionados por el Centro de Investigación en Precios de Seguridad (CRSP) y de la tecnología informática avanzada de la época. Dichos estudios se han establecido como instrumentos cruciales para la investigación en áreas que abordan la estructura del capital, marcando el comienzo de una nueva era en el estudio de las finanzas, inspirados en los influyentes trabajos de Modigliani y Miller. De esta forma, Mitchell y Netter (1994) definen a los event studies de la siguiente forma textual: "Un estudio de eventos es una técnica estadística que estima el impacto en el precio de las acciones de sucesos tales como fusiones, anuncios de ganancias, y demás. La idea básica es desentrañar los efectos de dos tipos de información en los precios de las acciones: información específica de la empresa en cuestión (por ejemplo, anuncio de dividendos) e información que probablemente afecte a los precios de las acciones en todo el mercado (por ejemplo, cambio en las tasas de interés)." (Corrado, 2011).

Procesamiento de Lenguaje Natural

Por otro lado, el Procesamiento del Lenguaje Natural, por sus siglas PLN, es una rama de la inteligencia artificial que busca centrarse en la relación que existe entre los ordenadores y el lenguaje humano. Así pues, nos encontramos ante una disciplina en la que la ciencia computacional, el lenguaje y la inteligencia artificial (IA) confluyen en el análisis continuo sobre cómo el lenguaje humano puede ser leído, entendido, interpretado y manipulado por máquinas de manera efectiva y eficiente. Sin embargo, uno de los principales desafíos en el PLN es cómo de ambiguo el lenguaje humano puede llegar a ser debido a que está sujeto a múltiples interpretaciones. Esto ha requerido del desarrollo de algoritmos sofisticados y modelos de aprendizaje automático para una correcta interpretación. (Jurafsky & Martin, 2019)

Para un correcto entendimiento del Procesamiento de Lenguaje Natural, es necesario entender el concepto de dato no estructurado, ya que es lo que ocasiona que esta metodología de análisis de texto sea tan ambigua y compleja. Básicamente, los datos no estructurados son definidos por la empresa tecnológica Elastic (s.f.), creadores de herramientas de análisis como Kibana o Logstash, como: “[...] datos que no están organizados en una estructura o un modelo diseñado. Los datos no estructurados suelen estar categorizados como cualitativos y podrían estar generados por máquinas o humanos. Los datos no estructurados son el tipo de datos más abundantes disponible y, una vez analizados, pueden usarse para guiar decisiones comerciales y lograr objetivos comerciales entre muchos otros casos de uso”. En otras palabras, son aquellos datos que carecen de una estructura o formato predefinido, a diferencia de los estructurados que sí poseen dicho formato definido, como puede ser una serie temporal. De esta forma, una noticia o una publicación en X caen bajo esta definición. Es esta naturaleza “desordenada” la que ocasiona el proceso de análisis complejo que se explicó anteriormente y la que justifica la existencia del Procesamiento de Lenguaje Natural debido a las técnicas avanzadas que proveen.

En primer lugar se encuentra el *sentiment analysis*, o análisis de sentimientos, en español. Se trata de un extenso proceso de estudio de datos con el objetivo principal de identificar y clasificar las distintas opiniones expresadas en los textos analizados para poder, así, categorizar la actitud o intención del autor de los mismos hacia el tema tratado. De esta forma, el resultado del *sentiment analysis* puede ser positivo, negativo o neutro. Así pues, el primer paso a la hora de realizar un análisis de sentimientos es la recolección de datos, ya sea en un portal de noticias o una red social. Seguidamente, se debe realizar una limpieza de datos. Es decir, eliminar las palabras que se consideren innecesarias para el análisis o que no estén relacionadas con el tema a tratar. En tercer lugar, se lleva a cabo el proceso de detección de sentimiento *per se* a través de diversos sistemas o técnicas establecidos que se explicarán más adelante. Finalmente, los sentimientos detectados en el anterior paso son clasificados en función de si son positivos, negativos o neutros, tal y como se estipuló previamente. De esta forma, los resultados quedan listos para poder ser expuestos a través de herramientas de visualización de datos. (Aqlan, Manjula, & Lakshman Naik, 2019)

A la hora de realizar un sentiment analysis se pueden utilizar diversas técnicas, como puede ser un modelo de regresión logística (Reddy, Sri, Reddy & Shaik, 2021), redes neuronales y Deep Learning como Long Short-Term Memory (Murthy, Allu, Anshvarapu, & Belusonti, 2020), Bag of Words y TF-IDF (Ahuja, Chug, Kohli & Gupta, 2019), modelos de clasificación como Naïve Bayes o SVM (Korovkinas, Danėnas & Garšva 2017) o Word Embeddings (Çano & Morisio, 2019).

Una de estas herramientas a destacar es VADER. Se caracteriza como una herramienta de análisis de sentimientos que funciona con base en reglas. Es especialmente efectiva para analizar textos breves y desordenados, como los típicos de las redes sociales. Esta herramienta emplea un léxico preestablecido que asigna puntuaciones de intensidad a palabras específicas, además de utilizar reglas heurísticas que evalúan la valencia del sentimiento (positiva, negativa o neutra) para realizar el análisis (Hutto & Gilbert, 2014).

Una etapa que es importante mencionar dentro del procesamiento de lenguaje natural es la tokenización. Así pues, la tokenización se encuentra definida como un método de procesamiento dentro de NLP en el cual, principalmente, se divide el contenido de un texto en las palabras o términos principales que lo componen, formando así los tokens o unidades básicas. Por ejemplo, si la frase que aparece en el texto es: “El perro está despierto”, los tokens serían: [“El”, “perro”, “está”, “despierto”]. Sin embargo, este proceso de tokenización trae consigo ciertas dificultades, como el hecho de que en algunos idiomas una única palabra puede ser varios tokens diferentes. (Vijayarani & Janani, 2016)

CAPM y Fama - French

En el ámbito del análisis financiero, el Modelo de Valoración de Activos de Capital (CAPM) es una herramienta esencial. Proporciona un marco teórico para entender cómo el riesgo asociado a una inversión influye en el retorno esperado. Desarrollado en los años 60 por expertos como Sharpe, Lintner y Mossin, el CAPM sugiere que el retorno de un activo debe ser suficiente para compensar al inversor por tomar un riesgo mayor al que implicaría una inversión sin riesgo.

$$E(R_i) = R_f + \beta_i(E(R_m) - R_f)$$

(Sharpe, 1990)

Aquí, $E(R_i)$ simboliza el retorno esperado del activo i , R_f representa la tasa de retorno libre de riesgo, β_i es un coeficiente que mide la sensibilidad del retorno esperado del activo al mercado en general, y $E(R_m) - R_f$ es la prima de riesgo del mercado, indicando el exceso de retorno esperado del mercado sobre la tasa libre de riesgo (Sharpe, 1990).

Como modelo alternativo, Fama y French introdujeron un modelo de tres factores que incorpora dos variables adicionales destinadas a explicar las discrepancias en los retornos de las acciones que no son capturadas por el riesgo de mercado solo. Este modelo avanzado, a

diferencia del CAPM que solo considera el riesgo de mercado, introduce dos factores de riesgo adicionales: la prima de riesgo de las empresas pequeñas y la prima de riesgo asociada a las empresas con alta relación de valor contable sobre valor de mercado (empresas "value") en comparación con aquellas con alto potencial de crecimiento.

$$E(R_i) = R_f + \beta_{iM}(E(R_m) - R_f) + \beta_{iSMB} \cdot SMB + \beta_{iHML} \cdot HML$$

(Fama & French, 2004)

Donde SMB (*Small Minus Big*) es la prima por el riesgo asociado al tamaño de las empresas, y HML (*High Minus Low*) representa la prima por el riesgo vinculado a las empresas *value*, con altos ratios de valor contable a valor de mercado, en contraste con las empresas *growth*, que tienen expectativas de alto crecimiento pero menores ratios de valor contable.

Se trata, así, de un análisis profundizado del CAPM, ya que la extensión propuesta por Fama y French subraya la importancia de considerar múltiples dimensiones del riesgo al evaluar el potencial de retorno de las inversiones en acciones, proporcionando así una herramienta más rica y matizada para la valoración de activos en el campo de la teoría financiera (Fama & French, 2004).

Cálculo de Retornos Anormales

El núcleo del análisis en un estudio de eventos reside en identificar los retornos anormales, es decir, aquellos rendimientos que se desvían de lo que el modelo de mercado predice:

$$A_0 = R_0 - E(R_0 | RM_0)$$

(Elaboración propia)

Donde A_0 es el retorno anormal en el día 0, R_0 es el retorno observado del activo en el día 0, y $E(R_0 | R_{M0})$ representa el retorno esperado del activo dado el retorno del mercado R_{M0} en ese día. El retorno anormal se calcula, pues, mediante la diferencia entre el retorno observado durante el evento (R_0) y el retorno esperado basado en el modelo de mercado. Este cálculo permite aislar el efecto del evento en estudio sobre el valor del activo, independientemente de las fluctuaciones generales del mercado (Sorescu et. al, 2017).

Los retornos anormales pueden tomar diferentes formas, como pueden ser los retornos anormales acumulados, o CAR por sus siglas en inglés, que no es más que la suma de los retornos anormales en un período especificado, tal y como se ve a continuación:

$$CAR_{it} = \sum_{t-k}^{t+l} AR_{it}$$

(Sorescu et. al, 2017)

La validación estadística de los retornos anormales es crucial para afirmar la influencia de un evento sobre el valor de las acciones. Esta validación puede implicar tanto técnicas paramétricas como no paramétricas, dependiendo de la naturaleza de los datos. Las pruebas no paramétricas, como la prueba de rangos, ofrecen una herramienta robusta frente a distribuciones de retorno no normales, asegurando la fiabilidad de los resultados incluso cuando las premisas de normalidad no se cumplen.

La esencia de la metodología de estudio de eventos radica en su capacidad para examinar el impacto que eventos corporativos específicos, como anuncios de nuevas alianzas, aprobaciones regulatorias, o entradas de nuevos competidores, tienen en el movimiento de los precios de las acciones de una compañía. Aunque fue concebida por investigadores financieros, su adopción en otros campos puede permitir explorar el valor financiero de acciones en marketing, por ejemplo, y cómo estas pueden influir en el mercado de valores. La metodología se basa en calcular rendimientos anormales, es decir, aquellos rendimientos que

se desvían de lo esperado basado en modelos predictivos de rendimiento como el modelo de mercado, durante y alrededor del evento.

ESTADO DEL ARTE

La premisa fundamental muchos estudios relacionados con el tema a tratar es que los precios de las acciones no solo son influenciados por factores económicos y financieros tradicionales, sino también por las percepciones y sentimientos del público expresados a través de las noticias. Esta hipótesis se basa en la observación de que las noticias financieras pueden causar fluctuaciones significativas en el mercado, afectando la confianza de los inversores y, por ende, los precios de las acciones.

Para investigar esta relación, Mohan et. al (2019), se centraron en la exploración de la relación entre el análisis de sentimientos de las noticias y los movimientos de precios de las acciones. Los autores recopilaron un amplio conjunto de datos que incluía precios diarios de las acciones de las empresas del S&P 500, junto con más de 265.000 artículos de noticias financieras relacionadas con estas compañías, cubriendo un período de cinco años. Así pues, los investigadores emplearon técnicas de procesamiento de lenguaje natural (NLP) para analizar el contenido de los artículos de noticias, buscando identificar y clasificar los sentimientos expresados. Este análisis de sentimientos se integró luego con los datos históricos de precios de las acciones para entrenar modelos de aprendizaje profundo con el objetivo de predecir los movimientos futuros de los precios.


Para su estudio, los autores realizaron estimaciones de las acciones de Apple Inc. con distintos modelos para, más tarde, comparar los resultados con el precio real de cotización diaria. De esta forma, la investigación confirmó la existencia de una correlación significativa entre los sentimientos derivados de las noticias financieras y los movimientos de precios de las acciones. En definitiva, se pudo comprobar como los modelos que incorporaron análisis de sentimientos junto con datos históricos de precios mostraron una mejora notable en la precisión de las predicciones, pero con excepciones en casos de volatilidades extremas en ambos sentidos.

De manera similar, otro estudio importante a destacar en este análisis es *Predicting the Effects of News Sentiments on the Stock Market* (Shah, Isah & Zulkernine, 2018). En él, se aborda la capacidad de predecir el mercado de valores utilizando el análisis de sentimiento de noticias financieras, con un enfoque en la industria farmacéutica a través de tres empresas del índice Nifty Pharma.

Lo más destacable de este análisis, y lo que lo hace interesante respecto a otros estudios similares como el anterior, es que los autores desarrollaron un diccionario especializado en el sector a analizar, muy útil para que el análisis de sentimiento posterior a la tokenización represente de manera más fidedigna la intención del texto y su índice de polarización. Así pues, cada palabra del diccionario tiene asignada una importancia mediante una ponderación, lo que ayuda a una mejor clasificación.

De esta forma, el modelo desarrollado utiliza un puntaje de sentimiento para sugerir decisiones de compra, venta o mantenimiento de una acción.

Con estas condiciones, el modelo de análisis de sentimientos en cuestión logró una precisión del 70.59% en la predicción de la dirección del movimiento diario de las acciones analizadas. Durante la evaluación del rendimiento del modelo, se observó que no hubo cambios significativos en el índice base Nifty Pharma, lo que sugiere que los movimientos de precios observados en las acciones específicas no se debieron a fuerzas más amplias del mercado, es decir, que el mercado en general no estaba experimentando volatilidad o tendencias que pudieran influir en el precio de todas las acciones de manera uniforme.



Gráfica 1: Resultados del estudio

En el gráfico superior se puede ver como el modelo fue capaz de predecir compras (flecha verde), ventas (flecha roja) y holdings (flecha amarilla) en función de distintas noticias que afectaron al precio de la acción de Sun Pharma, como puede ser que la FDA aprobase la comercialización de un nuevo medicamento o una caída en los beneficios del tercer trimestre. El impacto de estas noticias se mide en mayor o menor medida gracias al diccionario elaborado y a las ponderaciones adjudicadas, permitiendo así llegar a la precisión del 70.95%, demostrando el valor añadido que tiene la elaboración de un diccionario personalizado como herramienta en el análisis.

Finalmente, el estudio titulado *A Note on Event Studies in Finance and Management Research*, realizado por De Jong y Naumovska (2016) investiga cómo los anuncios de cambio de nombre corporativo afectan los precios de las acciones de las empresas.

Para llevar a cabo esta investigación, los autores seleccionaron varias empresas que habían anunciado un cambio de nombre y analizaron el comportamiento de sus acciones en un período determinado alrededor de la fecha del anuncio. Durante esta ventana, se observaron las fluctuaciones en los precios de las acciones para identificar cualquier variación anormal.

Los resultados del estudio revelaron que los anuncios de cambio de nombre pueden tener un impacto significativo en los precios de las acciones. No obstante, la magnitud y la dirección de este impacto varían según la percepción de los inversores y la estrategia empresarial subyacente al cambio de nombre. Los autores también subrayaron la importancia de controlar otros eventos que podrían haber influido en los precios de las acciones durante el mismo período, conocidos como "eventos confundidos", para asegurar la precisión de los resultados.

ANÁLISIS

DATOS

En este apartado, se describirán detalladamente las fuentes y la naturaleza de los datos utilizados para llevar a cabo el análisis de eventos relacionado con ExxonMobil. Inicialmente, este estudio integra dos tipos principales de información: los precios de las acciones de Exxon y los factores Fama-French. Los datos de precios proporcionan una vista directa del comportamiento bursátil de ExxonMobil a lo largo del tiempo, mientras que los factores Fama-French permiten ajustar las expectativas de rendimiento por riesgos sistemáticos del mercado y otros factores económicos.

1. Precios

La primera tabla de datos recopila información detallada sobre el comportamiento diario de las acciones de Exxon Mobil Corporation en el mercado de valores. Cada fila representa los datos de un día específico de negociación durante 10 años, comenzando el 2 de enero de 2008 hasta el 29 de diciembre de 2018.

Para la obtención de los datos relativos al rendimiento de las acciones de Exxon, se empleó la biblioteca financiera de Yahoo en Python. El periodo de tiempo seleccionado para el análisis fue desde el año 2007 hasta 2018. Este rango temporal fue elegido con el fin de abarcar un conjunto representativo de datos para realizar una evaluación consistente del rendimiento de la acción.

Nombre de Atributo	Descripción
index	Índice de la fila en el dataset
Date	Fecha de la observación

Open	Precio de apertura del activo en la fecha dada
High	Precio máximo alcanzado por el activo en la fecha
Low	Precio mínimo alcanzado por el activo en la fecha
Close	Precio de cierre del activo en la fecha
Adj Close	Precio de cierre ajustado del activo en la fecha
Volume	Volumen de acciones negociadas en la fecha

Tabla 1: Precios

2. Factores

La tabla de factores financieros contiene datos históricos diarios que describen los componentes del comportamiento del mercado de valores de Fama y French de Exxon, comenzando desde julio de 1926. Este modelo es crucial para analizar el comportamiento de los rendimientos esperados de las acciones en relación con su exposición a tres factores de riesgo económicos generales y las primas de riesgo correspondientes: la prima de riesgo del mercado de acciones (Mkt-Rf), la prima de riesgo que refleja las diferencias en el desempeño entre empresas grandes y pequeñas (SMB), y la prima de riesgo asociada a la estrategia de inversión basada en estilos de activos (HML) (Fama y French, 2004). A continuación, se detallan los atributos incluidos en la tabla:

Nombre de Atributo	Descripción
Unnamed: 0	Fecha de la observación en formato YYYYMMDD.

Mkt-RF	Prima de riesgo de mercado, es decir, el exceso de retorno del mercado sobre la tasa libre de riesgo.
SMB	Retorno adicional de pequeñas empresas sobre grandes empresas (Small Minus Big).
HML	Retorno adicional de empresas de alto valor contable frente a bajo valor contable (High Minus Low).
RF	Tasa de interés libre de riesgo para el período.

Tabla 2: Factores

CÁLCULO DE RETORNOS


En primer lugar, se lleva a cabo una limpieza de datos para poder excluir cualquier valor no válido, o *na*, del análisis. Tras esto, se pasa al cálculo de los retornos. Para ello, se utilizan los precios de cierre ajustados, o *Adj. Close*, los cuales reflejan el valor de la acción después de ajustar por cualquier división de acciones (*stock splits*), dividendos, y otros derechos corporativos que podrían haber ocurrido desde la fecha de cierre original. Esto proporciona una representación más precisa del rendimiento real de la inversión. (Yahoo Finance, s.f.)

De esta forma, se optó por calcular los rendimientos a través del método ‘simple’ en lugar de uno logarítmico debido a que el interés del estudio está en observar los efectos porcentuales directos de los eventos sobre los precios, por lo que los rendimientos simples son suficientes y más intuitivos para interpretar (Hudson & Gregoriou, 2015):

$$\text{Rendimiento Simple} = \frac{P_t - P_{t-1}}{P_{t-1}}$$

(Elaboración propia)

A continuación se presenta un análisis gráfico de la evolución del precio ajustado de cierre de las acciones de ExxonMobil desde enero de 2008 hasta diciembre de 2018. La visualización, realizada con la biblioteca *matplotlib*, proporciona una perspectiva clara de las fluctuaciones en el precio de la acción a lo largo de un periodo de diez años, destacando tanto los picos como los valles que marcan eventos significativos y tendencias generales en el comportamiento del mercado:



Gráfica 1: Evolución Exxon

MODELO DE MERCADO

Una vez se han realizado mayores ajustes sobre los *dataframes*, como ajustes de columnas, fechas e índices, llega el momento de trabajar con los datos hacia el modelo de mercado, para los cuales se ha creado un dataframe llamado 'df_combinado' que cuenta tanto con los

elementos de Precios como de Factores, ordenados temporalmente.

Inicialmente, se consideró emplear un enfoque tradicional de regresión lineal ordinaria (OLS) para calcular las betas de Exxon a los tres factores de Fama y French. Este método, que divide los datos en conjuntos de entrenamiento y prueba, permite una evaluación robusta y general del modelo en todo el conjunto de datos. Utilizando este enfoque, se podría obtener un modelo predictivo basado en la relación promedio observada durante el periodo estudiado. Es decir, con unos únicos estimadores o betas para todo el modelo.

Sin embargo, el enfoque de regresión *rolling* es el más adecuado. Este método permite calcular las betas utilizando únicamente la información disponible en cada momento, evitando el uso de datos futuros que podrían comprometer la validez del análisis. Para el análisis, se emplea una ventana temporal de dos años, lo que facilita la captura de la dinámica y volatilidad de las relaciones entre las variables a lo largo del tiempo. En contextos de alta volatilidad, como en estudios de evento donde se analizan los efectos de acontecimientos específicos sobre los rendimientos de las acciones, es crucial recalibrar constantemente los coeficientes de regresión para reflejar los cambios recientes en el mercado. (Coudert & Mabille, 2015).

De esta forma, en el análisis, se designa la columna Return del DataFrame como la variable dependiente Y , representando los retornos diarios de las acciones. Las variables independientes X incluyen los tres factores de riesgo descritos por Fama-French, anteriormente mencionados: Mkt-RF, SMB y HML. A estas variables independientes se les añade una constante utilizando la función `add_constant` de statsmodels.

Seguidamente, se configura una ventana móvil de dos años para el análisis de regresión rolling, lo que equivale aproximadamente a 504 observaciones, considerando que el mercado opera cerca de 252 días al año. Esta ventana móvil permite actualizar los parámetros del modelo de forma dinámica, capturando así variaciones en las relaciones de los factores a lo largo del tiempo, lo que es particularmente útil para estudiar periodos de alta volatilidad o

cambios estructurales en el comportamiento del mercado.

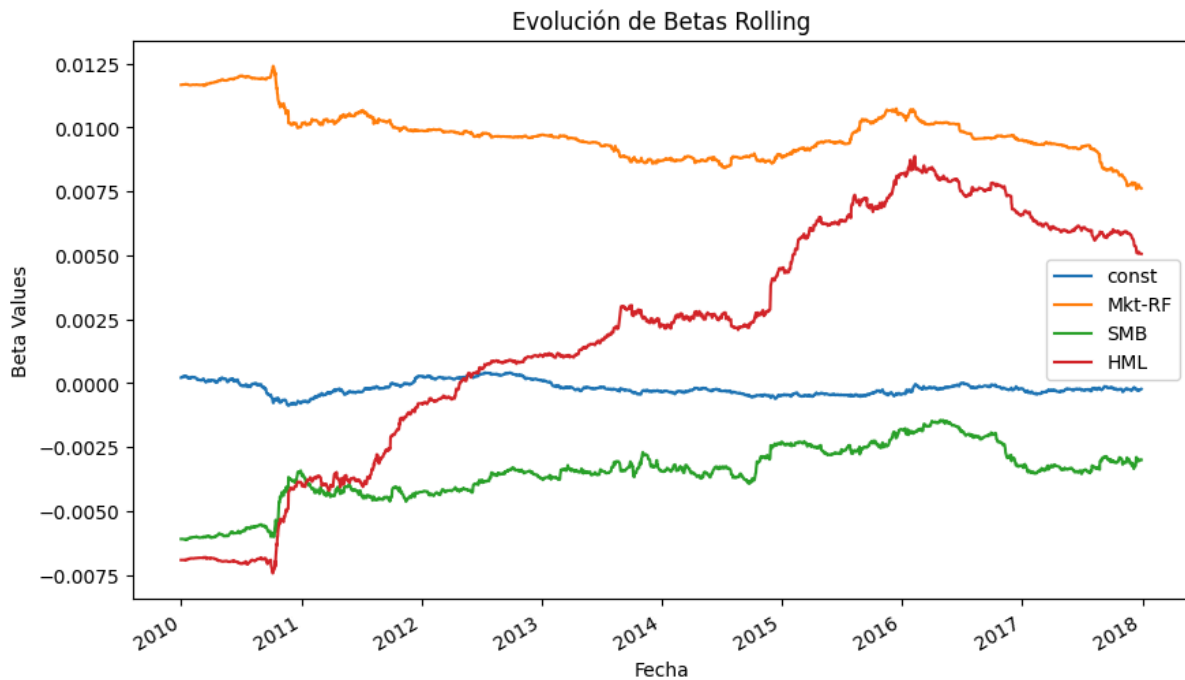
De esta forma, utilizando la clase RollingOLS de statsmodels, se implementa la regresión lineal con ventana móvil sobre las series temporales definidas. El ajuste del modelo se realiza a partir de la primera ventana de 504 días, y luego se actualiza continuamente a medida que se disponen de nuevos datos. Estos primeros dos años de datos “perdidos” son lo que se conoce como período *burn-in*. Este enfoque permite evaluar la estabilidad y la variabilidad de los coeficientes β a lo largo del tiempo (Johansen, 2010).

Así pues, el modelo de regresión lineal va a permitir obtener dos conjuntos de resultados principales:

1. **Betas (Coeficientes del Modelo):** Estos son los coeficientes estimados para cada uno de los factores en las variables independientes (X), que en este caso incluyen Mkt-RF, SMB, y HML, además de una constante. Los Betas representan la sensibilidad de los retornos de las acciones respecto a cada uno de estos factores de riesgo calculados para Exxon. En otras palabras, muestran cuánto se espera que cambie el retorno de la acción por cada unidad de cambio en el factor de riesgo correspondiente, ajustado por las condiciones del mercado durante el periodo que cubre cada ventana móvil (Fama & French, 2004).
2. **Retornos Anormales (ARt):** Tal y como se explicó previamente, se calculan como la diferencia entre los retornos observados y los retornos del modelo. Son esencialmente el retorno que excede o no alcanza lo que se esperaría basado en los riesgos asumidos, según los factores modelados (Sorescu et. al, 2017).

BETAS

Las betas diarias para cada término pueden ser visualizadas en el gráfico de a continuación:



Gráfica 2: Evolución Betas

Este gráfico busca representar la evolución de los cuatro parámetros, o betas, calculados diariamente durante los ocho años posteriores al período *burn-in*. A simple vista es complicado sacar conclusiones, por lo que se procede estudiar los valores concretos de volatilidad de los betas, obteniendo los siguientes:

Volatilidad de las Betas:

<i>const</i>	0.000261
<i>Mkt-RF</i>	0.000939
<i>SMB</i>	0.001084
<i>HML</i>	0.004667

- a. **Mkt-RF:** Muestra una tendencia generalmente estable hasta mediados de 2014, seguida de un aumento significativo hasta finales de 2016, y luego experimenta una disminución.
- b. **SMB:** Se observa que esta beta se mantiene relativamente estable y cerca de cero, lo

que sugiere que la diferencia de rendimiento entre empresas pequeñas y grandes no tuvo un impacto significativo en los retornos de ExxonMobil durante el período analizado.

- c. **HML:** Esta beta también muestra cambios notables, particularmente un aumento desde 2014 hasta 2017. Esto podría interpretarse como un aumento en la sensibilidad de los retornos de ExxonMobil a las diferencias en el valor contable relativo durante este período. HML posee la volatilidad más alta de las cuatro, tal y como se puede ver en el gráfico.

- d. **Const:** La línea correspondiente a la constante muestra una estabilidad relativa con variaciones menores a lo largo del tiempo, lo que indica que la parte no explicada por los factores de riesgo se mantiene constante.

EVENT STUDY

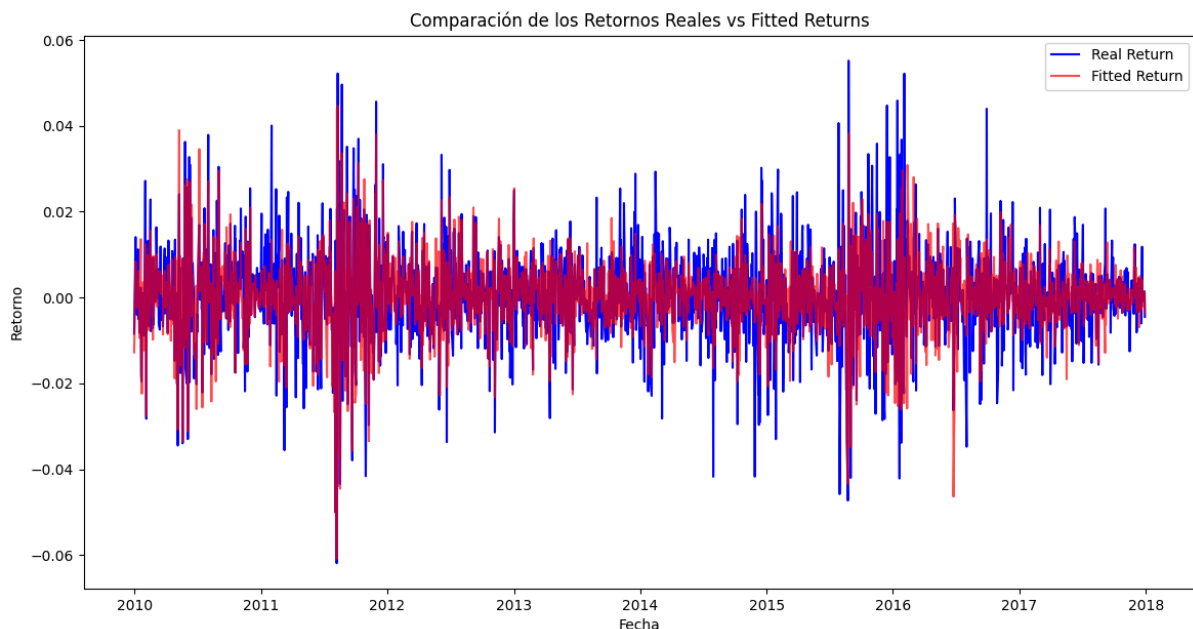
Para continuar con el estudio, es fundamental realizar el cálculo de los *abnormal returns* o retornos anormales. Para ello, se procede a calcular los retornos predichos. Esto se hace ajustando un bucle que recorre desde el primer índice válido hasta el final del conjunto de datos. Para cada iteración del bucle, se extraen los coeficientes de la ventana correspondiente y se toman los valores de las variables independientes del último día de esa ventana. Luego, se realiza el cálculo del valor ajustado para ese día específico utilizando el producto punto entre los coeficientes y los valores de las variables independientes, lo que resulta en el retorno predicho para ese día.

Estos retornos predichos se recopilan en una lista y luego se asignan al DataFrame original, creando así una nueva columna. Posteriormente, el código calcula los retornos anormales como la diferencia entre los retornos reales observados y los retornos predichos o *fitted return*.

Debido a que el impacto del evento puede tener influencia sobre los retornos anormales más allá de durante la propia fecha, se ha desarrollado y aplicado una función específica destinada a calcular el retorno anormal acumulativo, o CAR, ajustado por los días hábiles efectivos dentro de la ventana temporal definida. Este cálculo comienza seleccionando un periodo de tres días centrado en cada fecha del conjunto de datos.

Para ello, se calcula la suma de los retornos anormales que ocurrieron durante estos días. Importante destacar, esta suma se normaliza dividiéndola por el número de días hábiles efectivos, permitiendo así ajustar el valor de los retornos anormales según la cantidad real de días operativos en la ventana considerada. Este paso asegura que el valor de refleje de manera más ajustada la intensidad y la dirección del impacto financiero durante el periodo analizado.


De esta forma, se pueden plasmar sobre un gráfico los retornos reales y los *Fitted Returns* calculados, para poder tener una visión sobre las principales diferencias, tal y como se puede ver a continuación, donde el rojo representa los retornos diarios calculados por el modelo y los azules los retornos reales:



Gráfica 3: Comparación retornos

Para representar la diferencia, se usa el gráfico de a continuación. Utiliza áreas rellenas para

destacar las diferencias entre los retornos reales y los ajustados. Las áreas verdes indican los periodos en los cuales los retornos reales exceden los retornos ajustados (diferencias positivas), mientras que las áreas rojas muestran los periodos en los cuales los retornos ajustados son mayores que los reales (diferencias negativas):



Gráfica 4: Diferencias entre retornos

Una vez se tienen los retornos anormales, es necesario obtener una lista de eventos para poder realizar el estudio de eventos *per se*. Para ello, se parte de una base de datos confeccionada por Fernando Santana (2023) en su Trabajo de Fin de Grado *The effect of financial news on stock prices: insights from NLP techniques*. Dichas bases de datos contienen información sobre noticias de prensa tanto del Financial Times como del Wall Street Journal sobre Exxon así como la fecha y el *sentiment score* de cada una de las noticias analizadas. Dichos datos se obtuvieron mediante la optimización de un modelo BERT pre entrenado:

Nombre de Atributo	Descripción
--------------------	-------------

Date	Fecha de la observación en formato YYYYMMDD.
total_sentiment	Medida cuantitativa del sentimiento expresado en las noticias.
major_sentiment	Categoriza el sentimiento mayoritario asociado a la misma fecha que el total_sentiment, ya sea <i>positive</i> o <i>negative</i> .

Tabla 3: Sentimientos

Para determinar cuántos de los eventos tienen sentimientos con efectos significativos en el mercado y, por ende, si los retornos anormales difieren significativamente de cero, se desarrolla una función que realiza un análisis detallado para cada fecha de evento específica.

El primer paso es examinar la volatilidad de los retornos durante un período definido alrededor de cada evento. Esto se hace calculando la desviación estándar de los retornos anormales en una ventana temporal que abarca desde $t - w$ hasta $t + w$, donde t es el día del evento y w es el número de días antes y después del evento (en este caso, 10 días).

La desviación estándar, σ , de los retornos anormales, R , se calcula como:

$$\hat{\sigma}_{AR} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (AR_{i,t} - \overline{AR}_t)^2}$$

(Yin et al., 2018)

Donde R_i son los retornos anormales en el día i , R es la media de los retornos anormales, y N es el número total de días en la ventana.

Una vez calculada la desviación estándar, se procede a examinar la diferencia de los retornos anormales entre el día del evento AR_t y el día siguiente AR_{t+1} . La diferencia, d , se estandariza para crear una medida comparativa independiente de la escala del mercado:

$$d = \frac{AR_{t+1} - AR_t}{\sigma}$$

Esta estandarización convierte la diferencia en un z score, que indica cuántas desviaciones estándar se aleja AR_{t+1} de AR_t . Pese a que la fórmula original del z score incluye la diferencia con la media (Curtis, 2016), se ha considerado la elección de utilizar una fórmula modificada ya que se enfoca específicamente en los cambios provocados por eventos particulares, capturando de manera directa el impacto inmediato de estos en los rendimientos de las acciones. Esto es crucial cuando el interés principal es medir cómo un evento específico.

El z score obtenido se compara luego con una distribución normal estándar para evaluar su significancia estadística. El objetivo es determinar si la diferencia observada es lo suficientemente extrema como para ser considerada estadísticamente significativa (Cheadle et. al, 2003). Esto se hace calculando el p valor asociado con el z score:

$$\text{valor-p} = 2 \times (1 - \text{CDF}_{\text{normal}}(|d|))$$


Donde CDF normal es la función de distribución acumulativa de una distribución normal estándar. El factor de 2 se utiliza para obtener una prueba de dos colas, ya que hay interés tanto en desviaciones positivas como negativas.

Si el p valor es menor que un umbral predefinido (0.05), entonces la diferencia entre AR_t y AR_{t+1} se considera estadísticamente significativa. Esto implica que el sentimiento de la noticia podría haber tenido un impacto real en los retornos del mercado y el retorno

anormal es significativo, al menos en el contexto temporal inmediato al evento. Es decir, que si el valor estadístico fuese menor que 0.05 se rechazaría la hipótesis nula de que los valores observados se deban al azar.


Financial Times

Comenzando por el análisis de eventos a partir de los datos del Financial Times sobre Exxon, se registraron un total de 463 noticias y sus respectivos *sentiment scores*, así como su clasificación en noticias positivas o negativas en función de dicha puntuación.




Gráfica 5: Comparación noticias FT

Tal y como se ve en el diagrama superior, de las 463 noticias totales (donde el 55.7% son negativas y el 44.3% positivas), 236 han sido clasificadas como que su *sentiment score* ha tenido efecto en el mercado, de las cuales 133 (56.4%) tienen la etiqueta de evento negativo y tan solo 103 (43.6%) de positivo.



Gráfica 6: Desglose noticias FT

De forma similar, en el gráfico superior se puede ver el desglose de eventos con *scores* que hayan tenido impactos significativos por si dichos *scores* son positivos o negativos. De esta forma, un 50.3% de los eventos calificados como positivos han tenido efecto frente a un 51.63% de los negativos.




Gráfica 7: Gráfico violín FT

Por otro lado, en el gráfico de violín superior, se analiza la distribución del sentimiento total en las dos categorías principales, positivo y negativo, previamente establecidas. El eje

horizontal, que muestra un espectro de -1.0 a 1.0, refleja el *sentiment score* desde completamente negativo hasta completamente positivo, con el cero representando una posición neutral. El eje vertical clasifica los datos entre sentimientos positivos y negativos.

La categoría negativa, ilustrada en naranja, muestra que la distribución de sentimientos positivos es más amplia en el centro, lo que indica que hay una gran variabilidad, pero tienden a agruparse ligeramente más cerca del cero que hacia el extremo negativo del espectro. En contraste, el violín verde también muestra una buena parte de su anchura cerca del centro, aunque con una forma que se extiende de manera similar hacia valores cercanos al 1.

A continuación, se han seleccionado las fechas de los 236 eventos importantes detectados. Dichos eventos fueron relacionados con su fecha hábil más cercana y no con la fecha exacta de publicación de la noticia. Esto se debe a que los retornos solo se calculan respecto a los días hábiles. Es decir, que si se asociasen directamente por la misma fecha, al haber noticias publicadas en días no hábiles como fines de semana o festivos, se perdería información. Como para una misma fecha puede haber más de una noticia que genere efecto, se optó por realizar la media de los sentimientos, pasando de 236 eventos a un total de 202. De esta forma, se pueden plasmar los eventos con el precio de cierre:



Gráfica 8: Posición eventos FT

Los puntos rojos en el gráfico indican aquellos días en los que las noticias cuyo *sentiment score* negativo tuvo un impacto considerable en el valor de las acciones según el análisis estadístico que se llevó a cabo, mientras que los verdes representan aquellos eventos con *sentiment scores* positivos con impacto importante.

A simple vista, se pueden apreciar la presencia de eventos en picos significativos, como a finales del 2012. Sin embargo, para poder tener una conclusión más clara y objetiva, se decidió aplicar un *t-test* sobre los retornos acumulados.


La hipótesis nula de la prueba *t* que se va a realizar postula que no habría diferencias significativas entre los retornos anormales observados durante los días de evento y un retorno normal de cero.

Así pues, el *t-statistic* obtenido fue de -7.24, indicando que los retornos anormales promedio en los días de evento fueron significativamente menores que cero. Esto sugiere que los eventos analizados, en promedio, tuvieron un efecto negativo sobre el valor de las

acciones de Exxon. Además, el p valor asociado a este estadístico fue de $9.57e-12$, lo que es sustancialmente menor que el umbral de 0.05 comúnmente utilizado para determinar significancia estadística. Este p valor bajo implica una fuerte evidencia contra la hipótesis nula y respalda la afirmación de que los eventos estudiados afectaron negativamente los precios de las acciones.

Adicionalmente, se realizó un análisis similar utilizando únicamente los retornos anormales en lugar de los acumulados. Este análisis resultó en un t-statistic de -4.59, lo que también indica que los retornos anormales fueron significativamente menores que cero. El p valor asociado fue de $7.79e-06$, nuevamente mucho menor que el umbral estándar de 0.05. Este resultado refuerza la evidencia de que los eventos específicos tuvieron impactos negativos inmediatos sobre el valor de las acciones de Exxon, corroborando los hallazgos del análisis acumulado.

Seguidamente, se puede plasmar la información sobre los eventos de una forma diferente para tener diferentes perspectivas, como a continuación:



Gráfica 9: Retornos Anormales FT

En el gráfico superior, se muestra claramente la fluctuación de los retornos anormales a lo largo del tiempo. La línea azul representa la magnitud de estos retornos, donde valores por encima de la línea de cero indican retornos anormales positivos y valores por debajo indican retornos negativos. Los puntos rojos, al igual que en el gráfico anterior, marcan los días donde el *sentiment score* negativo fue significativo, mientras que los verdes muestran lo mismo para los positivos. Los eventos con sentimiento negativo a menudo coinciden con los días de bajos retornos anormales, sugiriendo un impacto negativo en el mercado, mientras que los días con sentimiento positivo no muestran una tendencia clara y consistente. Esto indica que el mercado puede ser más sensible a las noticias negativas.

A lo largo del periodo estudiado, se puede observar como varios puntos coinciden con los picos más altos y los valles más profundos en la serie temporal, sugiriendo que las noticias en esos días fueron recibidas con reacciones fuertes por parte del mercado.

Por otro lado, y como parte del análisis, se buscó comparar los retornos anormales de los días que contaban con un evento y los días sin el, utilizando de nuevo una prueba de *t-statistic*, pero esta vez de muestras independientes. Básicamente, se define una ventana de 120 días alrededor de cada evento con un *sentiment score* significativo y se compara el comportamiento del mercado durante estos días con el de los días normales sin eventos. Utilizando la prueba T de Student, se calcula tanto la *t statistic* como el *p* valor para evaluar la significancia estadística de las diferencias observadas en los retornos anormales entre estos dos grupos. La *t-statistic* de muestras independientes compara las medias de dos grupos independientes para determinar si existe una diferencia estadísticamente significativa entre ellas, a diferencia de la prueba estándar, que mide si la media de una muestra difiere significativamente de un valor conocido o teórico (Kent State University Libraries, s.f.).

Los resultados de la prueba mostraron un *t statistic* de -16.31 y un *p value* bajo de 2.135e-59. El *t statistic* negativo indica que los retornos anormales promedio en los días de evento son significativamente menores que los de los días no evento. Este resultado es

estadísticamente significativo, como lo demuestra el *p-value* prácticamente nulo, lo que indica que, generalmente, hay un impacto claro y negativo de los eventos en los retornos anormales del mercado, indicando que los eventos tienden a estar asociados con movimientos de mercado adversos.

A continuación se puede ver una tabla con diversos datos estadísticos sobre los retornos anormales en fechas donde han habido eventos que han tenido un impacto significativo, dividiéndolos en Eventos Positivos (*sentiment score* > 0) y Eventos Negativos (*sentiment score* < 0):

Estadísticas	Eventos Positivos (CAR)	Eventos Negativos (CAR)	Eventos Positivos (AR)	Eventos Negativos (AR)
Media RA	-0.001590	-0.002649	-0.0002252	-0.002900
Desviación Est.	0.003828	0.004624	0.007304	0.008709
Mínimo	-0.010980	-0.016437	-0.023262	-0.034512
25%	-0.003811	-0.005075	-0.006645	-0.007831
50% (Mediana)	-0.001409	-0.002192	0.001687	-0.002208
75%	0.000723	0.000550	0.002566	-0.001732
Máximo	0.007705	0.007669	0.018598	0.015071

Tabla 4: Estadísticas eventos FT

Observando los eventos positivos, se puede ver que, a pesar de su naturaleza, el retorno medio anormal es ligeramente negativo, con un promedio de -0.001590 en los retornos acumulados y un -0.002252 en AR. Esto sugiere que incluso los eventos percibidos como positivos pueden no tener el impacto positivo esperado en los precios de las acciones, o que hay otros factores que contrarrestan estos efectos positivos en el mercado.

La desviación estándar para los eventos positivos indica una volatilidad moderada en ambos casos durante estos eventos. Los valores extremos en los eventos positivos varían significativamente, con el mínimo en -0.0109 y el máximo en 0.0077 para CAR y mínimo en -0.0232 y máximo en 0.018598 para AR, lo que refleja una amplitud considerable en los resultados de estos eventos.

Por otro lado, los eventos con sentimientos negativos presentan un promedio aún más bajo, de -0.002649 en CAR y de -0.002900 para AR, lo que es coherente con la expectativa de que noticias o eventos negativos podrían tener un impacto adverso en el mercado. La desviación estándar para los eventos negativos es ligeramente superior a la de los eventos positivos, lo cual es indicativo de una mayor dispersión en los retornos anormales, posiblemente reflejando una mayor incertidumbre o reacciones emocionales más intensas del mercado frente a noticias negativas.


Los eventos negativos también muestran una gama más amplia de retornos anormales acumulativo, desde un mínimo de -0.016437 hasta un máximo de 0.007669 , y desde un mínimo de -0.034512 hasta un máximo de 0.015071 en el caso de los retornos anormales, lo que podría interpretarse como una mayor sensibilidad del mercado a las malas noticias, donde los inversores podrían reaccionar de manera más drástica, ya sea vendiendo en pánico o, en algunos casos, comprando en bajadas pronunciadas.

Al comparar CAR y AR, se hace evidente que mientras CAR ofrece una vista del impacto acumulado de eventos sobre un período extendido, mostrando una visión más "suavizada" de la reacción del mercado, AR proporciona un vistazo más inmediato y reactivo, a menudo caracterizado por mayor volatilidad.

De manera adicional, si se realiza un cálculo de *t statistic* para una muestra sobre los retornos anormales de eventos con sentimientos positivos y negativos, se puede obtener una visión estadísticamente significativa sobre cómo estos eventos afectan al mercado. Para los eventos positivos, la *t statistic* obtenida de -2.842 indica que los retornos anormales son significativamente diferentes de cero, con un p valor de 0.0056. Esto confirma que, en promedio, los eventos positivos están asociados con un impacto negativo en los retornos, contrario a la intuición inicial que podría sugerir que los eventos positivos deberían llevar a aumentos en los precios de las acciones.

Para los eventos negativos, la situación es más pronunciada. Con un *t statistic* de -3.602 y un p valor extremadamente bajo de 0.00047, los resultados refuerzan la idea de que los eventos negativos tienen un efecto significativamente negativo en los retornos del mercado. Este es un hallazgo esperado, ya que generalmente se considera que las noticias negativas provocan caídas en el mercado, pero el nivel de significancia estadística subraya cómo de robusto es este efecto.

Finalmente, se procede a ilustrar a continuación la distribución de los retornos anormales acumulados clasificados por el tipo de sentimiento de las noticias asociadas. Los retornos anormales derivados de eventos con sentimiento positivo se muestran en azul, mientras que los de eventos con sentimiento negativo en naranja. Se utilizó un histograma para cada grupo con el fin de visualizar la frecuencia de diferentes rangos de retorno. Las medias de cada conjunto se indican mediante líneas discontinuas azul y naranja, respectivamente, siendo la línea vertical gris representa el punto de retorno anormal cero:



Gráfica 10: Distribución retornos anormal FT


De manera visual se pueden corroborar los análisis estadísticos previos. El gráfico muestra la distribución de los retornos anormales acumulativos para eventos con sentimientos positivos y negativos, empleando una densidad relativa para comparar ambas distribuciones en una escala común. Esta representación permite observar cómo se distribuyen los retornos anormales en relación con el tipo de sentimiento durante los eventos financieros específicos. Los bins en el histograma representan rangos de retornos anormales, mientras que la altura de cada barra refleja la proporción de eventos que caen dentro de esos rangos, normalizada por el número total de eventos en cada categoría.

Se observa que la media de los retornos para eventos positivos es ligeramente negativa, aproximadamente -0.0016 , mientras que para los eventos negativos es aún más baja, alrededor de -0.0026 , tal y como se pudo ver previamente. Esto indica que, en promedio, los eventos tanto positivos como negativos tienden a asociarse con una disminución en el valor del activo, aunque la magnitud de esta disminución es algo mayor en eventos negativos. La presencia de líneas verticales discontinuas indica las medias de cada distribución.

Wall Street Journal

A continuación, se abordará el análisis de los sentimientos relacionados con las noticias del Wall Street Journal. Después de evaluar exhaustivamente los datos derivados del Financial Times, este cambio de fuente busca corroborar los hallazgos previos o revelar nuevas tendencias y patrones en cómo las noticias influyen los retornos anormales del mercado.


En primer lugar, se clasificaron las 481 noticias del Wall Street Journal y sus respectivos sentiment scores:



Gráfica 11: Comparación noticias WSJ

De las 481 noticias totales (66.5% negativas y 33.5% positivas), 233 fueron clasificadas como noticias de impacto, siendo 76 (32.6%) de *sentiment score* positivo y 157 (67.4%)


negativo. A continuación, se puede ver el desglose por tono:



Gráfica 12: Desglose noticias WSJ

A simple vista, se puede observar como las noticias del Wall Street Journal tienden a ser mucho más negativas (un 66.5%) que en el caso del Financial Times, donde el porcentaje de negativas disminuye a un 55.7%. Sin embargo, en ambos periódicos el porcentaje de noticias con efecto en el desglose por tono es similar, en torno a un 50%.

Si se realiza un gráfico de violín como anteriormente, se obtienen los siguientes datos:




Gráfica 13: Gráfico violín WSJ

Se puede observar que el sentimiento positivo tiende a tener una distribución más amplia y

centrada alrededor de valores ligeramente positivos, mientras que el sentimiento negativo parece concentrarse más cerca del centro pero se extiende hacia valores más extremos en ambas direcciones. A simple vista se puede ver como el tono del Wall Street Journal parece más moderado que en el caso del Financial Times, donde había más noticias cercanas al -1 y al +1.

A continuación, se optó por plasmar los eventos en un gráfico de evolución del precio de cierre, donde se pueden ver ciertas tendencias asociadas con los signos de los eventos:




Gráfica 14: Posición eventos WSJ

De misma manera que en el análisis del Financial Times, se llevó a cabo un cálculo de fecha hábil más cercana para los eventos en días no hábiles y de cálculo de retornos normales acumulados.

De esta forma, al realizar el t-test para ver si la media de los retornos anormales acumulados en los días con eventos catalogados de impacto difiere significativamente de cero, se obtiene un *t-statistic* negativo de -7.084 (CAR) y un p valor de 2.156e-11 y un

t-statistic de -2.93 con un p valor 0.037 para AR, indicando que los eventos asociados con el sentimiento capturado en esos días tienden a tener un impacto negativo en el valor de mercado. Estos resultados obtenidos por el WSJ son muy similares a los del FT, donde los *t*-statistics eran de -7.24 (CAR) y -4.59 (AR).

De manera adicional, a continuación se pueden ver los resultados de los retornos anormales diarios con los eventos indicados:



Gráfica 15: Retornos Anormales WSJ

Similar a como ocurría con el diario anterior, los eventos con sentimiento negativo a menudo parecen coincidir con las fechas en las que los retornos anormales son más bajos mientras que los días con sentimiento positivo no se puede visualizar un patrón tan claro.

Siguiendo con el análisis que ya se realizó para el Financial Times, se llevó a cabo un *t*-test independiente para comparar los retornos anormales entre los días de evento y los no evento para determinar si existe una diferencia significativa en los retornos anormales causados por los días con eventos de impacto en comparación con los días normales o de no

evento. Los resultados para el WSJ reflejaron un *t-statistic* de -11.23 y un p valor de 3.53e-29, frente al -16.31 del FT. Estos resultados están en línea con el impacto negativo que se pudo ver en el Financial Times, donde se obtuvieron resultados más bajos todavía.

Al desglosar las estadísticas sobre los retornos anormales en función de *sentiment score* del evento se obtiene la siguiente tabla, a la que se le ha añadido los datos del Financial Times para poder realizar una mejor comparación:

Estadísticas	Eventos Positivos (CAR)	Eventos Negativos (CAR)	Eventos Positivos (AR)	Eventos Negativos (AR)
Media RA	-0.001590	-0.002649	-0.002391	-0.001438
Desviación Est.	0.003828	0.004624	0.007421	0.009268
Mínimo	-0.010980	-0.016437	-0.018816	-0.034512
25%	-0.003811	-0.005075	-0.008119	-0.006328
50% (Mediana)	-0.001409	-0.002192	-0.00102	-0.001475
75%	0.000723	0.000550	0.001884	0.004358
Máximo	0.007705	0.007669	0.014391	0.023155

Tabla 5: Estadísticas eventos WSJ

Para los eventos positivos, la media de los retornos anormales en el WSJ fue de -0.001710, ligeramente superior a la del FT que registró -0.001590. En contraste, para los eventos negativos, la media en el WSJ fue -0.002400, comparativamente más alta que en el FT, que fue de -0.002649. Estos datos para el Wall Street Journal reafirman la idea de que pese a

haber *sentiment scores* positivos, el retorno anormal tiende a ser negativo.

La desviación estándar para ambos tipos de eventos en el WSJ mostró una variabilidad similar a la del FT, con valores levemente superiores en el WSJ para los eventos positivos y ligeramente inferiores para los negativos. Esto podría indicar que la respuesta del mercado a las noticias del WSJ puede ser, en promedio, un poco más volátil para las noticias positivas y menos para las negativas en comparación con el FT.


En cuanto a los extremos observados (mínimos y máximos), los datos del Wall Street Journal se encuentra en rangos similares.

Por otro lado, al realizarse *t tests* para evaluar si los retornos anormales de eventos con sentimiento positivo y negativo difieren significativamente de cero, tal y como se hizo anteriormente, los resultados indican que tanto para los eventos positivos como para los negativos, los retornos son significativamente menores que cero. Específicamente, la *t statistic* para eventos positivos fue de -3.556 con un *p* valor significativo de 0.000680, mientras que para eventos negativos fue de -6.138 con un valor *p* extremadamente bajo de 8.58e-09. En comparación con los resultados obtenidos para el Financial Times, las *t statistic* para eventos positivos y negativos son ligeramente más bajas en el caso del WSJ, pero los valores *p* son similares. Sin embargo, si dicho análisis se lleva a cabo con los retornos anormales no acumulados, se obtiene para los eventos positivos una *t statistic* de -2.715 con un *p* valor de 0.0083 y, en los negativos, un *t statistic* de -1.82 (superior al de los eventos positivos) y un *p* valor de 0.071, lo que significa que no hay suficiente evidencia estadística para rechazar la hipótesis nula.

Esto sugiere que, aunque hay una tendencia hacia un impacto negativo de los eventos, al tender los retornos anormales no acumulativos a ser más sensibles a lo inmediato, puede ser que no se esté capturando completamente el impacto duradero de un evento.

Finalmente, el gráfico de histograma inferior ilustra la distribución de los retornos anormales

acumulativos para eventos de noticias clasificados por sentimiento positivo y negativo.



Gráfica 16: Distribución retornos anormal FT

Tal y como sucedía con el caso del Financial Times, el hecho de que ambas medias sean negativas puede indicar una tendencia del mercado a reaccionar adversamente a las noticias, independientemente de su naturaleza positiva o negativa, reflejando posiblemente una predisposición del mercado hacia la aversión al riesgo o la reacción a la incertidumbre asociada con los eventos de noticias.

CONCLUSIONES

Este trabajo de fin de grado se centró en evaluar el impacto de los eventos en los retornos anormales de las acciones, utilizando como fuente de datos dos importantes periódicos financieros, el Wall Street Journal (WSJ) y el Financial Times (FT). La investigación abordó cómo las noticias, dependiendo de su sentimiento (positivo o negativo), afectan el valor de ExxonMobil. De esta forma, se pudieron obtener las siguientes conclusiones:

1. **Impacto Significativo de las Noticias:** Los resultados demuestran que tanto las noticias positivas como las negativas tienen un impacto estadísticamente significativo en los retornos anormales, con las noticias negativas mostrando un efecto más pronunciado. Este fenómeno refleja la sensibilidad del mercado a las noticias adversas, posiblemente debido a una mayor aversión al riesgo por parte de los inversores.

2. **Comparación entre Fuentes de Noticias:** Al comparar los efectos de las noticias provenientes del Financial Times y del Wall Street Journal, se observa una consistencia en los patrones de reacción del mercado. Sin embargo, las pruebas estadísticas indican que no hay diferencias significativas en la magnitud del impacto entre ambas fuentes, sugiriendo que la reacción del mercado está más influenciada por el contenido de la noticia que por su origen.

3. **Distribución de los Retornos Anormales:** Los análisis de distribución muestran que los retornos anormales tienden a ser negativos tanto para noticias positivas como negativas, lo que podría indicar que el mercado responde a la incertidumbre subyacente de cualquier evento, independientemente de su tono.

4. **Comparación entre Periódicos:** Al comparar los efectos de las noticias reportadas por el WSJ y el FT, se encontraron diferencias sutiles en la magnitud de los retornos anormales y las estadísticas asociadas. Los datos indican que las reacciones del mercado pueden ser ligeramente más moderadas para las noticias del WSJ en comparación con el FT. Este hallazgo puede estar influido por diferencias culturales y de percepción entre los lectores

predominantemente estadounidenses del WSJ y los internacionalmente diversificados del FT.

5. Comparación entre AR y CAR: Los Retornos Anormales (AR) han demostrado ser útiles para capturar respuestas inmediatas del mercado y suelen mostrar mayor volatilidad, mientras que los Retornos Anormales Acumulados (CAR) han proporcionado una perspectiva más completa del impacto sostenido de los eventos, mostrando significancia estadística más alta en pruebas *t-test*, lo que sugiere que CAR es más efectivo para evaluar impactos duraderos sobre precios de acciones. Ambos métodos juntos ofrecen una visión completa, capturando tanto las reacciones inmediatas como las consecuencias a largo plazo de eventos en el mercado.

6. Implicaciones para Inversores y Gestores: Para los inversores y los gestores de carteras, estos hallazgos resaltan la necesidad de monitorear de cerca el flujo de noticias y su posible impacto en los precios de las acciones. Integrar herramientas de análisis de sentimiento y eventos en la gestión de carteras podría mejorar significativamente la capacidad de anticipar y mitigar los efectos negativos de las noticias en los activos.

LIMITACIONES DEL ESTUDIO

El presente trabajo de fin de grado, pese a haber sido exhaustivo en su enfoque y análisis, presenta varias limitaciones que deben ser reconocidas a la hora de analizar los resultados y conclusiones obtenidas:

Selección de Fuentes de Datos: El estudio se centró exclusivamente en dos importantes periódicos financieros, el Wall Street Journal y el Financial Times. Aunque ambos son altamente reconocidos, la elección limitada de fuentes puede no capturar completamente la gama de influencias mediáticas en el mercado. Medios menos tradicionales o plataformas digitales, como blogs financieros, redes sociales y sitios de noticias en línea, también juegan un papel significativo en la formación de la percepción del mercado y no fueron considerados en este estudio.

Generalización de Resultados: Los resultados obtenidos se basaron únicamente en ExxonMobil, una gran multinacional en la industria del petróleo y gas. Esto limita la capacidad de generalizar los hallazgos a otras empresas, industrias o contextos económicos que pueden no compartir las mismas características o reacciones del mercado.

Interpretación del Sentimiento: La interpretación y clasificación del sentimiento de las noticias se hizo a través de un enfoque automatizado, que, aunque eficiente, puede no captar completamente la complejidad o el matiz de cómo las noticias son percibidas por los inversores humanos.

Modelo: El modelo Fama-French de tres factores no captura todos los posibles factores de riesgo que pueden influir en los retornos de las acciones. Factores adicionales o variables macroeconómicas específicas, podrían proporcionar una explicación más completa de los retornos anormales. Además, Los modelos estadísticos, incluyendo OLS, vienen con supuestos inherentes como linealidad, normalidad de los errores, y homocedasticidad. Si estos supuestos no se cumplen, los resultados del modelo podrían ser sesgados o inconsistentes.

RECOMENDACIONES PARA FUTURAS INVESTIGACIONES

Inclusión de más factores de riesgo: Ampliar el modelo Fama-French para incluir factores adicionales. Esto podría ayudar a capturar mejor la variabilidad en los retornos de las acciones y ofrecer una visión más completa del impacto de diferentes tipos de riesgo.

Comparación intersectorial e internacional: Extender el análisis a otras empresas dentro del mismo sector o a diferentes sectores podría ayudar a entender si los patrones observados son específicos de ExxonMobil o si son comunes en otras empresas. Además, realizar estudios similares en diferentes mercados internacionales podría revelar cómo varían los impactos de las noticias según el contexto geográfico y económico.

Análisis de otros medios de comunicación: Explorar el efecto de las noticias provenientes de diferentes medios de comunicación además del Financial Times y Wall Street Journal. Esto incluiría medios digitales, redes sociales, y publicaciones menos formales para ver cómo diferentes fuentes de información impactan los retornos de las acciones.

Estudios cualitativos: Complementar los análisis cuantitativos con investigaciones cualitativas que exploren las razones detrás de las reacciones del mercado a ciertos tipos de noticias. Entrevistas con inversionistas, analistas y otros participantes del mercado podrían ofrecer insights sobre cómo se perciben y actúan sobre las noticias.

ANEXOS

DECLARACIÓN DE USO DE HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL GENERATIVA EN TRABAJOS FIN DE GRADO

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Francisco Javier Vázquez Visos, estudiante de Administración y Dirección de Empresas y Análisis de Negocios / Business Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Influencia del Sentimiento de las Noticias en los Retornos Anormales de ExxonMobil: Un Análisis Comparativo entre el Financial Times y el Wall Street Journal", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
 2. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
 3. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
 4. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
-

5. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
6. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 19 de junio de 2024

Firma: Francisco Javier Vázquez Visos

CÓDIGO

```
import pandas as pd
import numpy as np
from datetime import datetime, timedelta
import psycopg2
import matplotlib.pyplot as plt
from dateutil.relativedelta import *
from pandas.tseries.offsets import *
from scipy import stats
from google.colab import drive
drive.mount('/content/gdrive')

Precios =
pd.read_csv('/content/gdrive/MyDrive/TFG_Business_Analytics/event_studies/data/exxon_stock.csv')
Factores =
pd.read_csv('/content/gdrive/MyDrive/TFG_Business_Analytics/event_studies/data/3_factors.csv')
Eventos =
pd.read_csv('/content/gdrive/MyDrive/TFG_Business_Analytics/event_studies/data/exxon_ft_title.csv')

Precios = Precios.dropna()
Factores = Factores.dropna()
Eventos = Eventos.dropna()

Precios['Return'] = Precios['Adj Close'].pct_change()
Precios = Precios.dropna()
```

```
Precios['Date'] = pd.to_datetime(Precios['Date'])
Precios.set_index(Precios['Date'].dt.strftime('%Y%m%d'), inplace=True)
Precios.drop(columns=['Date'], inplace=True)
Precios.drop(columns=['Unnamed: 0'], inplace=True)

Factores.rename(columns={'Unnamed: 0': 'Date'}, inplace=True)
rf=Factores[['Date', 'RF']]
rf=rf.set_index('Date')
Factores.set_index('Date', inplace=True)
Factores.drop('RF',axis=1)
Factores['Constant']=1
Factores = Factores[['Constant','Mkt-RF', 'SMB', 'HML']]

Factores = Factores.loc['20080103':'20230201']

Eventos['Date'] = pd.to_datetime(Eventos['Date'])
Eventos.set_index(Eventos['Date'].dt.strftime('%Y%m%d'), inplace=True)
Eventos.drop(columns=['Date'], inplace=True)
Eventos.drop(columns=['Unnamed: 0'], inplace=True)

df_combinado = Precios.join(Factores)

df_combinado.index = pd.to_datetime(df_combinado.index)
prices = df_combinado['Adj Close']
plt.figure(figsize=(10, 6))
plt.plot(prices, label='Precio Ajustado de Cierre')
plt.title('Evolución del Precio Ajustado de Cierre de ExxonMobil')
plt.xlabel('Fecha')
plt.ylabel('Precio Ajustado de Cierre (USD)')
plt.legend()
```

```
plt.grid(True)
```

```
plt.show()
```

```
import statsmodels.api as sm
```

```
from statsmodels.regression.rolling import RollingOLS
```

```
df_combinado.index = pd.to_datetime(df_combinado.index)
```

```
Y = df_combinado['Return']
```

```
X = df_combinado[['Mkt-RF', 'SMB', 'HML']]
```

```
X = sm.add_constant(X)
```

```
window_size = 252 * 2
```

```
model_rolling = RollingOLS(Y, X, window=window_size, min_nobs=window_size)
```

```
rolling_result = model_rolling.fit()
```

```
fig, ax = plt.subplots(figsize=(10, 6))
```

```
rolling_result.params.plot(ax=ax)
```

```
ax.set_title('Evolución de Betas Rolling')
```

```
ax.set_xlabel('Fecha')
```

```
ax.set_ylabel('Beta Values')
```

```
plt.show()
```

```
beta_volatility = rolling_result.params.std()
```

```
print("Volatilidad de los Betas:", beta_volatility)
```

```
first_valid_index = rolling_result.params.dropna().index[0]
```

```
print("Primer coeficiente beta válido desde:", first_valid_index)
```

```
predicted_returns = []
```

```
for i in range(rolling_result.params.index.get_loc(first_valid_index), len(X)):
```

```
    params = rolling_result.params.iloc[i]
```

```
X_row = X.iloc[i]
fitted_value = np.dot(X_row, params)
predicted_returns.append(fitted_value)

predicted_index = df_combinado.loc[first_valid_index:].index[:len(predicted_returns)]
df_combinado.loc[predicted_index, 'Fitted_Return'] = predicted_returns
df_combinado['Return_Difference'] = df_combinado['Return'] -
df_combinado['Fitted_Return']
print("Primeros Fitted_Returns:", df_combinado['Fitted_Return'].dropna().head())
print("Primeras Diferencias de Retorno:",
df_combinado['Return_Difference'].dropna().head())

plt.figure(figsize=(14, 7))
plt.plot(df_combinado.loc[predicted_index].index,
df_combinado.loc[predicted_index]['Return_Difference'], label='Abnormal Return',
color='red')
plt.title('Abnormal Returns Over Time')
plt.xlabel('Date')
plt.ylabel('Abnormal Return')
plt.legend()
plt.show()

df_combinado.index = pd.to_datetime(df_combinado.index)
df_combinado = df_combinado[df_combinado.index >= pd.Timestamp('2009-12-31')]

betas = rolling_result.params
betas_df = pd.DataFrame(betas)

fig, ax = plt.subplots(figsize=(10, 6))
betas_df.plot(ax=ax)
```

```
ax.set_title('Evolución de los Coeficientes Rolling Betas')
ax.set_xlabel('Fecha')
ax.set_ylabel('Valor de Beta')
ax.legend(title='Factores')
plt.grid(True)
plt.show()
```

```
plt.figure(figsize=(14, 7))
plt.plot(df_combinado.index, df_combinado['Return'], label='Real Return', color='blue')
plt.plot(df_combinado.index, df_combinado['Fitted_Return'], label='Fitted Return',
color='red', alpha=0.7)
plt.title('Comparación de los Retornos Reales vs Fitted Returns')
plt.xlabel('Fecha')
plt.ylabel('Retorno')
plt.legend()
plt.show()
```

```
plt.figure(figsize=(14, 7))
differences = df_combinado['Return'] - df_combinado['Fitted_Return']
plt.fill_between(df_combinado.index, 0, differences, where=(differences >= 0), color='green',
alpha=0.5, label='Positive Difference (Real > Fitted)')
plt.fill_between(df_combinado.index, 0, differences, where=(differences <= 0), color='red',
alpha=0.5, label='Negative Difference (Real < Fitted)')
plt.axhline(0.01, color='darkgreen', linestyle='--', linewidth=1, label='+0.01 Difference')
plt.axhline(-0.01, color='darkred', linestyle='--', linewidth=1, label='-0.01 Difference')
plt.axhline(0.02, color='darkgreen', linestyle='-', linewidth=1, label='+0.02 Difference')
plt.axhline(-0.02, color='darkred', linestyle='-', linewidth=1, label='-0.02 Difference')
plt.title('Visualización de Diferencias entre Retornos Reales y Ajustados con Líneas de
Referencia')
```

```
plt.xlabel('Fecha')
plt.ylabel('Diferencia de Retorno')
plt.legend(loc='upper right')
plt.axhline(0, color='black', linewidth=0.5, alpha=0.7)

plt.show()

combined_data =
pd.read_csv('/content/gdrive/MyDrive/TFG_Business_Analytics/event_studies/data/exxon_ft
_sentiment', parse_dates=['Date'])

combined_data.set_index('Date', inplace=True)

combined_data.sort_index(inplace=True)
print(combined_data)

combined_data_sentiment = combined_data

combined_data_sentiment.drop(columns=['Unnamed: 0'], inplace=True)

df_combinado.index = pd.to_datetime(df_combinado.index, format='%Y%m%d')
if not isinstance(combined_data_sentiment.index, pd.DatetimeIndex):
    combined_data_sentiment.index = pd.to_datetime(combined_data_sentiment.index)
ano = timedelta(366)
dia = timedelta(1)

def get_correct_date(dicc, date):
    try:
        x = dicc[date]
        return x
```

except:

```
event = datetime.strptime(date, '%Y%m%d')  
return get_correct_date(dicc, (event+dia).strftime('%Y%m%d'))
```

```
from datetime import datetime, timedelta
```

```
import numpy as np
```

```
import scipy.stats
```

```
def extract_statistics_rolled(date, df_combinado, window_size=10):
```

```
    event = datetime.strptime(date, '%Y%m%d')  
    window_start = event - timedelta(days=window_size)  
    window_end = event + timedelta(days=window_size)
```

```
    try:
```

```
        start_date = df_combinado.index.asof(window_start)  
        end_date = df_combinado.index.asof(window_end)  
        if start_date is None or end_date is None:  
            print(f"No close data available for window from {window_start} to {window_end}")  
            return None  
        start_idx = df_combinado.index.get_loc(start_date)  
        end_idx = df_combinado.index.get_loc(end_date)  
        window_data = df_combinado.loc[start_idx:end_idx]
```

```
    except KeyError:
```

```
        print(f"No close data available for window from {window_start} to {window_end}")  
        return None
```

```
    if window_data.empty:
```

```
        print(f"No data available for window {window_start} to {window_end}")  
        return None
```

```
abnormal_R = window_data['Return_Difference']

day_number = abnormal_R.count()
sigma = np.sqrt(((abnormal_R)**2).sum() / (day_number - 2))
sigma_2 = np.sqrt(day_number * sigma**2)
abnormal_ayer = abnormal_R.iloc[-1]

event_tomorrow = (event + timedelta(days=1)).strftime('%Y-%m-%d')
try:
    next_day = df_combinado.index.asof(event_tomorrow)
    if next_day is None:
        print(f'Data for {event_tomorrow} is not available.')
        return None
    next_day_idx = df_combinado.index.get_loc(next_day)
    abnormal_hoy = df_combinado.iloc[next_day_idx]['Return_Difference']
except KeyError:
    print(f'Data for {event_tomorrow} is not available.')
    return None

est = (abnormal_hoy - abnormal_ayer) / sigma
stats_value = scipy.stats.norm(0, sigma_2).cdf(est)
return stats_value

def calculate_important_events(df, df_combinado):
    df = df[(df.index.year > 2007) & (df.index.year < 2018)]
    important_events = []
    pos_events = 0
    neg_events = 0
    pos_important = 0
    neg_important = 0
```

```
for index, row in df.iterrows():
    statistics = extract_statistics_rolled(index.strftime('%Y%m%d'), df_combinado)
    if statistics is not None:
        if statistics <= 0.05:
            print(f'Statistics for date {index.strftime('%Y%m%d')}: {statistics}')
            important_events.append(index.strftime('%Y%m%d'))
            if row['major_sent'] == 'positive':
                pos_important += 1
            else:
                neg_important += 1
            if row['major_sent'] == 'positive':
                pos_events += 1
            else:
                neg_events += 1
        else:
            print(f'Statistics for date {index.strftime('%Y%m%d')} could not be calculated.")

print("\n\n")
print(f'Number of important events after 2010: {len(important_events)}')
print(f'Total number of events after 2010: {len(df)}')
print(f'Number of positive events: {pos_events}, Percentage: {(pos_events/len(df))*100 if
len(df) > 0 else 0}%")
print(f'Number of negative events: {neg_events}, Percentage: {(neg_events/len(df))*100
if len(df) > 0 else 0}%")
print(f'Number of important positive events: {pos_important}, Percentage:
{(pos_important/len(df))*100 if len(df) > 0 else 0}%")
print(f'Number of important negative events: {neg_important}, Percentage:
{(neg_important/len(df))*100 if len(df) > 0 else 0}%")
```

```
return important_events, df, len(important_events), len(df)

combined_data = combined_data.loc['2009-12-31:']

important_events_ft_all, mod_events_ft_all, len_important_events, total_events =
calculate_important_events(combined_data, df_combinado)

important_events_ft_all = pd.to_datetime(important_events_ft_all, format='%Y%m%d')
combined_data.index = pd.to_datetime(combined_data.index)
filtered_data = combined_data[combined_data.index.isin(important_events_ft_all)]

filtered_data = filtered_data[filtered_data.index >= pd.Timestamp('2009-12-31')]

import seaborn as sns
custom_palette = {
    'negative': 'orange',
    'positive': 'green'
}

figsize = (12, 1.2 * len(filtered_data['major_sent'].unique()))
plt.figure(figsize=figsize)
sns.violinplot(data=filtered_data, x='total_sentiment', y='major_sent', inner='stick',
palette=custom_palette)
sns.despine(top=True, right=True, bottom=True, left=True)
plt.show()

x = [0, 1]
categorias = ['Total Noticias', 'Importantes']
totales = [sum(n) for n in zip(positivas, negativas)]
porc_positivas_total = (positivas[0] / totales[0]) * 100
```

```
porc_negativas_total = (negativas[0] / totales[0]) * 100
porc_positivas_importantes = (positivas[1] / totales[1]) * 100
porc_negativas_importantes = (negativas[1] / totales[1]) * 100
```

```
fig, ax = plt.subplots(figsize=(8, 5))
bar_width = 0.35
```

```
bar1 = ax.bar([p - bar_width/2 for p in x], positivas, width=bar_width, label='Positivas',
color='green')
bar2 = ax.bar([p + bar_width/2 for p in x], negativas, width=bar_width, label='Negativas',
color='red')
```

```
ax.set_xlabel('Categoría')
ax.set_ylabel('Número de Noticias')
ax.set_title('Comparación de Noticias Positivas y Negativas')
ax.set_xticks(x)
ax.set_xticklabels(categorias)
```

```
def add_labels_inside_bars(bars, percentages):
    for bar, percentage in zip(bars, percentages):
        height = bar.get_height()
        ax.annotate('{}\n({:.1f}%)'.format(height, percentage),
            xy=(bar.get_x() + bar.get_width() / 2, height/2),
            color='white',
            ha='center', va='center')
```

```
ax.annotate('Total Noticias: {}'.format(totales[0]),
            xy=(x[0], max(positivas[0], negativas[0])),
            color='blue',
            ha='center', va='bottom')
```

```
ax.annotate('Con efecto: {}'.format(totales[1]),
            xy=(x[1], max(positivas[1], negativas[1])),
            color='blue',
            ha='center', va='bottom')

add_labels_inside_bars(bar1, [porc_positivas_total, porc_positivas_importantes])
add_labels_inside_bars(bar2, [porc_negativas_total, porc_negativas_importantes])

ax.legend()

plt.show()

total_positivas = positivas[0]
importantes_positivas = positivas[1]
total_negativas = negativas[0]
importantes_negativas = negativas[1]

porcentaje_imp_positivas = (importantes_positivas / total_positivas) * 100
porcentaje_imp_negativas = (importantes_negativas / total_negativas) * 100

fig, ax = plt.subplots(figsize=(8, 5))
bar_width = 0.35

bar_total = ax.bar(categorias, [total_positivas, total_negativas], width=bar_width,
                  label='Total', color=['green', 'red'], alpha=0.5)
bar_importantes = ax.bar(categorias, [importantes_positivas, importantes_negativas],
                        width=bar_width, label='Con efecto', color=['darkgreen', 'darkred'])

ax.set_xlabel('Tipo de Noticias')
```

```
ax.set_ylabel('Número de Noticias')
ax.set_title('Impacto de Noticias Positivas y Negativas')
ax.legend()

def add_labels(bars, totals):
    for bar, total in zip(bars, totals):
        height = bar.get_height()
        ax.annotate('{}\n({:.1f}%)'.format(height, (height / total) * 100),
                    xy=(bar.get_x() + bar.get_width() / 2, height),
                    ha='center', va='bottom')

add_labels(bar_importantes, [total_positivas, total_negativas])

plt.show()

average_sentiment = filtered_data.groupby(filtered_data.index).total_sentiment.mean()
average_sentiment = average_sentiment.reset_index()
average_sentiment.columns = ['Date', 'total_sentiment']

average_sentiment['major_sent'] = average_sentiment['total_sentiment'].apply(lambda x:
'positive' if x > 0 else 'negative')

average_sentiment.set_index('Date', inplace=True)

print(average_sentiment)

df_combinado.loc[:, 'Event_Sentiment'] = np.nan
for event_date, event_info in average_sentiment.iterrows():
    next_market_date = df_combinado[df_combinado.index >= event_date].index.min()
    if pd.notna(next_market_date):
```

```
df_combinado.loc[next_market_date, 'Event_Sentiment'] = event_info['total_sentiment']

df_combinado.dropna(subset=['Event_Sentiment'])

plt.figure(figsize=(14, 7))
event_days = df_combinado.dropna(subset=['Event_Sentiment'])
plt.plot(df_combinado.index, df_combinado['Close'], label='Close', color='blue', alpha=0.6)
colors = event_days['Event_Sentiment'].apply(lambda x: 'green' if x > 0 else 'red')
plt.scatter(event_days.index, event_days['Close'], color=colors, label='Event Day', zorder=3)
plt.title('Market Response to Events')
plt.xlabel('Date')
plt.ylabel('Close Price')
plt.legend()
plt.show()

def calculate_normalized_CAR(row, window_size=3):
    center_index = df_combinado.index.get_loc(row.name)
    indices = range(center_index - window_size // 2, center_index + window_size // 2 + 1)
    valid_indices = [i for i in indices if 0 <= i < len(df_combinado)]
    dates = df_combinado.index[valid_indices]
    business_days = pd.bdate_range(start=dates.min(), end=dates.max()).intersection(dates)
    car_value = df_combinado.loc[business_days, 'Return_Difference'].sum()
    if len(business_days) > 0:
        return car_value / len(business_days)
    else:
        return np.nan

df_combinado['CAR_3day'] = df_combinado.apply(calculate_normalized_CAR, axis=1)

print(df_combinado[['Return_Difference', 'CAR_3day']].head())
```

```
from scipy.stats import ttest_1samp

event_days = df_combinado.dropna(subset=['Event_Sentiment'])
t_stat, p_value = ttest_1samp(event_days['Return_Difference'], 0)
print(f"T-statistic: {t_stat}, P-value: {p_value}")

plt.figure(figsize=(12, 6))

plt.plot(df_combinado.index, df_combinado['CAR_3day'], label='Cumulative Abnormal
Returns', color='blue', alpha=0.5)
event_days = df_combinado.dropna(subset=['Event_Sentiment'])
colors = ['green' if x > 0 else 'red' for x in event_days['Event_Sentiment']]
plt.scatter(event_days.index, event_days['CAR_3day'], color=colors, label='Event Days')
plt.axhline(0, color='gray', linestyle='--')
plt.title('Abnormal Returns Around Event Days')
plt.xlabel('Date')
plt.ylabel('Abnormal Returns')
plt.legend()
plt.show()

window_days_before = 60
window_days_after = 60
windows_data = pd.DataFrame()

for event_date in df_combinado[df_combinado['Event_Sentiment'].notna()].index:
    start_date = event_date - pd.Timedelta(days=window_days_before)
    end_date = event_date + pd.Timedelta(days=window_days_after)
    window_df = df_combinado.loc[start_date:end_date].copy()
    window_df['Event_Date'] = event_date
```

```
windows_data = pd.concat([windows_data, window_df], ignore_index=True)

windows_data.fillna(0, inplace=True)

from scipy.stats import ttest_ind

mask_event_days = windows_data['Event_Sentiment'] != 0
mask_non_event_days = (windows_data['Event_Sentiment'] == 0) |
(windows_data['Event_Sentiment'].isna())
event_days_returns = windows_data[mask_event_days]['Return_Difference']
non_event_days_returns = windows_data[mask_non_event_days]['Return_Difference']
t_stat, p_value = ttest_ind(event_days_returns.dropna(), non_event_days_returns.dropna())

print(f"T-statistic: {t_stat}, P-value: {p_value}")

positive_events = event_days[event_days['Event_Sentiment'] > 0]
negative_events = event_days[event_days['Event_Sentiment'] < 0]

print("Estadísticas de Retornos Anormales para Eventos Positivos:")
print(positive_events['Return_Difference'].describe())

print("\nEstadísticas de Retornos Anormales para Eventos Negativos:")
print(negative_events['Return_Difference'].describe())

t_stat_pos, p_value_pos = ttest_1samp(positive_events['CAR_3day'], 0)
print(f"Resultados del t-test para eventos positivos: T-statistic = {t_stat_pos}, P-value =
{p_value_pos}")

t_stat_neg, p_value_neg = ttest_1samp(negative_events['CAR_3day'], 0)
```

```
print(f'Resultados del t-test para eventos negativos: T-statistic = {t_stat_neg}, P-value =  
{p_value_neg}')
```

```
positive_returns = positive_events['Return_Difference']  
negative_returns = negative_events['Return_Difference']
```

```
plt.figure(figsize=(12, 6))  
plt.hist(positive_returns, bins=50, alpha=0.5, label='Positive Sentiment', color='blue',  
density=True)  
plt.hist(negative_returns, bins=50, alpha=0.5, label='Negative Sentiment', color='orange',  
density=True)
```

```
mean_positive = np.mean(positive_returns)  
mean_negative = np.mean(negative_returns)
```

```
plt.axvline(mean_positive, color='blue', linestyle='--', label=f'Mean Positive:  
{mean_positive:.4f}')  
plt.axvline(mean_negative, color='orange', linestyle='--', label=f'Mean Negative:  
{mean_negative:.4f}')
```

```
plt.axvline(0, color='gray', linestyle='--')  
plt.title('Distribution of Abnormal Returns by Sentiment Type')  
plt.xlabel('Abnormal Returns')  
plt.ylabel('Relative Frequency')  
plt.legend()  
plt.show()
```


BIBLIOGRAFÍA

Ahuja, R., Chug, A., Kohli, S., Gupta, S., & Ahuja, P. (2019). The impact of features extraction on the sentiment analysis. *Procedia Computer Science*, 152, 341-348.

Aqlan, A. A. Q., Manjula, B., & Lakshman Naik, R. (2019). A study of sentiment analysis: concepts, techniques, and challenges. In *Proceedings of International Conference on Computational Intelligence and Data Engineering: Proceedings of ICCIDE 2018* (pp. 147-162). Springer Singapore.

Ball, R. and P. Brown, (1968), An empirical evaluation of accounting income numbers, *Journal of Accounting Research* 6, 159-178.

Cheadle, C., Vawter, M. P., Freed, W. J., & Becker, K. G. (2003). Analysis of microarray data using Z score transformation. *The Journal of molecular diagnostics*, 5(2), 73-81.

Corrado, C. J. (2011). Event studies: A methodology review. *Accounting & Finance*, 51(1), 207-234.

Curtis, A. E., Smith, T. A., Ziganshin, B. A., & Elefteriades, J. A. (2016). The mystery of the Z-score. *Aorta*, 4(04), 124-130.

Coudert, V., Hervé, K., & Mabilie, P. (2015). Internationalization versus regionalization in the emerging stock markets. *International Journal of Finance & Economics*, 20(1), 16-27.

Çano, E., & Morisio, M. (2019). Word embeddings for sentiment analysis: a comprehensive empirical survey. arXiv preprint arXiv:1902.00753.

Deepgram. (n.d.). What is Tokenization in NLP & Machine Learning? Recuperado el 10/01/2024, de <https://www.deepgram.com/>

De Jong, A., & Naumovska, I. (2016). A note on event studies in finance and management research. *Review of Finance*, 20(4), 1659-1672.

Elastic. (s.f.). ¿Qué son los datos no estructurados? Una guía completa de datos no estructurados. Recuperado el 09/01/24, de <https://www.elastic.co/es/what-is/unstructured-data>

ExxonMobil. (s.f.). Our history. Recuperado el 15 de junio de 2024 de <https://corporate.exxonmobil.com/who-we-are/our-global-organization/our-history>

Fama, E.F., Fisher, L., Jensen, M.C., and R. Roll, (1969), The adjustments of stock prices to new information, *International Economic Review* 10(1), 1-21

Fama, E. F., & French, K. R. (2004). The capital asset pricing model: Theory and evidence. *Journal of economic perspectives*, 18(3), 25-46.

Hutto, C., & Gilbert, E. (2014, May). Vader: A parsimonious rule-based model for sentiment analysis of social media text. In *Proceedings of the international AAAI conference on web and social media* (Vol. 8, No. 1, pp. 216-225).

Hudson, R. S., & Gregoriou, A. (2015). Calculating and comparing security returns is harder than you think: A comparison between logarithmic and simple returns. *International Review of Financial Analysis*, 38, 151-162.

Johansen, A. M. (2010). Markov Chain Monte Carlo. En P. Peterson, E. Baker, & B. McGaw (Eds.), *International Encyclopedia of Education* (3rd ed., pp. 245-252). Elsevier. <https://doi.org/10.1016/B978-0-08-044894-7.01347-6>

Jurafsky, D., & Martin, J. H. (2019) *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition*.

Kent State University Libraries. (s.f.). Independent samples t test. SPSS Tutorials. Retrieved June 16, 2024, from <https://libguides.library.kent.edu/SPSS/IndependentTTest>

Korovkinas, K., Danėnas, P., & Garšva, G. (2017). SVM and Naïve Bayes classification ensemble method for sentiment analysis. *Baltic journal of modern computing*, 5(4), 398-409.

Mitchell, M. L., and J. M. Netter, 1994, The role of financial economics in securities fraudcases: applications at the Securities and Exchange Commission, *Business Lawyer* 49(2),545–590.

Murthy, G. S. N., Allu, S. R., Andhavarapu, B., Bagadi, M., & Belusonti, M. (2020). Text based sentiment analysis using LSTM. *Int. J. Eng. Res. Tech. Res*, 9(05).

Mohan, S., Mullapudi, S., Sammeta, S., Vijayvergia, P., & Anastasiu, D. C. (2019, April). Stock price prediction using news sentiment analysis. In 2019 IEEE fifth international conference on big data computing service and applications (BigDataService) (pp. 205-208). IEEE.

Reddy, P. S., Sri, D. R., Reddy, C. S., & Shaik, S. (2021). Sentimental analysis using logistic regression. *Int. J. Eng. Res. Afr*, 11, 36-40.

Santana, F. (2023). The effect of financial news on stock prices: insights from NLP techniques.

Sorescu, A., Warren, N. L., & Ertekin, L. (2017). Event study methodology in the marketing literature: an overview. *Journal of the Academy of Marketing Science*, 45, 186-207.

Shah, D., Isah, H., & Zulkernine, F. (2018, December). Predicting the effects of news sentiments on the stock market. In 2018 IEEE International Conference on Big Data (Big Data) (pp. 4705-4708). IEEE.

Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19(3), 425-442

Sharpe, W. F. (1990). Capital asset prices with and without negative holdings. Nobel Foundation.

Vijayarani, S., & Janani, R. (2016). Text mining: open source tokenization tools-an analysis. *Advanced Computational Intelligence: An International Journal (ACII)*, 3(1), 37-47.

Yahoo Finance. (n.d.). What is the adjusted close? Retrieved June 20, 2024

Yin, S., Mazouz, K., Benamraoui, A., & Saadouni, B. (2018). Stock price reaction to profit warnings: the role of time-varying betas. *Review of Quantitative Finance and Accounting*, 50, 67-93.

Ziyue, Z. (2023). Studying the Impact of Media Coverage on the Stock Market Using Mediating Effects. *Advances in Economics, Management and Political Sciences*.