

ANÁLISIS PREDICTIVO DEL PRECIO DE LAS TIERRAS RARAS



Jesús García Lozano
Trabajo Final Analytics
23/04/2024

ABSTRACT

Rare earth metals are a popular yet unexplored topic nowadays. Thanks to their physical and chemical traits, they play a vital role in the development of modern technologies such as solar panels, nuclear energy reactors or phone chips. This wide variety of applications make rare earths a valuable asset in the market of commodities. Following the findings made on the paper *Modelado del mercado de las tierras raras*, by Manuel González Plaza, this paper aims to study the price predictions based on different variables that affect the prices of rare earth metals in the commodities market. Such findings are the basis of this analysis, which focus on the macroeconomic variables of Wu-Xia Shadow Rate, GEA tracker, and ESG index. Through a benchmark prediction, an autoregressive model forecasts the daily prices of rare earth metals between February 26th, 2016 and March 31st, 2023. Then, a second model forecasts the prices again; however, this time it will include the variables mentioned before, within the same time frame and a daily frequency. This will give a better understanding of price behavior and deepens the possibilities of further analysis. Results show the complexity for the prediction of these prices and suggest that the variables initially thought to affect these numbers are more intricate than they appear, as the impact of different socioeconomic and market trends play a significant role in defining these values.

Keywords: rare earths, price index, commodities, predictive model, autoregression, Wu-Xia Shadow Rate, GEA Tracker, ESG.

RESUMEN

Las tierras raras son un tema popular pero aún inexplorado en la actualidad. Gracias a sus características físicas y químicas, desempeñan un papel vital en el desarrollo de tecnologías modernas como paneles solares, reactores de energía nuclear o chips para teléfonos. Esta amplia variedad de aplicaciones hace que las tierras raras sean un activo valioso en el mercado de materias primas. Siguiendo los hallazgos realizados en el artículo "Modelado del mercado de las tierras raras", de Manuel González Plaza, este documento tiene como objetivo estudiar las predicciones de precios basadas en diferentes variables que afectan los precios de los metales de tierras raras en el mercado de materias primas. Estos hallazgos son la base de este análisis, que se centra en las variables macroeconómicas de la Tasa de Fondos Federales en Sombras de Wu-Xia, el GEA tracker y el índice ESG. A través de una predicción de referencia, un modelo autorregresivo pronostica los precios diarios de los metales de tierras raras entre el 26 de febrero de 2016 y el 31 de marzo de 2023. Luego, un segundo modelo vuelve a predecir los precios; sin embargo, esta vez incluirá las variables mencionadas anteriormente, dentro del mismo marco temporal y con una frecuencia diaria. Esto proporcionará una mejor comprensión del comportamiento de los precios y profundizará las posibilidades de análisis adicionales. Los resultados muestran la complejidad para la predicción de estos precios, y sugieren que las variables consideradas inicialmente de gran impacto hacia estos números son más intrincadas de lo que parecen, ya que los efectos de diferentes tendencias socioeconómicas y de mercado juegan un papel significativo en la definición de estos valores.

Palabras clave: metales de tierras raras, índice de precios, materias primas, modelo predictivo, autorregresión, Tasa de Fondos Federales en Sombras de Wu-Xia, GEA Tracker, índice ESG.

ÍNDICE

1. INTRODUCCIÓN	5
1.1 Modelo	6
1.2 Variables	7
2. LAS TIERRAS RARAS	10
2.1 Definición y tipos	10
2.2 Aplicaciones	11
2.3 Distribución y explotación	12
2.4 Preocupación medioambiental	14
2.5 Tendencias Futuras	15
3. METODOLOGÍA	16
3.1 Descripción de los datos	16
3.2 Modelo Predictivo	19
R2OS	21
Clark-West	21
CSPED (Cumulative Sum Prediction Error Difference)	23
4. DISCUSIÓN DE LOS RESULTADOS	24
5. CONCLUSIÓN	26
6. ANEXO	28
7. Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado	32
8. BIBLIOGRAFÍA	33

1. INTRODUCCIÓN

Las tierras raras son un conjunto de metales pertenecientes al grupo F de la tabla periódica, el grupo de los lantánidos, unos elementos con unas propiedades no encontradas en ningún otro grupo de metales y que poseen infinidad de aplicaciones (Chakhmouradian, A. R., & Wall, F., 2012). Estos elementos, entre los que se encuentran el lantano, el cerio o el neodimio, poseen unas características físicas y químicas que resultan fundamentales en una variedad de aplicaciones tecnológicas, con especial importancia en la fabricación de microchips.

Dichos elementos se denominan “raros” porque normalmente se encuentran en la naturaleza en cantidades bajas comparado con el resto de los metales. Esto no significa que sean escasos, si no que se encuentran en depósitos dispersos y en concentraciones bajas, lo que hace que su extracción y purificación sean costosos (Kanazawa, Y., & Kamitani, M., 2006).

Algunas de las aplicaciones más relevantes de las tierras raras son la industria de la alta tecnología, industria automotriz, iluminación, energías renovables, electrónica y medicina (Chakhmouradian, A. R., & Wall, F., 2012). Todas estas aplicaciones son, en definitiva, el día a día de la mayoría de los consumidores, por lo que se prevé que la demanda de estos metales irá en aumento debido a la importancia que poseen.

En cuanto a la dimensión financiera, el mercado de las tierras raras ha experimentado un notable crecimiento debido a su demanda en industrias tecnológicas, como se ha mencionado anteriormente. Este crecimiento ha dado lugar al desarrollo de mercados financieros especializados, incluyendo los mercados de futuros y spot, que facilitan la compra, venta y especulación sobre estos elementos.

Los mercados de futuros de tierras raras permiten a los participantes negociar contratos que representan una cantidad específica de tierras raras a un precio acordado para entrega en el futuro. Estos contratos ayudan a gestionar el riesgo de precio y permiten a inversores obtener exposición a los movimientos de precios sin poseer el producto físico.

Por otro lado, los mercados spot de tierras raras permiten la compra y venta inmediata de estos elementos, proporcionando flexibilidad y liquidez a los participantes.

Sin embargo, los mercados de tierras raras son volátiles y se ven afectados por variables como la oferta y demanda, geopolítica, avances tecnológicos y regulaciones gubernamentales. Por ejemplo, restricciones de exportación impuestas por China, el principal productor, pueden afectar significativamente los precios y la disponibilidad de estos elementos.

En cuanto a inversiones financieras, las dos formas más comunes de invertir en tierras raras es mediante la inversión directa o a través de un ETF (Exchange-traded Funds, por sus siglas en inglés).

La inversión directa consiste en asignar recursos financieros a empresas del sector, es decir, las mineras. Estas empresas deben dedicar la mayor parte de su actividad a la extracción de estos metales. Destacan las australianas Lynas Corporation e Iluka Resources.

Los ETFs con subyacente físico permiten invertir en un conglomerado de empresas del sector, empresas reales como las mencionadas en el párrafo anterior, aunque no está muy desarrollado por el momento. Por otro lado, existen otros ETFs que no tienen subyacente físico si no que replican la evolución del índice de precios de las tierras raras.

Además, dada su importancia en la tecnología moderna, las tierras raras son consideradas recursos estratégicos, y su suministro puede ser objeto de preocupación en términos de seguridad y economía a nivel global. La explotación sostenible y la gestión adecuada de estos elementos son áreas de interés significativo para muchos países y organizaciones.

Por ello, dada la creciente importancia de las tierras raras en el mercado internacional, este trabajo pretende descubrir si existe una posibilidad de predecir el precio de éstas basándose en un análisis predictivo que tome en cuenta las variables más significativas que afectan en la fluctuación de los precios de dichos metales.

1.1 Modelo

Este trabajo continúa la línea de investigación del estudio denominado *Modelado del mercado de las tierras raras*, trabajo de fin de grado de Manuel González Plaza, en el cual se analizaban cuáles eran las variables que más influyen en la fluctuación de precios de las tierras raras en el mercado internacional de las commodities.

Desde el punto de vista de la oferta, se analizaron como potenciales variables significativas el Shadow rate, la producción mensual en \$ de metales raros en China, los precios mensuales (\$/Tn), y el índice del valor dólar mensual.

Desde el punto de vista de la demanda, las variables estudiadas fueron el SP 500 ESG index (%), y el índice GREA en % (global real economic activity).

Los resultados obtenidos sugieren que las variables de mayor impacto son el Shadow rate, el índice ESG y el GREA. Por tanto, esta investigación se centrará en estas tres variables para examinar la predictibilidad de los precios de las tierras raras. Sin embargo, dicha investigación fue realizada con datos mensuales en vez de diarios. Esto reduce mucho el volumen de los datos a analizar, y los resultados no son tan exactos ni la investigación tan exhaustiva. Los datos diarios aportan un volumen suficiente como para que el análisis sea no solo más fiable si no también más rastreable en caso de haber algún evento significativo en el periodo analizado, y como consecuencia se produce una disminución de la incertidumbre y un aumento de las posibles líneas de investigación futuras. Por tanto, el trabajo actual hará uso de datos con frecuencia diaria comprendidos entre el 26 de febrero de 2016 y el 31 de marzo de 2023.

1.2 Variables

Las tres variables sujeto de estudio son, como se ha visto anteriormente, por parte de la oferta el Shadow rate, y por parte de la demanda los índices ESG y GREA.

- Wu-Xia Shadow Federal Funds Rate (%): esta tasa de interés se emplea para evaluar la economía en situaciones donde las tasas nominales se aproximan al umbral inferior de cero. El concepto de Shadow rate ha ganado relevancia desde la crisis financiera de 2008, período en el cual las tasas nominales alcanzaron dicho límite inferior (Federal Reserve Bank of Atlanta).
- S&P 500 ESG Index (%): los elementos que forman las tierras raras están estrechamente vinculados a la energía verde. Con la creciente demanda generada por los Objetivos de Desarrollo Sostenible (ODS) y los acuerdos para el año 2050, la necesidad de estos elementos está en constante aumento. Es por ello que se ha

seleccionado el indicador ESG (Ambiental, Social y de Gobierno Corporativo) como una variable que refleja la demanda de estos metales. El índice S&P 500 ESG, ponderado por capitalización, está diseñado específicamente para evaluar el rendimiento de los valores que cumplen con los criterios de sostenibilidad (S&P 500 Jow Dones Index).

- Index of Global Real Economic Activity (%): el índice GREA es un indicador del ciclo económico. Se presenta como desviaciones porcentuales de la tendencia y se considera como un indicador del volumen de envío en los mercados mundiales de productos básicos industriales. Este índice se actualiza de forma diaria (Diaz, E. M., & Perez-Quiros, G., 2021).

Para el análisis del caso, se introdujeron las variables explicadas en el programa MatLab. El objetivo es predecir el precio actual de las tierras raras mediante la regresión lineal de sus precios pasados. Tras una preparación de éstas mediante técnicas de deflación y estandarización, se pasó a ejecutar dos modelos.

El primer modelo es un modelo autorregresivo de orden 1, comúnmente abreviado como AR(1). Este modelo sirve como referencia (benchmark), en el que el valor actual de la variable dependiente se modela como una combinación lineal de su valor en el período anterior, ajustado por un término de error. Este modelo es útil para analizar y predecir series temporales donde se cree que el valor actual depende principalmente de su valor inmediatamente anterior. Como para este caso, la hipótesis nula contempla una predictibilidad de la variable dependiente (el precio actual) en función de las variables de periodos anteriores (precios pasados), se emplea este modelo para comprobar si es así o no. Esto está en línea con la hipótesis de las expectativas racionales, por la cual se afirma que “los agentes económicos forman racionalmente sus expectativas sobre el futuro a través de un análisis detallado de los estados pasados y presentes de la economía” (Expansión, 2024).

El segundo modelo es una extensión del primero. El modelo ARX (1) no solamente tiene en cuenta el valor de la variable en el periodo anterior, si no que se le suman una o más variables exógenas. Para este caso, se le añadieron las variables de interés mencionadas anteriormente,

y así determinar si aportan más información sobre las futuras fluctuaciones del precio de las tierras raras.

Posteriormente se realiza un ejercicio de predictibilidad, estimando el *out-of-sample* para observar qué tal se desempeñan ambos modelos.

Se obtuvo un p valor del 5,75% y un R^2OS de 4,996e-14. Particularmente, se encuentra que en el periodo de 2016 a 2018, aproximadamente, las variables seleccionadas ayudan a mejorar la predictibilidad de los precios de metales raros con significancia estadística, a excepción de un período comprendido entre la segunda mitad de 2016 y la primera mitad de 2017. Sin embargo, a partir de 2018, el modelo ARX ofrece el mismo desempeño que el modelo base.

El trabajo se estructura de la siguiente manera:

En el siguiente apartado se explica en detalle qué son las tierras raras, tanto sus orígenes como aplicaciones, explotación y tendencias futuras de estos metales.

Posteriormente, en el apartado 3, se detallará la metodología empleada en este estudio junto a los resultados obtenidos, presentando el modelo y todas sus partes, que incluye un apartado sobre el cálculo del R^2OS , detallando su fórmula y variables implicadas; otro apartado llamado Clark-West, en el que se observa si los resultados son estadísticamente significativos mediante el Error Cuadrático Medio de Predicción (MSPE); y una última sección dedicada a la diferencia acumulativa de errores de predicción cuadráticos (CSPED, por sus siglas en inglés).

Para finalizar, en los apartados 4 y 5, hay una sección dedicada a la discusión de los resultados y otra a la conclusión del estudio, respectivamente, y un anexo (apartado 6) adjunto del código empleado en MatLab.

2. LAS TIERRAS RARAS

2.1 Definición y tipos

Las tierras raras son un conjunto de elementos que sin duda tienen una importancia vital para el desarrollo tecnológico, actual y futuro. Sus propiedades físicas y químicas similares permiten multitud de aplicaciones, gracias a su resistencia al calor, su magnetismo, durabilidad y maleabilidad, principalmente (Dushyantha, N., et. al, 2020).

El descubrimiento de las tierras raras se remonta al año 1787, cuando un militar sueco descubrió una roca que contenía un metal extraño, y tras un estudio de este lo bautizó en el año 1794 como itrio. (R. Sáez Puche...). A partir de ese momento, poco a poco se fueron descubriendo los 17 elementos que actualmente forman el grupo F de la tabla periódica, los lantánidos, que como se observa en la figura 1, son el grupo que se encuentra debajo del resto.

Imagen 1: tabla periódica de los elementos.

The image shows a standard periodic table of elements. The f-block elements, which are the lanthanides and actinides, are highlighted with a red border. These elements are located at the bottom of the table, below the main body of elements. The lanthanides (La to Lu) are in the row above the actinides (Ac to Lr). The elements are arranged in rows and columns, with their atomic numbers, symbols, and names listed. The f-block elements are: La, Ce, Pr, Nd, Pm, Sm, Eu, Gd, Tb, Dy, Ho, Er, Tm, Yb, Lu, Ac, Th, Pa, U, Np, Pu, Am, Cm, Bk, Cf, Es, Fm, Md, No, and Lr.

Fuente: WordPress

Muchos de los elementos que forman parte de las tierras raras no son tan escasos como podría parecer en un primer momento; el cerio (el más abundante), es más común en la naturaleza que

el cobre o el plomo. Otras muchas abundan más que el estaño y el molibdeno, y todas (menos el prometio) son más comunes que la plata o el mercurio (Taylor and McClelland, 1985).

Por otro lado, los elementos lantánidos con números atómicos bajos son generalmente más abundantes en la naturaleza que aquellos cuyo número atómico es más alto, y los que tienen números atómicos pares son de dos a siete veces más comunes que los elementos adyacentes con números atómicos impares (Castor & Hendrick, 2006).

2.2 Aplicaciones

Las tierras raras tienen una gran variedad de aplicaciones, formando una de las gamas más extensas de productos de consumo de cualquier tipo. Se cree que su consumo es un indicador económico significativo (Castor & Hendrick, 2006).

Gracias a las características de estos metales, sus aplicaciones son muy variadas, teniendo especial importancia en el campo de la tecnología, debido a que son componentes fundamentales de microchips que hoy en día son necesarios para el funcionamiento de los teléfonos móviles, coches, DVDs, iluminación LED o electrodomésticos inteligentes, entre otros (Castor & Hendrick, 2006).

A continuación, en la Tabla 1, se explican algunos ejemplos de cómo los metales raros se emplean hoy en día alrededor del mundo para diferentes aplicaciones:

Tabla 1. Aplicaciones de las tierras raras por industria

Electrónica	Pantallas de TV, ordenadores, teléfonos móviles, microchips de silicio, monitores, baterías recargables, lentes de cámaras, luces LED, iluminación fluorescente, escáner de equipajes, sistemas de propulsión marinos.
Manufactura	Imanes de alta resistencia, aleaciones de metales, medidores de tensión, pigmentos para cerámica, colorante para vidrios y cristales, agentes químicos oxidantes, polvo abrasivo, fabricación de plásticos, como aditivos para reforzar otros metales, convertidores catalíticos de automóviles
Ciencias médicas	Máquinas portables de rayos X, tubos de rayos X, TAC, imagenología en medicina celular, tratamientos contra el cáncer, pruebas de tamizaje genético y láseres dentales
Tecnología	Láser, cristal óptico, fibra óptica, MASERS, radares, barras de combustible nuclear, lámparas de vapor de mercurio, vidrios altamente reflectantes,

Energías limpias	memoria de ordenadores, baterías nucleares, superconductores de alta temperatura
Otros	Vehículos híbridos y eléctricos, turbinas de los aerogeneradores, baterías recargables de última generación, catalizadores de biocombustibles
	El europio se emplea para detectar billetes de euro falsos y evitar las falsificaciones
	Aproximadamente se puede encontrar 1kg de tierras raras en un vehículo híbrido
	El holmio tiene la fuerza magnética más alta de todos los elementos, y se emplea para la fabricación de imanes extremadamente fuertes. Esta propiedad se emplea para reducir el peso de motores

Fuente: Elaboración propia con datos de *Rare earth elements. Industrial minerals and rocks* (Castor & Hendrick, 2006).

2.3 Distribución y explotación

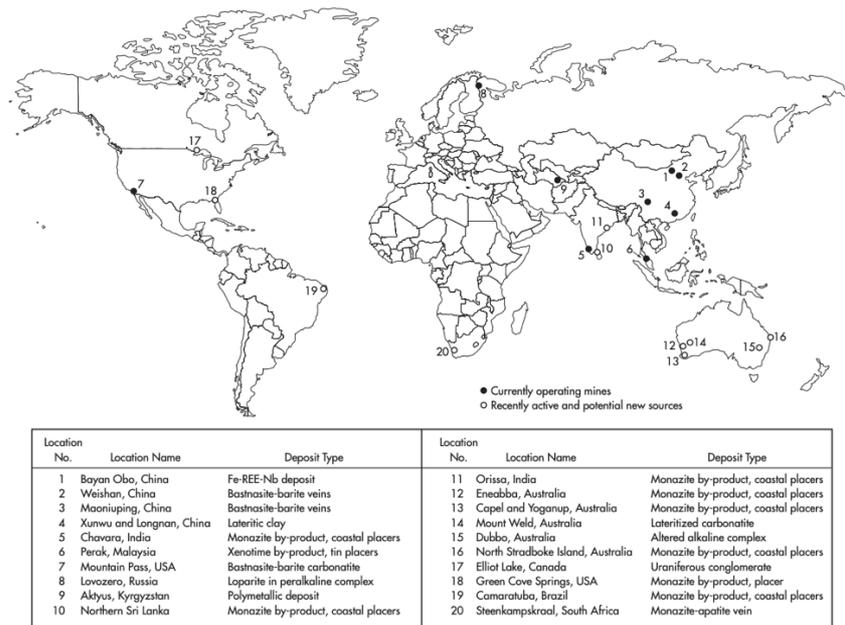
Las tierras raras fueron originalmente producidas en cantidades escasas, en el entorno geológico donde se descubrieron por primera vez (pegmatitas graníticas).

Entre los siglos XIX y XX, las tierras raras provenían principalmente de depósitos aluviales situados al sureste de Estados Unidos. Excepto el cerio, el lantano y el neodimio, el resto de los lantánidos individuales no estuvieron disponible para su comercialización hasta los años 40 (Castor & Hendrick, 2006).

Posterior a esta década, el mercado de las tierras raras en Estados Unidos comenzó a tener competencia cuando países ricos en estos metales, como Australia y Rusia, empezaron a extraer y comercializar estos elementos.

Sin embargo, en 1980 China se sumó a este grupo, y las participaciones del resto de países disminuyeron drásticamente (Castor & Hendrick, 2006). Actualmente, como se observa en la figura 2, la mayoría de las tierras raras provienen de China, debido a la especial abundancia de estos elementos en el país. En la siguiente imagen se observan las ubicaciones más relevantes de minas de tierras raras alrededor del mundo.

Figura 2. Ubicación de las minas más relevantes de tierras raras en el mundo



Fuente: *Castor & Hendrick, 2006*

Un estudio realizado por el Servicio Geológico de Estados Unidos revela que, en 2020, las reservas mundiales de metales raros son de aproximadamente 120 millones de toneladas. Estos yacimientos se concentran en Vietnam, Brasil, China, India, Australia y otros países.

China es el único país que concentra principalmente recursos de tierras raras pesadas, aquellas con un número atómico elevado y que por tanto presentan mayor masa debido a un mayor número de protones en su núcleo, mientras que en el resto solo se encuentran tierras raras ligeras, aquellas cuyo número atómico es menor (Liu & Chen, 2021). Además, como se observa en la figura 3, estos yacimientos se encuentran en provincias al sureste del país, lo que lo hace aún más atractivo debido a su relativa proximidad con ciudades tan importantes para el comercio como Cantón, Hong Kong o incluso Shanghai.

Figura 3: ubicación de las minas de tierras raras en China



Fuente: *CGTN*

2.4 Preocupación medioambiental

En Estados Unidos, las minas de extracción y las plantas de procesamiento de metales raros deben cumplir los mismos requisitos medioambientales que el resto de las minas y plantas. Aunque esto no es así en todos los países, lo cierto es que la preocupación medioambiental más grande es la de los residuos, ya que algunos son radiactivos. Aparte del riesgo para la salud que estos residuos provocan, es muy caro deshacerse de ellos con seguridad, por lo que la producción de algunas plantas de Estados Unidos y Australia se ha visto disminuida (Zhou B. et. al, 2017).

Por otro lado, el consumo de tierras raras está estrechamente vinculado a las regulaciones medioambientales que controlan la polución del aire. Las tierras raras se emplean para la fabricación de los catalizadores industriales, por lo que cuando las regulaciones se endurecen y la calidad de los combustibles necesita ser mejor, la demanda por estos elementos cambia, ya

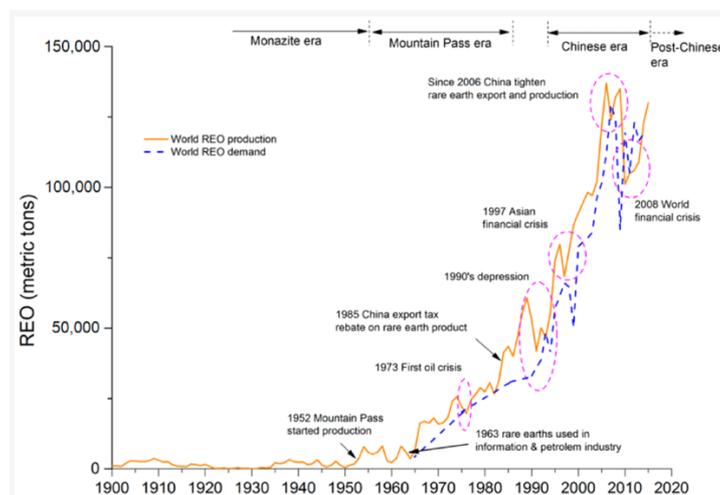
que cambia la composición del producto final. Por tanto, se puede afirmar que estos elementos contribuyen a la liberación de CO₂ y otros gases de efecto invernadero a la atmósfera, ya que son necesarios para la producción de los carburantes (Castor & Hendrick, 2006).

2.5 Tendencias Futuras

Con la evolución exponencial de las tecnologías que existe actualmente, se espera que el consumo de tierras raras siga en aumento (Zhou B. et. al, 2017). El aumento de la digitalización, el crecimiento de la población mundial, la aparición de nuevos mercados en los países emergentes y el aumento del rango de aplicaciones de las tierras raras son algunos de los ejemplos por los que se prevé este crecimiento.

China seguirá siendo el principal proveedor mundial, aunque aparecerán nuevos competidores en este mercado (figura 4), competidores que ofrecerán elementos nuevos a través de aleaciones, interacciones con otros elementos y versiones mejoradas de las existentes, lo que lo convertirá en un mercado cada vez más importante y competitivo (Castor & Hendrick, 2006).

Figura 4: oferta y demanda internacional de tierras raras

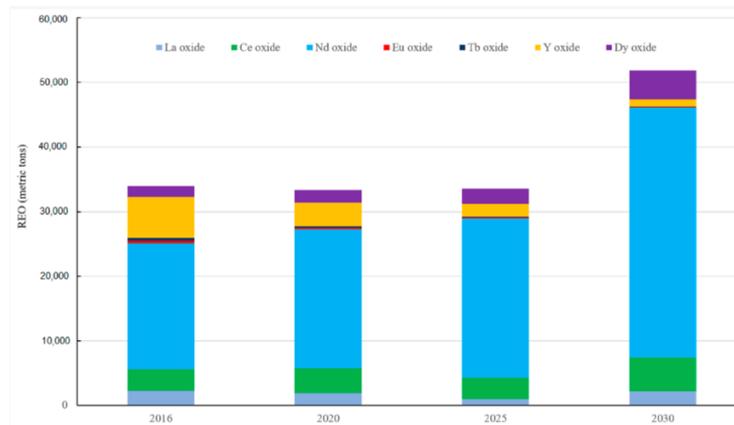


Fuente: Zhou B, Li Z, Chen C, 2017

Otro factor que permite la evolución de este mercado es que se estima que existen en el mundo reservas suficientes de tierras raras como para cubrir la demanda de todo el siglo XXI, por lo que las posibilidades de explotación y producción son muy amplias (Zhou B. et. al, 2017).

Además, las tendencias actuales de la transición a energías limpias requieren una gran cantidad de estos minerales para aplicaciones tan importantes como las turbinas de los aerogeneradores, iluminación eficiente o las placas solares. Pese a que los combustibles fósiles siguen siendo la principal fuente de energía primaria, las energías verdes son las que más rápido crecen, y para 2035 se estima que representen el 10% de toda la energía primaria, la cual a su vez aumenta un 1,3% anual (Zhou B. et. al, 2017). Por lo tanto, como se muestra en la figura 5, la demanda de estos metales para este sector específico está en constante aumento.

Figura 5: demanda global de óxidos de metales raros de tecnologías limpias



Fuente: Zhou B, Li Z, Chen C, 2017

3. METODOLOGÍA

En esta sección se presenta la metodología, donde se explicará detalladamente el procedimiento seguido para hacer el modelo predictivo del precio de las tierras raras y las fórmulas empleadas en cada apartado, acompañado de los resultados obtenidos.

3.1 Descripción de los datos

Cabe destacar la frecuencia diaria de los datos estudiados, ya que no es algo con lo que típicamente se trabaje en este tipo de investigaciones debido a que la obtención de estos presenta ciertas dificultades, particularmente porque dos de las tres variables de interés son de carácter macroeconómico. En concreto, los datos relativos al índice de actividad económica global (GREA) y los de la tasa de interés Wu-Xia Shadow rate aportan información muy interesante que pocas veces es considerada en las predicciones con frecuencia diaria.

Todos los datos están comprendidos en el período entre el 26 de febrero de 2016 y el 31 de marzo de 2023.

Precio de las tierras raras

Esta variable es la que en el estudio hemos denominado *Yobj*, y recoge los precios diarios de las tierras raras para poder construir el modelo AR (1), el cual se basa en datos pasados para predecir los futuros. Dichos datos son los que proporciona *VanEck Rare Earth/Strategic Metals*, el ETF más completo de tierras raras. A la hora de importar los datos a MatLab, se ha tenido en cuenta la posibilidad de datos no existentes, y se han eliminado para limpiar el *dataset*.

Se deflactaron los precios con el *Consumer Price Index* (CPI) de Estados Unidos, ya que los precios están dados en dólares americanos, para así ajustar el precio nominal y trabajar con el precio real. El CPI de EE.UU. fue obtenido de la *St. Louis FRED*. Debido a que el CPI se reporta únicamente con frecuencia mensual, para cada precio diario, se utilizó el valor del índice CPI del mes anterior correspondiente. Esto asegura que el ejercicio de predictibilidad utilice únicamente los datos disponibles en cada fecha, para un pronóstico *out-of-sample*.

Finalmente, se estimaron los retornos porcentuales diarios de los precios reales de las tierras raras.

ESG S&P 500

El índice ESG S&P 500 es un índice bursátil que muestra el desempeño de las top 500 empresas más valoradas de Estados Unidos, en todo lo relacionado con factores ambientales, sociales y de gobierno corporativo. Proporciona a los inversores una forma directa de identificar y seguir empresas que destacan en la integración de estos factores en sus operaciones y estrategias comerciales. Estos datos fueron extraídos del *Federal Reserve Bank of Atlanta*. Tras una importación de estos a MatLab, se procedió a eliminar los datos no disponibles y a deflactar los valores con el CPI de Estados Unidos, para así una vez más trabajar con valores reales de

los precios y no con los nominales. Finalmente, se estimaron los retornos porcentuales diarios del índice ESG S&P 500.

GREA tracker

El índice GREA es una medida del ciclo económico que se utiliza para seguir las fluctuaciones en los mercados globales de productos básicos industriales, con frecuencia diaria. Se calcula a partir de las desviaciones porcentuales de los precios de materias primas con respecto a la tendencia y se actualiza diariamente para reflejar los cambios en el volumen de demanda en estos mercados (Diaz, E. M., & Perez-Quiros, G., 2021). En particular, el indicador se construye estimando el movimiento de los precios de materias primas mediante un análisis de componentes principales, donde las materias primas son seleccionadas por un algoritmo para elegir aquellas que mejor reflejen las fluctuaciones en las condiciones internacionales de negocios. La construcción de este indicador a partir de los precios de materias primas es lo que permite su disponibilidad con frecuencia diaria.¹ Estos datos luego se importaron a Matlab para su análisis. Debido a la naturaleza de este indicador, los datos se transformaron únicamente eliminando los datos no disponibles.

Shadow Rate

La *shadow rate* es un tipo de interés que se emplea para evaluar la economía en situaciones donde los tipos nominales se aproximan al umbral inferior de cero. El concepto de Shadow Rate ha ganado relevancia desde la crisis financiera de 2008, periodo en el cual las tasas nominales alcanzaron dicho límite inferior. A partir de este momento, el mecanismo tradicional de transmisión de la política monetaria a la economía real fue distorsionado, por lo que los bancos centrales comenzaron a recurrir a medidas no convencionales para estimular la economía y eliminar riesgos de deflación. Por tanto, medir los efectos de cambios en la política monetaria ya no puede realizarse únicamente a través de cambios en el tipo de interés oficial de los bancos centrales, por lo que Wu and Xia (2016) propusieron la estimación del *shadow rate*, tipo de interés que puede adoptar valores negativos cuando los tipos nominales se encuentran en el umbral inferior de cero y los bancos centrales introducen medidas de política monetaria no convencional. Aunque el *shadow rate* de Wu and Xia (2016) únicamente se

¹ Los datos han sido puestos a disposición por parte de los autores.

encuentra disponible con frecuencia mensual, De Rezende y Ristiniemi (2023), estiman los *shadow rates* de Estados Unidos, Suecia, la zona euro y el Reino Unido, con frecuencia diaria. En este trabajo se ha utilizado el *shadow rate* diario de Estados Unidos (De Rezende, R. B., & Ristiniemi, A., 2023), como proxy para los mercados financieros mundiales, obtenido de la página web personal de los autores. Los datos se transformaron únicamente eliminando los datos no disponibles.

3.2 Modelo Predictivo

El ejercicio de predicción se realizó en dos fases.

La primera, como se ha mencionado anteriormente, es un modelo autorregresivo de orden 1, comúnmente conocido como AR(1). Este modelo establece un punto de referencia, donde el valor actual de la variable dependiente se calcula como una combinación lineal de su valor en el período anterior, ajustado por un término de error. Esta estructura es útil para analizar y pronosticar series temporales en las que se cree que el valor actual está influenciado principalmente por su valor inmediatamente anterior. En este contexto, se utiliza este modelo como un punto de partida para verificar si existe alguna previsibilidad en la variable dependiente (el precio actual) en función de sus valores pasados. Por tanto, el modelo de referencia se define de la siguiente manera:

Ecuación 1:

$$y_{t+1} = \alpha + \beta y_t + \xi_{t+1} \quad \xi_t \sim (0, \sigma^2)$$

donde y_{t+1} cambio porcentual diario de los precios de tierras raras deflactados por el CPI para el tiempo $t + 1$; α es una constante, β es un coeficiente y ξ_{t+1} es un término de error que tiene una media cero y una varianza σ^2 .

El segundo modelo es una extensión del primero, conocido como modelo ARX(1). En este modelo, además de considerar el valor de la variable en el período anterior, se incorporan una o más variables exógenas. En este caso particular, se agregaron las variables de interés mencionadas anteriormente para determinar si proporcionan información adicional sobre las

futuras fluctuaciones en el precio de las tierras raras. Estas variables son el índice ESG, el Shadow Rate y el GEA Tracker.

Cabe resaltar la utilización del GEA Tracker en el ejercicio de predicción. La capacidad predictiva de este indicador depende de la exactitud con la que prediga las condiciones comerciales a nivel global. Si el GEA Tracker es un buen indicador de la actividad, debería ser útil para los pronosticadores para predecir cambios en las condiciones comerciales mundiales, y por tanto, de los precios de los metales de tierras raras.

Se utilizó la siguiente regresión predictiva para generar los pronósticos:

Ecuación 2:

$$y_{t+1} = \alpha + \beta_1 y_t + \beta_2 \Delta x_t + \xi_{t+1} \quad \xi_t \sim (0, \sigma^2)$$

donde y_{t+1} cambio porcentual diario de los precios de tierras raras deflactados por el CPI para el tiempo $t + 1$; α es una constante, β_1 y β_2 son coeficientes, Δx_t es el cambio en la variable x en el tiempo t , la cual es una matriz que contiene los datos de los precios deflactados del CPI, ESG, GEA Tracker y Wu-Xia Shadow rate; ξ_{t+1} es un término de error que tiene una media cero y una varianza σ^2 .

El ejercicio de predicción se realizó para el periodo comprendido entre el 26 de febrero de 2016 y el 31 de marzo de 2023, ya que dicho intervalo contenía los datos más completos y actualizados necesarios para el análisis. Todos los datos tienen una frecuencia diaria, incluyendo los valores obtenidos durante los días laborales comprendidos dentro de la muestra. El ejercicio se realiza de manera recursiva de forma que los parámetros de ambos modelos continuamente se actualizan a lo largo del tiempo

En cualquier momento t , el indicador GEA, se construye utilizando el último subconjunto de materias primas seleccionado por un algoritmo genético como la mejor combinación, denominada A_t . Esto significa que el Rastreador GEA f_t es una función de la combinación de materias primas en el tiempo t junto con la información disponible en ese momento I_t .

Por tanto, para asegurar que los pronósticos podrían haber sido generados en tiempo real a medida que los datos estén disponibles, se utiliza la información en cada punto en el tiempo, con una ventana expansiva para la muestra.

R²OS

El rendimiento de pronóstico de cada modelo se evalúa mediante la estadística R^2 fuera de muestra, R^2OS , sugerida por Campbell y Thompson (2008) para comparar los pronósticos \hat{y}_{t+1} y \bar{y}_{t+1} y a un horizonte de un mes, donde \hat{y}_{t+1} es un pronóstico basado en el modelo predictivo descrito por la primera ecuación, e \bar{y}_{t+1} es un pronóstico basado en el modelo de referencia descrito por la segunda ecuación. A continuación, la estadística R^2OS se calcula mediante:

Ecuación 3:

$$R^2OS = 1 - \frac{\sum_{t=t_0-1}^{T-1} (y_{t+1} - \hat{y}_{t+1})^2}{\sum_{t=t_0-1}^{T-1} (y_{t+1} - \bar{y}_{t+1})^2}$$

donde y_{t+1} es el valor realizado del cambio porcentual en el precio real de los metales raros, t_0 es el inicio de la muestra de pronóstico (26 de febrero de 2016) y T es el final de la muestra (31 de marzo de 2023). En consecuencia, el R^2OS mide la reducción en el Error Cuadrático Medio de Predicción (MSPE, por sus siglas en inglés) para el modelo de regresión predictivo en comparación con el modelo de referencia, en términos porcentuales. Así, se observa que cuando $R^2OS > 0$, los pronósticos \hat{y}_{t+1} superan los pronósticos de referencia \bar{y}_{t+1} .

Clark-West

Una vez calculado el rendimiento del pronóstico mediante el R^2OS , se comprobó si los resultados eran estadísticamente significativos. Para ello, se llevó a cabo una prueba contra la hipótesis nula de igualdad en el Error Cuadrático Medio de Predicción (MSPE) entre los dos modelos. Sin embargo, dado que el modelo de referencia está contenido dentro del modelo de regresión predictiva, el parámetro β_2 en la Ecuación 2 sería cero en la población bajo la hipótesis nula. Este hecho provoca un sesgo ascendente en la estimación del MSPE del modelo de regresión predictiva debido a dicho parámetro.

Es por ello que, siguiendo a Díaz and Pérez-Quirós (2021), para este modelo se estimó el estadístico MSPE ajustado, desarrollado por Clark and West (2007). Esta estadística ajusta el sesgo restando la diferencia cuadrática en las predicciones puntuales generadas por cada modelo de la siguiente manera.

Primero se define

Ecuación 4:

$$\zeta_{t+1} = (y_{t+1} - \bar{y}_{t+1})^2 - [(y_{t+1} - \hat{y}_{t+1})^2 - (\hat{y}_{t+1} - \bar{y}_{t+1})^2]$$

y luego se realiza la regresión de $\{\zeta_{s+1}\}_{s=t_0}^{T-1}$ en una constante para calcular el estadístico t bajo la hipótesis nula de que la constante es cero. El valor p se obtiene con una distribución normal estándar, para una prueba unilateral.

Los resultados obtenidos se muestran en la tabla 2.

Tabla 2. Resultados del ejercicio de predictibilidad

Estadístico	Valor
p_value	0,0575
R^2OS	4,9960e-14

Fuente: *elaboración propia*

Esta tabla presenta el R^2OS obtenido del ejercicio de predictibilidad de los cambios porcentuales en los precios de metales de tierras raras para el periodo comprendido entre el 26 de febrero de 2016 y el 31 de marzo de 2023. También se presenta el nivel de significatividad del R^2OS obtenido según el estadístico de Clark West. Los resultados muestran que el porcentaje de errores que se disminuyen al incorporar las tres variables al modelo es muy pequeño. Sin embargo, el p-valor nos indica que es estadísticamente distinto de cero con una significancia de casi 95%. Por tanto, procederemos a analizar, dentro de la muestra, posibles cambios en la predictibilidad de cada modelo a lo largo del tiempo.

CSPED (Cumulative Sum Prediction Error Difference)

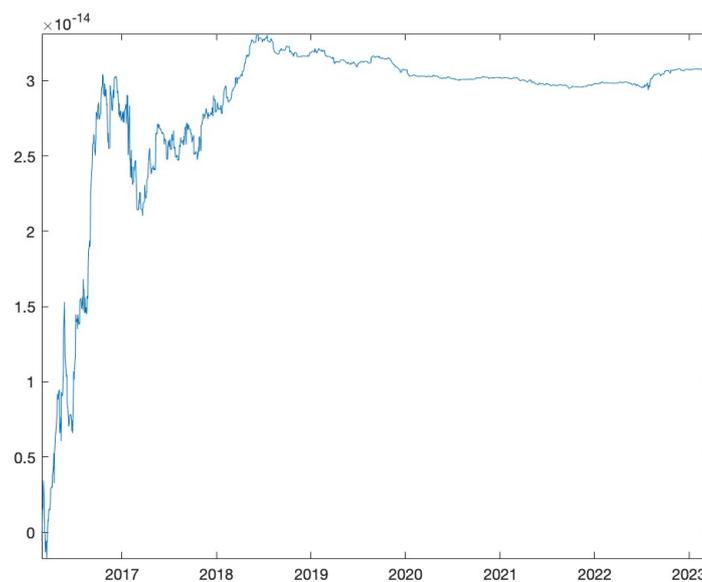
Para ello, siguiendo a Welch y Goyal (2008), también investigamos cómo varían los errores de predicción cuadráticos con el tiempo, mediante una inspección gráfica de la diferencia acumulativa de errores de predicción cuadráticos (CSPED):

Ecuación 6:

$$CSPED_t = \sum_{s=1}^t (\xi_{AR,t} - \xi_t)^2$$

donde $\xi_{AR,t}$ es el error de predicción del modelo de referencia, y ξ_t es el error de predicción del modelo que contiene todas las variables. La Figura 6 presenta los resultados. La forma de interpretar el gráfico es observando la pendiente de la función resultante. Si la pendiente es positiva, significa que el modelo propuesto es capaz de predecir los precios con mayor exactitud que el modelo de referencia; si es negativa, quiere decir que el modelo propuesto predice peor que el modelo de referencia; y si la pendiente es cero, la predictibilidad de los precios es la misma con ambos modelos. Por tanto, cuanto mayor sea la pendiente, mejor será la predicción calculada en el periodo indicado.

Figura 6: CSPED



Fuente: *elaboración propia*

4. DISCUSIÓN DE LOS RESULTADOS

Como se puede apreciar en la figura 6, durante el primer año de predicción (2016-2017), el modelo experimenta una mejora significativa en la capacidad de predecir los precios de las tierras raras en comparación con el modelo de referencia. Esto se refleja en la pendiente positiva del gráfico, lo que indica que el error del modelo propuesto es consistentemente menor que el del modelo de referencia durante este período. Esta tendencia sugiere que las variables consideradas aportan una cantidad considerable de información al modelo, lo que contribuye a su mayor precisión en las predicciones.

Sin embargo, alrededor del primer trimestre de 2017, se observa una pendiente negativa, lo que sugiere que el modelo experimentó un deterioro en la precisión de las predicciones de precios durante ese intervalo de tiempo.

A pesar de esto, entre el segundo trimestre de 2017 y la mitad de 2018, el modelo recupera su capacidad para predecir con mayor precisión que el modelo de referencia, como se observa en la pendiente positiva del gráfico. Sin embargo, a partir de ese punto, el gráfico se estabiliza con una pendiente cercana a cero, lo que indica que las predicciones del modelo se alinean con las del modelo de referencia y que las variables ya no aportan información adicional.

El deterioro en las predicciones del modelo entre 2017 y 2018 puede atribuirse al descubrimiento de un yacimiento en Japón que contiene aproximadamente 16 millones de toneladas de estos elementos. Como se indica en la tabla 3, esta cantidad es suficiente para abastecer al mundo durante más de 700 años, lo que representa una fuente casi ilimitada de metales raros y plantea un riesgo para China al poner en peligro su monopolio y posición como principal productor mundial.

Tabla 3. Principales minerales encontrados en la mina de Japón.

Elemento	Uso	Años de abastecimiento
Disproseo	Utilizado en las tecnologías de defensa, cerámica e imanes avanzados	730
Itrio	Fabricación de láseres	780
Terbio	Usado en la fabricación de los motores eléctricos e	420

híbridos, en la esfera de
defensa y en imanes
avanzados.

Europio

Usado en fluorescentes, tiene
aplicaciones en los sectores
de defensa y nuclear.

620

Fuente: *elaboración propia a partir de los datos de Takaya, Y., Yasukawa, K., Kawasaki, T., Fujinaga, K., Ohta, J., Usui, Y., ... & Kato, Y. (2018).*

El hallazgo de la mina japonesa tiene una repercusión crucial en el mercado de las tierras raras, especialmente debido al impacto que genera en los precios de estos elementos. Históricamente, China ha mantenido un fuerte control sobre la producción y exportación de tierras raras, lo que le otorgó un monopolio en este sector. Sin embargo, la aparición de la mina japonesa plantea una seria amenaza a este dominio chino.

La competencia resultante de la entrada en escena de esta nueva fuente de suministro ha provocado una alteración significativa en los precios de los lantánidos y otros elementos de tierras raras. Esta disrupción en el mercado explicaría, en gran medida, por qué el modelo propuesto en este estudio no logra predecir de manera precisa los precios durante el período comprendido entre 2017 y 2018. Específicamente, este período coincide con el inicio de la explotación de la mina japonesa, lo que genera una serie de cambios en la dinámica del mercado y en las expectativas de oferta y demanda de tierras raras a nivel global.

En este contexto, la presencia de una nueva fuente de suministro con un potencial significativo de abastecimiento modifica la percepción de escasez y la dinámica de precios que anteriormente estaban influidas por el monopolio chino. Por lo tanto, el hallazgo de la mina japonesa representa un hito importante en el mercado de las tierras raras y señala un cambio significativo en la estructura y la competencia de la industria a nivel mundial.

5. CONCLUSIÓN

El objetivo de este trabajo ha sido averiguar si es posible construir un modelo predictivo para el precio de las tierras raras.

Para lograrlo, se ha llevado a cabo un análisis de las variables más relevantes, es decir, aquellas que tienen un mayor impacto en la variación de los precios de estas materias primas. Estas variables, incluidas en el modelo, son la Tasa de Fondos Federales en Sombras de Wu-Xia (2016), que es una tasa de interés utilizada para evaluar la economía en situaciones donde las tasas nominales se acercan al límite inferior de cero; el Índice S&P 500 ESG, que es un indicador ambiental, social y de gobierno corporativo que refleja la demanda de estos metales; y el índice GREA, que es un indicador del ciclo económico expresado como desviaciones porcentuales de la tendencia, y se considera como un indicador del volumen de envíos en los mercados mundiales de materias primas industriales.

Lo más significativo de este análisis y de los datos empleados ha sido la frecuencia diaria de los mismos. Esto ha aportado una gran cantidad de información adicional que con datos mensuales no se habría podido detectar.

El análisis de los datos se realizó a través de un modelo de referencia (benchmark) y otro modelo propuesto. El primero comprende los precios diarios de tierras raras entre el 26 de febrero de 2016 y el 31 de marzo de 2023; el segundo añade las variables explicadas anteriormente durante las mismas fechas y con frecuencia diaria, y así poder compararlo con el anterior, y poder analizar si efectivamente las variables afectan a las predicciones o no.

Los resultados más relevantes han sido la posibilidad de realizar estas predicciones con el modelo propuesto en periodos donde China llevaba el monopolio mundial de tierras raras (2016-2017), y donde las condiciones económico-políticas son relativamente estables (segunda mitad de 2017 – primera mitad de 2018). Posteriormente, el modelo es incapaz de predecir estos precios principalmente por la aparición de nuevas minas fuera de China.

La principal contribución de este trabajo es la realización de las predicciones de precios de tierras raras con datos diarios en vez de mensuales, así como dar luz acerca de por qué en el presente resulta más difícil realizar estas predicciones en el mercado de las commodities.

6. ANEXO

```
clear
clc
%Deflactar precios con el CPI
[Yobj,data_text] = xlsread("precios_diarios.xlsx",1);%leer datos

Dates = Yobj(:,1);
Yobj = Yobj(:,2);
Dates = Dates(~isnan(Yobj));
Yobj = Yobj(~isnan(Yobj));

Dates = datetime(Dates, 'ConvertFrom', 'excel');
Dates = flipud(Dates);
Dates = Dates(1:3127);
Yobj = flipud(Yobj);
Yobj = Yobj(1:3127);

[CPI, data_text] = xlsread("US_CPI.xlsx",1);
Dates_cpi = CPI(:,1);
CPI = CPI(:,2);
Dates_cpi = Dates_cpi(~isnan(CPI));
CPI = CPI(~isnan(Dates_cpi));

Dates_cpi = datetime(Dates_cpi, 'ConvertFrom', 'excel');

Real_Price = Yobj;
for t=1 : size(CPI,1)
    index = month(Dates) == month(Dates_cpi(t,1))...
    & year(Dates) == year(Dates_cpi(t,1));
    Real_Price(index,1) = Real_Price(index,1)/CPI(t,1);
end

Yobj = detrend(log(Real_Price));

%% TIME TO PREPARE THE REST OF THE VARIABLES FOR THE PROPOSED MODEL
% Lo mismo para el ESG, deflactarlo con el CPI y hacer que los vectores
% tengan las mismas dimensiones y fechas

[ESG,data_text] = xlsread("MSCI.xlsx",1);%leer datos

Dates_msci = ESG(:,1);
ESG = ESG(:,2);
Dates_msci = Dates_msci(~isnan(ESG));
ESG = ESG(~isnan(ESG));

Dates_msci = datetime(Dates_msci, 'ConvertFrom', 'excel');
Dates_msci = flipud(Dates_msci);
ESG = flipud(ESG);

[CPI, data_text] = xlsread("US_CPI.xlsx",1);
Dates_cpi = CPI(:,1);
CPI = CPI(:,2);
Dates_cpi = Dates_cpi(~isnan(CPI));
CPI = CPI(~isnan(CPI));
```

```

Dates_cpi = datetime(Dates_cpi, 'ConvertFrom', 'excel');

Real_msci = ESG;
for t=1 : size(CPI,1)
    index = month(Dates_msci) == month(Dates_cpi(t,1))...
    & year(Dates_msci) == year(Dates_cpi(t,1));
    Real_msci(index,1) = Real_msci(index,1)/CPI(t,1);
end

Real_msci = detrend(log(Real_msci));
Real_msci =Real_msci(datefind(Dates, Dates_msci));
Dates_msci =Dates_msci(datefind(Dates, Dates_msci));

% Para el Shadow Rate no hay que hacer nada de deflactar, solo concat
[SR,data_text] = xlsread("Shadow rates all economies.xlsx",1);%leer datos

Dates_SR = SR(:,1);
SR = SR(:,4);

% Cargamos el GEA Tracker
[GEA,data_text] = xlsread("GEA Tracker.xlsx",1);%leer datos

Dates_gea = GEA(:,1);
GEA = GEA(:,2);
Dates_gea = Dates_gea(~isnan(GEA));
GEA = GEA(~isnan(GEA));

Dates_gea = datetime(Dates_gea, 'ConvertFrom', 'excel');

%anadir linea codigo de lagmatrix

Dates_SR = datetime(Dates_SR, 'ConvertFrom', 'excel');
SR = SR(datefind(Dates, Dates_SR));
Dates_SR = Dates_SR(datefind(Dates, Dates_SR));

% Unir fechas de todos los datos
DATES = Dates(datefind(Dates_gea,Dates));
DATES = DATES(datefind(Dates_SR,DATES));

Yobj = Yobj(datefind(Dates,DATES));
Real_msci = Real_msci(datefind(Dates_msci, DATES));
SR = SR(datefind(Dates_SR, DATES));
GEA = GEA(datefind(Dates_gea, DATES));

%% Benchmark model

X_temp = lagmatrix(Yobj, 1);           %retrasamos los datos a t-1

X_temp = X_temp(2:end,:);             %cortamos el primer dato de t-1

Y = Yobj(2:756,1);                     %nos quedamos con la primera
columna y 756 filas

```

```

X = [ones(755,1) X_temp(1:755,1)];           %generamos un vector de unos
BETA = inv(X'*X)*X'*Y;                       %calculamos la Beta
T = size(Yobj,1)-755;                         %para el loop, definimos el num de
iteraciones
Y_bench = NaN(T,1);                          %crear matriz vacia para que el
loop la rellene
for t=1:T                                     %loop que crea la Y_bench
    Y = Yobj(1:754+t,1);
    X = [ones(754+t, 1) X_temp(1:754+t, 1)];
    B = inv(X'*X)*X'*Y;
    Y_bench(t,1) = X(end,:)*B;
end
% BENCHMARK COMPLETED

%% Proposed model (coming up)
X_temp = lagmatrix([Yobj Real_msci SR GEA], 1);

X_temp = X_temp(2:end,:);                    %cortamos el primer dato de t-1
Y = Yobj(2:756,1);                           %nos quedamos con la primera
columna y 755 filas
X = [ones(755,1) X_temp(1:755,1)];           %generamos un vector de unos
BETA = inv(X'*X)*X'*Y;                       %calculamos la Beta
T = size(Yobj,1)-755;                         %para el loop, definimos el num de
iteraciones
Y_proposed = NaN(T,1);                       %crear matriz vacia para que el
loop la rellene
for t=1:T                                     %loop que crea la Y_bench
    Y = Yobj(1:754+t,1);
    X = [ones(754+t, 1) X_temp(1:754+t, :)];
    B = inv(X'*X)*X'*Y;
    Y_proposed(t,1) = X(end,:)*B;
end
%% R20S
Y_sample = Yobj(756:end);
R20S = 1 - sum((Y_sample - Y_proposed).^2)/sum((Y_sample - Y_bench).^2);

%% C
C = (Y_sample - Y_bench).^2 - ((Y_sample - Y_proposed).^2 - ...
(Y_proposed - Y_bench).^2);

```

```
EstMdl = fitlm(ones(size(C,1), 1), C , 'Intercept', false);
p_value = table2array(EstMdl.Coefficients(1,4));

%% CSPED
CSPED = cumsum((Y_sample - Y_bench).^2 - (Y_sample - Y_proposed).^2);

%% Plot
dates_sample = DATES(756:end);

figure
plot(dates_sample, CSPED)
axis tight
```

7. 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, Jesús García Lozano, estudiante de E2+analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Análisis Predictivo del Precio de las Tierras Raras", 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. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
4. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
5. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
6. **Generador previo de diagramas de flujo y contenido:** Para esbozar diagramas iniciales.
7. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
8. **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: 23 de abril de 2024

Firma: JESÚS GARCÍA LOZANO

8. BIBLIOGRAFÍA

- Castor, S. B., & Hedrick, J. B. (2006). Rare earth elements. *Industrial minerals and rocks*, 7, 769-792.
https://web.archive.org/web/20180722021907id/http://www.fieldexploration.com/images/property/1_RareEarths_FLX_02.pdf
- Chakhmouradian, A. R., & Wall, F. (2012). Rare earth elements: minerals, mines, magnets (and more). *Elements*, 8(5), 333-340.
<https://doi.org/10.2113/gselements.8.5.333>
- Dushyantha, N., Batapola, N., Ilankoon, I. M. S. K., Rohitha, S., Premasiri, R., Abeyasinghe, B., ... & Dissanayake, K. (2020). The story of rare earth elements (REEs): Occurrences, global distribution, genesis, geology, mineralogy and global production. *Ore Geology Reviews*, 122, 103521.
<https://doi.org/10.1016/j.oregeorev.2020.103521>
- Diaz, E. M., & Perez-Quiros, G. (2021). GEA tracker: A daily indicator of global economic activity. *Journal of International Money and Finance*, 115, 102400.
<https://doi.org/10.1016/j.jimonfin.2021.102400>
- Expansión (2024). Expectativas racionales. En *Diccionario Económico de Expansión*. Recuperado de <https://www.expansion.com/diccionario-economico/expectativas-racionales.html>
- Kanazawa, Y., & Kamitani, M. (2006). Rare earth minerals and resources in the world. *Journal of alloys and compounds*, 408, 1339-1343.
<https://doi.org/10.1016/j.jallcom.2005.04.033>
- Liu, T., & Chen, J. (2021). Extraction and separation of heavy rare earth elements: A review. *Separation and Purification Technology*, 276, 119263.
- Muhammad Adeel, Jie Yinn Lee, Muhammad Zain, Muhammad Rizwan, Aamir Nawab, M.A. Ahmad, Muhammad Shafiq, Hao Yi, Ghulam Jilani, Rabia Javed, R. Horton, Yukui Rui, Daniel C.W. Tsang, Baoshan Xing, Cryptic footprints of rare

earth elements on natural resources and living organisms, *Environment International*, Volume 127, 2019, Pages 785-800, ISSN 0160-4120, <https://doi.org/10.1016/j.envint.2019.03.022>

- De Rezende, R. B., & Ristiniemi, A. (2023). A shadow rate without a lower bound constraint. *Journal of Banking & Finance*, 146,106686.<https://doi.org/10.1016/j.jbankfin.2022.106686>

- Taylor, S.R., and S.M. McClennan. 1985. *The Continental Crust: Its Composition and Evolution*. Oxford, UK: Blackwell Scientific Publications.

- Takaya, Y., Yasukawa, K., Kawasaki, T., Fujinaga, K., Ohta, J., Usui, Y., ... & Kato, Y. (2018). The tremendous potential of deep-sea mud as a source of rare-earth elements. *Scientific reports*, 8(1), 1-8. <https://www.nature.com/articles/s41598-018-23948-5.pdf>

- V. Balam, Rare earth elements: A review of applications, occurrence, exploration, analysis, recycling, and environmental impact, *Geoscience Frontiers*, Volume 10, Issue 4, 2019, Pages 1285-1303, ISSN 1674-9871, <https://doi.org/10.1016/j.gsf.2018.12.005>

- Welch, I., & Goyal, A. (2008). A comprehensive look at the empirical performance of equity premium prediction. *Review of Financial Studies*, 21(4), 253–303.

- Zhou B, Li Z, Chen C. Global Potential of Rare Earth Resources and Rare Earth Demand from Clean Technologies. *Minerals*. 2017; 7(11):203. <https://doi.org/10.3390/min7110203>

- Wu Xia: Federal reserve bank of Atlanta <https://www.atlantafed.org/cqer/research/wu-xia-shadow-federal-funds-rate>

- S&P500 ESG Index: <https://www.atlantafed.org/cqer/research/wu-xia-shadow-federal-funds-rate>